

INSTITUTO FEDERAL DO ESPÍRITO SANTO
MESTRADO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

LUCAS DE OLIVEIRA SOARES

**DETECÇÃO DE MOTOR COM FUGA À TERRA EM SISTEMAS DE BAIXA
TENSÃO DE NEUTRO ATERRADO COM RESISTOR DE ALTO VALOR
UTILIZANDO APRENDIZADO MÁQUINA**

SERRA
2022

LUCAS DE OLIVEIRA SOARES

**DETECÇÃO DE MOTOR COM FUGA À TERRA EM SISTEMAS DE BAIXA
TENSÃO DE NEUTRO ATERRADO COM RESISTOR DE ALTO VALOR
UTILIZANDO APRENDIZADO MÁQUINA**

Dissertação apresentada à Coordenadoria do Curso de Mestrado em Engenharia de Controle e Automação do Instituto Federal do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador:

Prof. Dr. Luiz Alberto Pinto

Coorientador:

Prof. Dr. Marco Antonio de Souza Leite Cuadros

SERRA

2022

Dados Internacionais de Catalogação na Publicação (CIP)

S676d Soares, Lucas de Oliveira
2022 Detecção de motor com fuga à terra em sistemas de baixa tensão de neutro aterrado com resistor de alto valor utilizando aprendizado de máquina / Lucas de Oliveira Soares. - 2022.
104 f. : il. ; 30 cm

Orientador: Prof. Dr. Luiz Alberto Pinto.

Coorientador: Prof. Dr. Marco Antonio de Souza Leite Cuadros.

Dissertação (mestrado) - Instituto Federal do Espírito Santo, Programa de Pós-graduação em Engenharia de Controle de Automação, 2022.

1. Aparelhos e materiais elétricos. 2. Aprendizado do computador. 3. Sistemas de reconhecimento de padrões. 4. Sistemas de energia elétrica. 5. Motores elétricos. I. Pinto, Luiz Alberto. II. Cuadros, Marco Antonio de Souza Leite. III. Instituto Federal do Espírito Santo. IV. Título.

CDD 621.31042

Biblioteca Rogéria Gomes Belchior - CRB6/ES 417

MINISTÉRIO DA EDUCAÇÃO
INSTITUTO FEDERAL DO ESPÍRITO SANTO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

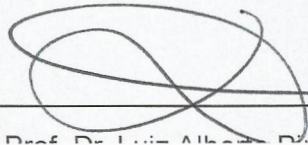
LUCAS DE OLIVEIRA SOARES

DETECÇÃO DE MOTOR COM FUGA À TERRA EM SISTEMAS DE BAIXA TENSÃO DE NEUTRO
ATERRADO COM RESISTOR DE ALTO VALOR UTILIZANDO APRENDIZADO DE MÁQUINA

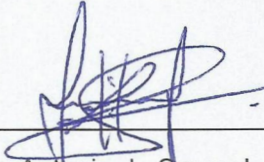
Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Controle e Automação do Instituto Federal do Espírito Santo, como requisito parcial para obtenção de título de Mestre em Engenharia de Controle e Automação.

Aprovado em 08 de março de 2022

COMISSÃO EXAMINADORA



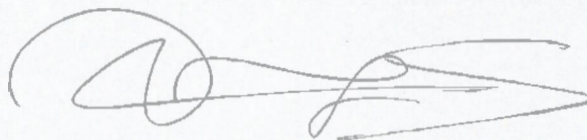
Prof. Dr. Luiz Alberto Pinto
Instituto Federal do Espírito Santo
Orientador



Prof. Dr. Marco Antonio de Souza Leite Cuadros
Instituto Federal do Espírito Santo
Orientador



Prof. Dr. Daniel Cruz Cavaliere
Instituto Federal do Espírito Santo
Membro Interno



Prof. Dr. Jorge Leonid Aching Samatelo
Universidade Federal do Espírito Santo
Membro Externo

AGRADECIMENTOS

Agradeço a Deus por me proporcionar perseverança durante toda a minha vida. Aos meus pais Rosa e Adelson pelo apoio e incentivo que serviram de alicerce para as minhas realizações em todos os momentos da minha vida. À minha querida esposa Polyanna pelo seu amor incondicional e por compreender minha dedicação ao projeto de pesquisa. Ao meu professor orientador Luiz Alberto Pinto pelas valiosas contribuições e ensinamentos dados durante todo o processo. A todos os meus amigos do curso de Pós-Graduação que compartilharam dos inúmeros desafios que enfrentamos, sempre com o espírito colaborativo. Também quero agradecer ao Instituto Federal do Espírito Santo e o seu corpo docente do curso de Pós-Graduação em Engenharia de Controle e Automação que demonstraram estar comprometidos com a qualidade e excelência do ensino e me ensinaram.

"Quando você perde sua mente pequena você liberta sua vida."

- *Serj Tankian / Daron Malakian*

RESUMO

O presente trabalho apresenta técnicas de reconhecimento de padrões utilizados na identificação de falhas em equipamentos elétricos de processos industriais. Foi utilizado um conjunto de dados obtido por meio de medição de correntes residuais, ou correntes de sequência zero, em equipamentos trifásicos presentes em Centros de Controle de Motores (CCMs) nas condições normais de operação e na condição de falha por fuga à terra. O sistema elétrico onde foram coletados estes dados possui a configuração de aterramento do neutro por meio de resistor de alto valor ôhmico, que limita as correntes de fuga à terra dificultando a identificação dos equipamentos que apresentam este tipo de defeito. Como o sistema não possui ferramentas para diagnóstico automático, as falhas foram identificadas ao longo de treze meses pelo time da manutenção da fábrica, realizando medições de corrente residual de carga por carga associada a parada dos equipamentos e medição da resistência de isolamento em referência à terra para constatação do defeito. Para análise das falhas, foram utilizados como descritores os sinais brutos, os sinais tratados por meio de dados estatísticos no domínio do tempo e no domínio tempo-frequência. Os modelos utilizados como treinamento foram os algoritmos k vizinho mais próximo, árvore de decisão, floresta aleatória, máquinas de vetores de suporte e redes neurais convolucionais. Diversos testes foram realizados utilizando todo o conjunto de dados com objetivo de verificar o desempenho dos treinamentos em busca dos melhores classificadores. Os resultados demonstram a eficiência de todas as técnicas, bem como as vantagens de se implementar um sistema de diagnóstico para identificar problemas e manter a disponibilidade/confiabilidade dos equipamentos, aumentando a segurança das pessoas e dos processos nestas instalações.

Palavras-chave: Diagnóstico de falhas, fuga à terra, extração de características, classificação, reconhecimento de padrões, equipamentos elétricos.

ABSTRACT

The present work presents pattern recognition techniques used in the identification of failures in industrial process electrical equipment. A set of data obtained by measuring residual currents, or zero-sequence currents, in three-phase equipment present in Motor Control Centers (MCCs) in normal operating conditions and in the condition of fault due to earth leakage was used. The electrical system where these data were collected has a neutral grounding configuration by means of a high ohmic resistor, which limits the leakage currents to earth, making it difficult to identify the equipment that has this type of defect. As the system does not have automatic diagnostic tools, failures were identified over thirteen months by the factory maintenance team, performing load residual current measurements per load associated with equipment stoppage and insulation resistance measurement in reference to ground for verification of the defect. For failure analysis, raw signals, signals treated by statistical data in the time domain and in the time-frequency domain were used as descriptors. The models used as training were the k nearest neighbor algorithms, decision tree, random forest, support vector machines and convolutional neural networks. Several tests were carried out using the entire dataset in order to verify the performance of training in search of the best classifiers. The results demonstrate the efficiency of all techniques, as well as the advantages of implementing a diagnostic system to identify problems and maintain equipment availability/reliability, increasing the safety of people and processes in these facilities.

Keywords: Fault diagnosis, earth leakage, feature extraction, classification, pattern recognition, electrical equipment.

LISTA DE ILUSTRAÇÕES

Figura 1 – Esquema de medição de corrente de fuga com sistema de pulso.....	18
Figura 2 – Esquema de conexão para o indicador de falha direcional, fornecendo uma corrente e tensão de sequência zero.....	19
Figura 3 – Princípio de operação do sistema de localização de falta a terra por medição de queda de tensão.....	20
Figura 4 – Topologia de controle centralizada para detecção de falta a terra com injeção de corrente externa.....	21
Figura 5 – Deslocamento parcial do neutro em sistema aterrado por resistência.....	25
Figura 6 – Diagrama fasorial do fluxo de corrente da fase C para falta à terra de um sistema RAV.....	26
Figura 7 – Modelos de transformadores de corrente tipo janela.....	28
Figura 8 – Esquema de ligação do sistema de detecção de falta a terra tipo ground sensor.....	28
Figura 9 – Relé de proteção SEL-849 para proteção de motores de baixa tensão.....	29
Figura 10 – Esquema de ligação do sistema de detecção de falta a terra tipo residual.....	29
Figura 11 – USC – Dispositivo para pesquisar o circuito em falta para a terra.....	30
Figura 12 – Valor de um relé de proteção com módulo de detecção de falta a terra.....	31
Figura 13 – Exemplo ilustrativo do algoritmo <i>SVM</i>	33
Figura 14 – Exemplo ilustrativo do algoritmo <i>k-NN</i> com $k=4$	36
Figura 15 – Exemplo ilustrativo do algoritmo <i>árvore de decisão</i>	36
Figura 16 – Exemplo ilustrativo do algoritmo <i>Random Forest</i>	39
Figura 17 – Arquitetura de rede convolucional unidimensional.....	40
Figura 18 – Análise multirresolução do sinal $f(x)$ com bancos de filtros passa-alta e passa-baixa.....	42
Figura 19 – Matriz de confusão de 2 classes.....	45
Figura 20 – Detalhe construtivo do CCM.....	47
Figura 21 – Equipamentos utilizados para aquisição de dados em campo - Oscilógrafo Yokogawa DL350 e Garra de Medição de Corrente Yokogawa 96033.....	48
Figura 22 – Espaço amostral das correntes de motores normais e com fuga a terra no domínio do tempo.....	50
Figura 23 – Coeficientes de detalhe e aproximação de sinais de corrente de sequência zero em motores normais com filtro <i>Coiflet 1</i>	51
Figura 24 – Coeficientes de detalhe e aproximação de sinais de corrente de sequência zero em motores com fuga à terra com filtro <i>Coiflet 1</i>	51

Figura 25 – Melhores Resultados de f1-score para cada conjunto de descritores..... 64

LISTA DE TABELAS

Tabela 1 – medidas estatísticas extraídas do sinal no domínio do tempo e tempo/escala..	44
Tabela 2 – Número de amostras por classe.....	48
Tabela 3 – Arquivos coletados em campo.....	49
Tabela 4 – Divisão de pontos amostrais para cada classe.....	49
Tabela 5 – Dimensões das matrizes por classe.....	54
Tabela 6 – Resultado classificação no domínio do tempo com descritores estatísticos.....	55
Tabela 7 – Dimensões das matrizes por coeficientes e níveis de resolução.....	55
Tabela 8 – Resultados de desempenho nos testes dos classificadores DT, SVM e RF com descritores estatísticos obtidos dos coeficientes no domínio tempo-escala.....	57
Tabela 9 – Resultados de desempenho nos testes do classificador k-NN com k igual a 1, 3 e 5 com descritores estatísticos obtidos dos coeficientes no domínio tempo-escala.....	58
Tabela 10 – Dimensões das matrizes por coeficientes e níveis de resolução.....	59
Tabela 11 – Resultados de desempenho nos testes dos classificadores DT, SVM e RF com descritores de entropia de <i>Shannon</i> obtidos dos coeficientes no domínio tempo-escala.....	60
Tabela 12 – Resultados de desempenho nos testes do classificador k-NN com k igual a 1, 3 e 5 com descritores de entropia de <i>Shannon</i> obtidos dos coeficientes no domínio tempo-escala.....	61
Tabela 13 – Resultados com otimizador <i>SGDM</i>	62
Tabela 14 – Resultados com otimizador <i>RMSPROP</i>	62
Tabela 15 – Resultados com otimizador <i>ADAM</i>	63

LISTA DE ABREVIATURAS E SIGLAS

CCM	Centro de Controle de Motores
CDC	Centro de Distribuição de Cargas
CWT	Continuous Wavelet Transform
DT	Decision Tree
DWT	Discrete Wavelet Transform
F1	F1-Score
FN	False Negative
FP	False Positive
HGR	High Grounding Resistance
IEEE	Institute of Electrical and Electronic Engineers
k-NN	k-Nearest Neighbor
LGR	Low Grounding Resistance
MIT	Motor de Indução Trifásico
PCA	Principal Component Analysis
RAV	Resistor de Alto Valor
RBF	Radial Basis Function
RBV	Resistor de Baixo Valor
RF	Random Forest
RMS	Root Mean Square
SEL	Schweitzer Engineering Laboratories
STFT	Short Time Fourier Transform
SVM	Support Vector Machine
TC	Transformador de Corrente
TN	True Negative

TP True Positive

TW Transformada Wavelet

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVO GERAL.....	16
1.2	OBJETIVOS ESPECÍFICOS.....	16
2	REVISÃO DO ESTADO DA ARTE	17
3	ANÁLISE DE TÉCNICAS DE SISTEMAS DE ATERRAMENTO E PROTEÇÃO	24
3.1	SISTEMAS ATERRADOS POR RESISTOR DE ALTO VALOR.....	24
3.1.1	Principais vantagens e desvantagens da utilização dos resistores de alto valor	25
3.2	SISTEMAS PARA DETECÇÃO DE FALTA À TERRA EM INSTALAÇÕES COM ATERRAMENTO DO NEUTRO POR RAV.....	27
3.3	PROBLEMAS CAUSADOS PELA CIRCULAÇÃO DE CORRENTES DE FUGA A TERRA EM INSTALAÇÕES ELÉTRICAS.....	31
4	REFERENCIAL TEÓRICO	33
4.1	ALGORITMOS DE CLASSIFICAÇÃO.....	33
4.1.1	Máquinas de Vetores de Suporte (Support Vector Machine - SVM)	33
4.1.2	k Vizinho Mais Próximo (k-Nearest Neighbour - k-NN)	34
4.1.3	Árvore de Decisão (Decision Tree - DT)	35
4.1.4	Floresta Aleatória (Random Forest - RF)	38
4.1.5	Redes Neurais Convolucionais	39
4.1.5.1	Métodos de Otimização.....	41
4.2	TRANSFORMADA WAVELET.....	41
4.2.1	Extração de características derivadas da transformada wavelet	43
4.2.1.1	Extração de características por entropia de Shannon.....	43
4.2.1.2	Extração de características por medidas estatísticas.....	43
4.3	NORMALIZAÇÃO DOS DADOS.....	44
4.3.1	Normalização por reescala	44
4.3.2	Normalização por padronização	45
4.4	MÉTRICAS DE DESEMPENHO.....	45
5	METODOLOGIA	47
5.1	AQUISIÇÃO DO SINAIS DE FUGA À TERRA.....	47
5.2	SEGMENTAÇÃO DOS SINAIS.....	49
5.3	ANÁLISE DOS DADOS E EXTRAÇÃO DE CARACTERÍSTICAS.....	50
5.4	TREINAMENTO DO CLASSIFICADOR.....	52

6	RESULTADOS	54
6.1	RESULTADO DA CLASSIFICAÇÃO COM OS MODELOS CONSTRUÍDOS COM DESCRITORES ESTATÍSTICOS NO DOMÍNIO DO TEMPO.....	54
6.2	RESULTADO DA CLASSIFICAÇÃO COM OS MODELOS CONSTRUÍDOS COM A UTILIZAÇÃO DE DESCRITORES NO DOMÍNIO <i>WAVELET</i>	55
6.3	RESULTADO DA CLASSIFICAÇÃO COM OS MODELOS CONSTRUÍDOS COM DESCRITORES OBTIDOS PELA ENTROPIA DE SHANNON NO DOMÍNIO <i>WAVELET</i>	59
6.4	RESULTADO DA CLASSIFICAÇÃO COM OS MODELOS CONSTRUÍDOS REDE NEURAL CONVOLUCIONAL.....	62
6.5	COMPARAÇÃO DOS RESULTADOS.....	63
7	CONCLUSÃO	65
7.1	TRABALHOS FUTUROS.....	66
	REFERÊNCIAS	67
	APÊNDICE A – Resultados dos Modelos.....	73
	ANEXO A – Tipos de Aterramentos em Sistemas Elétricos Industriais.....	96
	ANEXO B – Descrição do sistema elétrico onde foi adquirido o conjunto de dados.....	100
	ANEXO C – Publicações.....	104

1 INTRODUÇÃO

Nos ambientes industriais existe uma diversidade de equipamentos complexos que são essenciais ao processo produtivo e, para o pleno funcionamento desses, as instalações dos circuitos de alimentação elétrica devem ser confiáveis, a fim de garantir a continuidade dos serviços com o mínimo de falhas. Interrupções na operação de equipamentos elétricos na indústria causam grande impacto em função da sua representatividade. Por exemplo, os motores de indução trifásicos (MIT) são responsáveis por 95% de todos os acionamentos das principais indústrias do mundo e consomem cerca de 50% da energia nestes setores (SOBRINHO, 2015). Com isso, as possibilidades de falhas nestes componentes, bem como em painéis, barramentos, entre outros, devem ser evitadas com a utilização de técnicas de manutenção eficientes, que sejam capazes de manter estes ativos em condições operacionais.

Nesse contexto, as práticas de manutenções devem estar solidamente estruturadas para aumentar a confiabilidade operacional e reduzir os custos associados a eventuais falhas que possam afetar o sistema produtivo. A confiabilidade dos ativos é essencial para a viabilidade financeira do negócio, e isto deve ser levado em consideração nos custos de produção, pois paradas não programadas provocadas por falhas nos sistemas podem representar até 40% do valor total dos ativos disponíveis nos parques industriais (ALMEIDA, 2018).

Segundo Bowen (2011), 98% das falhas em sistemas elétricos de potência estão associadas a falhas fase-terra (monofásicas). Outros tipos de falhas (bifásicas e trifásicas), em grande parte, são evoluções de falhas monofásicas, ou oriundas de falhas humanas relacionadas a operações mal realizadas. Uma das soluções mais comumente utilizadas para a redução do impacto causado por falhas fase-terra, em sistemas industriais de baixa tensão, é a utilização de aterramento do neutro através de um resistor de alta impedância, a fim de limitar as correntes entre fase-terra para valores na faixa de 1A a 10A. Uma das vantagens da implementação dessa solução, do ponto de vista do funcionamento do sistema, é que o mesmo poderá continuar em operação pelo tempo necessário para que a falha seja encontrada e eliminada, antes que evolua para situações de maior gravidade.

Embora a implementação de sistemas de alimentação trifásicos com neutro aterrado por resistor de alta impedância, seja vantajosa do ponto de vista funcional, a identificação e o isolamento de problemas associados com faltas à terra (curto-circuitos fase-terra), em centros de controle de motores (CCM), nesses sistemas é um desafio para a manutenção. As correntes de baixa intensidade que circulam entre fase e terra nesses sistemas podem ser facilmente confundidas com as correntes provenientes de desbalanço de fases. Outro aspecto que pode dificultar a identificação das correntes de fuga à terra, é a grande quantidade de cargas no mesmo sistema, o que requer, para a identificação da carga que apresenta a fuga à terra, a medição pontual da

corrente em cada carga, aumentando a probabilidade de erro humano na identificação, o que pode mesmo não ocorrer em função do que foi citado em (HUSSEY; DRZYMALA, 2019).

Existem no mercado dispositivos e sistemas para equipamentos elétricos de baixa tensão que realizam a proteção de detecção de falta à terra que, em sua maioria, se baseiam na identificação do desbalanço de corrente por meio de um transformador toroidal. Além do custo de implantação destes dispositivos ser elevado, a medição de assimetria de corrente exige alta sensibilidade, e estes estão propensos a desligamentos indesejados, devido a correntes de partida e de comutação para grandes cargas, ao desbalanço natural da alimentação no sistema elétrico e, principalmente, devido a circulação de correntes oriundas de componentes capacitivas, intrínsecas em instalações industriais. Instalações industriais antigas que, originalmente, não possuem sistemas para detecção de fuga à terra em seus alimentadores devem ter seus projetos atualizados e modernizados para obter este tipo de proteção.

Este trabalho apresenta uma proposta para a identificação de falta à terra em alimentadores de motores em sistemas aterrados por resistor de alta impedância em CCMs (Centro de Controle de motores) de uma planta industrial de celulose. Para a realização dos experimentos foram utilizadas as medições de corrente de sequência zero com os equipamentos em condição de operação normal e em condição de falha. Os dados foram coletados por meio de um registrador de alta capacidade de amostragem de até 1 MHz. O método proposto foi concebido tendo por base um CCM que alimenta mais de 60 motores, e o objetivo é a identificação do motor, de forma individual, que apresenta a falta de fuga à terra. Para a construção dos modelos foram extraídos descritores estatísticos dos sinais no domínio tempo e no domínio tempo/escala obtidos com transformada *wavelet*. Os classificadores foram implementados com a utilização dos algoritmos vizinho mais próximo (*k-Nearest Neighbour k-NN*), árvore de decisão (*Decision Tree DT*), máquinas de vetores de suporte (*Support Vector Machine SVM*), floresta aleatória (*Random Forest RF*) e rede neural convolucional (*Convolutional Neural Network CNN*).

Na sequência, este trabalho está constituído pelos seguintes capítulos: o Capítulo 2 contém uma revisão bibliográfica do estado da arte sobre utilização de sinais elétricos para o diagnóstico de faltas à terra; o Capítulo 3 faz uma abordagem sobre as técnicas de aterramento utilizadas em sistemas elétricos, e as estratégias para proteção contra correntes de fuga existentes. O Capítulo 4, faz uma breve descrição teórica das técnicas e ferramentas aplicadas para a execução da pesquisa, com destaque para os algoritmos de classificação. O Capítulo 5 apresenta a metodologia que orientou a realização do trabalho com uma detalhada descrição do conjunto de dados. O Capítulo 6 apresenta os resultados dos testes realizados e o Capítulo 7 traz as conclusões derivadas da elaboração da pesquisa.

1.1 OBJETIVO GERAL

O objetivo geral deste trabalho é o desenvolvimento de um sistema para identificação de falha de fase à terra em alimentadores de motores elétricos em CCMs, por meio de medição de correntes de sequência zero, com o uso de técnicas de aprendizado de máquina.

1.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos são:

- Construir um conjunto de dados para o estudo de identificação de cargas com falha a terra em sistemas aterrados por resistor de alto valor;
- Estudar e implementar técnicas de análise de sinais brutos, no domínio do tempo e no domínio tempo-escala para avaliação das melhores técnicas;
- Implementar e validar modelos de classificação binários que recebem como entradas os vetores de características já definidos;
- Definir o melhor critério de avaliação dos algoritmos classificadores utilizados nessa pesquisa;

2 REVISÃO DO ESTADO DA ARTE

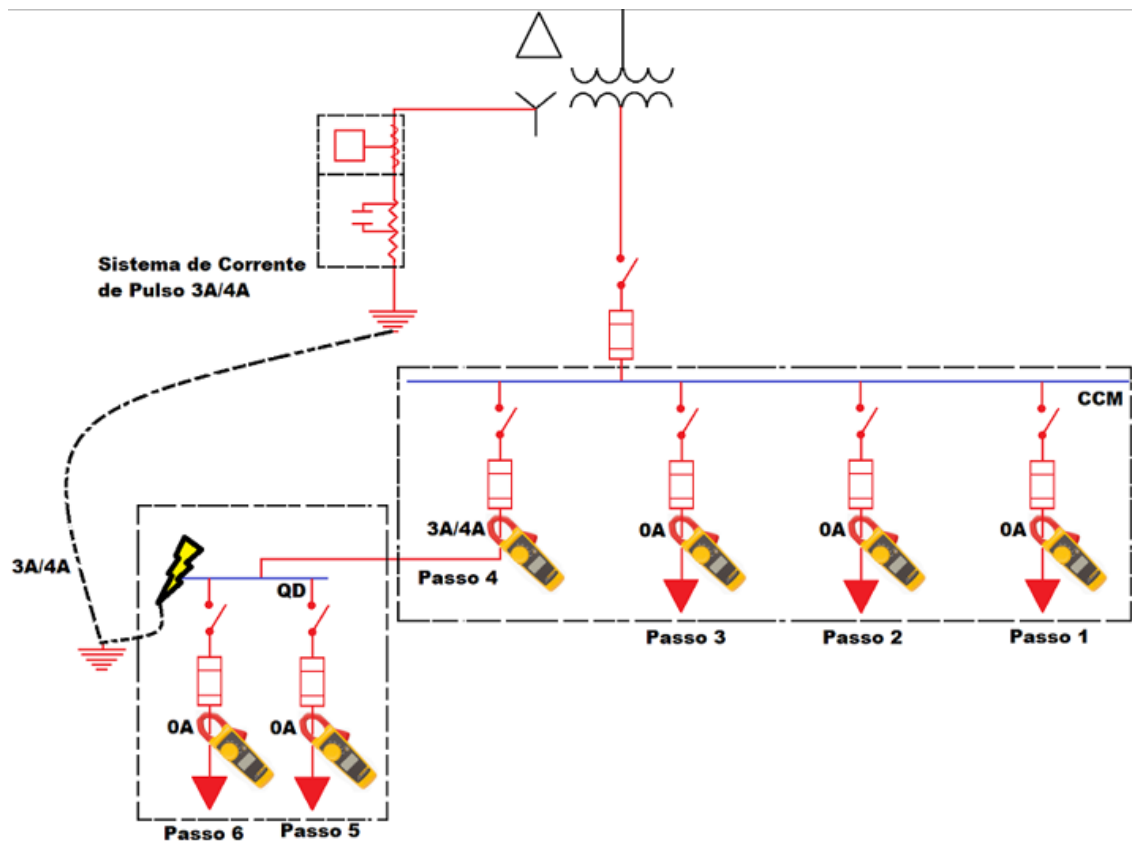
O desenvolvimento de métodos para detecção de faltas em sistemas elétricos industriais utilizando análise de sinais de variáveis elétricas tem sido objeto de pesquisa ao longo das últimas décadas. Devido às peculiaridades de projeto sistemas elétricos que não são aterrados, ou que são aterrados por resistência de alto valor têm apresentado particular interesse dos pesquisadores. Tal interesse se deve ao fato de, dependendo da magnitude da falta, tais sistemas podem operar indefinidamente sob a condição de falta à terra, desde que essa envolva apenas uma das fases. Contudo, a falta deve ser identificada e isolada de forma a evitar a sua propagação pelos outros componentes do sistema, e a sua evolução para condições mais severas, o que, inevitavelmente, provocaria a interrupção do processo produtivo. O aumento da confiabilidade dos sistemas elétricos, e a manutenção da continuidade da produção com a implantação de sistemas de diagnóstico de falhas, confere uma grande vantagem competitiva às indústrias. Falhas e desligamento extemporâneos de sistemas elétricos que alimentam processos críticos, resulta em perda de produção, materiais e equipamentos (NELSON; SEN, 1999). Diversas estratégias para projeto de sistemas robustos de proteção contra falta à terra têm sido propostos na literatura.

O trabalho de Lubich (1997), apresenta as principais características da utilização do circuito com neutro aterrado através de resistor de alto valor, bem como uma técnica para detecção de ponto com fuga de corrente. Segundo o autor, um requisito importante para a instalação desse tipo de sistema de aterramento é a determinação das correntes de carregamento que existem no circuito, em função da capacitância intrínseca da instalação. Para determinar a corrente de carregamento capacitivo, é necessário conhecer a tensão de linha do circuito e a capacitância entre a linha e a terra (capacitâncias totais das fases A, B, e C). Com a utilização desses dados calcula-se, na sequência a impedância, a corrente de carregamento por fase e a corrente média total. Após a determinação desses parâmetros, determina-se o valor do resistor de aterramento adequado ao sistema de detecção de falta à terra.

A solução para a detecção do ponto de ocorrência da fuga, consiste em um módulo que injeta um sinal de corrente pulsante com valor entre 3 A a 4 A no ponto de aterramento, como pode ser visto na Figura 1. A corrente injetada é superior a corrente capacitiva do circuito, e circulará, para à terra, pelo caminho da fase que está com baixa isolação. Para a identificação do circuito com falta à terra, a corrente de todas as cargas conectadas ao barramento deverão ser medidas, e a carga com falta à terra será identificada quando a corrente medida for igual ao valor da corrente injetada.

Os autores em Baldwin, Renovich e Saunders (2003) apresentam um algoritmo para detecção de falta à terra em sistemas aterrados por resistor de alto valor em instalações de baixa tensão.

Figura 1 – Esquema de medição de corrente de fuga com sistema de pulso.

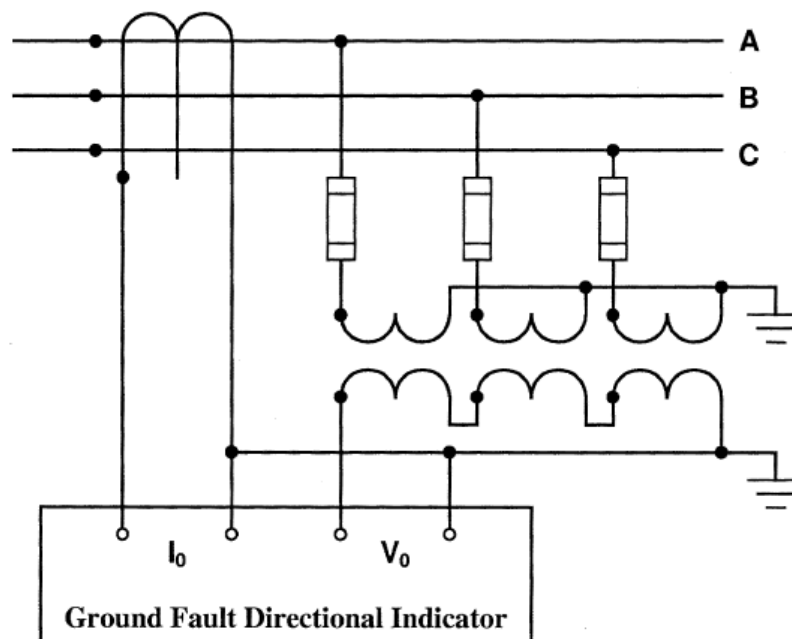


Fonte: Adaptado de Costa (2014)

O sistema, que se baseia na detecção da direção da falta em função das variações dos fasores de tensão e corrente do circuito, é constituído por quatro estágios principais: detecção de falta, filtragem da polarização, estimativa de fasor e cálculo do ângulo de fase com estimativa de direção. A medição dos sinais é realizada com o uso de um transformador de corrente residual e um transformador de potencial com conexão secundária "delta aberto", conforme ilustrado na Figura 2.

Quando ocorre uma fuga à terra, são geradas tensões e correntes de sequência zero que são detectadas pelo conjunto. Em seguida, é aplicada a transformada rápida de Fourier para encontrar os fasores dos sinais de tensão e corrente, e a partir desses, determina-se o ângulo da impedância, que é a diferença angular entre os fasores de tensão e corrente. Essas informações alimentam um sistema microprocessado embarcado que faz a estimativa da direção da falta. De acordo com os autores, a acurácia do sistema embarcado é em média 60% para correntes de falta à terra na faixa de 10 mA e 20 mA, e de 100% para correntes de fuga superiores a 20 mA. O trabalho publicado por Cai et al. (2014) propõe uma técnica para detecção de falta à terra em redes de distribuição elétrica, baseado nas correntes de sequência zero. O procedimento consiste na medição das correntes de fase, e no cálculo das correntes de sequência zero com a utilização de computadores. De acordo com o algoritmo proposto, se os valores das correntes de sequência zero forem baixos, não há faltas de fuga à terra no sistema, caso contrário, existe fuga à terra em algum ponto do sistema em questão.

Figura 2 – Esquema de conexão para o indicador de falha direcional, fornecendo uma corrente e tensão de sequência zero.




Fonte: Baldwin Renovich e Saunders (2003)

Para a identificação do nó da rede onde ocorreu a falha utiliza-se o ângulo do componente de corrente de sequência zero. Os autores mencionam que para sistemas onde a impedância de falta é inferior a $1 \text{ k}\Omega$ o método proposto é altamente eficaz, com acurácia em torno de 100%.

Em Topolanek et al. (2015) é apresentada uma técnica para detecção de falta à terra baseada em medição de tensão. Esta aplicação é desenvolvida especialmente para sistemas de distribuição compensados, equipados com conexão automática de curta duração de um resistor auxiliar para aumentar o componente ativo da corrente de falta à terra. Esse procedimento é normalmente utilizado em redes de distribuição europeias para melhorar a sensibilidade da proteção contra falta à terra direcional. O método consiste na avaliação das quedas de tensão causadas pela conexão de um resistor auxiliar na condição de falta à terra, registradas por um sistema de medição instalado no lado de baixa tensão dos transformadores abaixadores de 22 kV para 0.4 kV . A Figura 3, apresenta o esquema utilizado para a localização da falta. Os DTS's são as estações de medição de tensão secundária em cada ramal. Após a ocorrência da falta de fuga à terra, os diagramas de tensão em todas as linhas são analisados, e as possíveis áreas do sistema em que ocorreu a falha são delimitadas pela análise das quedas de tensão. De acordo com os autores, o método se mostrou eficiente para faltas sólidas ou de baixa impedância, não sendo garantido seu funcionamento no caso de faltas de alta impedância. Os autores consideram faltas de alta impedância, aquelas com resistências superiores a $800 \text{ k}\Omega$.

O trabalho de Valdes, Papallo e Premerlani (2006) propõe uma técnica para detecção de falta à terra em sistemas aterrados por alta resistência.

Figura 3 – Princípio de operação do sistema de localização de falta a terra por medição de queda de tensão.



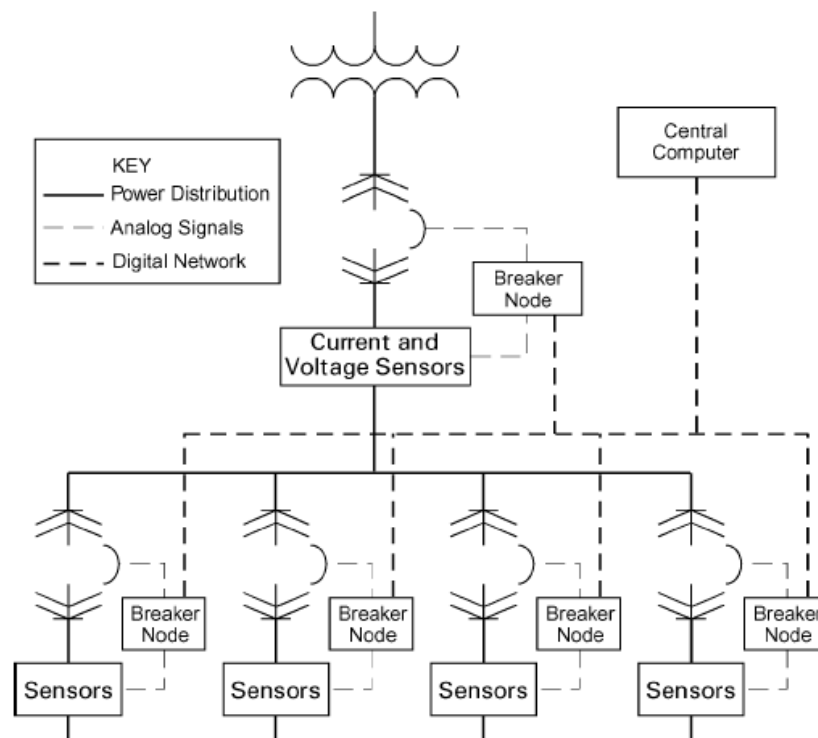
Fonte: Topolanek et al. (2015)

Na proposição dos autores, um sinal externo da ordem de 4 a 8 A, 600 Hz é injetado no circuito do resistor de aterramento. Sensores de corrente são instalados nos ramais, e as informações sobre o comportamento das correntes são enviadas a um computador central. Quando ocorre uma falta à terra, o computador identifica o caminho da corrente injetada no circuito e indica com relativa precisão o ponto de ocorrência. A Figura 4 apresenta a topologia proposta pelos autores. De acordo com os autores, comparativamente às demais técnicas existentes, o método proposto é um dos mais economicamente viáveis.

A utilização da transformada *wavelet* (TW) tem se mostrado uma opção viável para a implementação de sistemas de diagnósticos de falha nos casos em que os processos podem ser representados por sinais ao longo do tempo. De fato, a utilização da transformada *wavelet* no processamento dos sinais extraídos do processo pode ressaltar informações relevantes que resultam na melhora do desempenho dos modelos (ABDESH; KHAN; RAHMAN, 2008). Notadamente a TW tem sido aplicada com sucesso no diagnóstico de falhas em motores elétricos industriais, a partir da análise de sinais de vibração, corrente, temperatura, entre outros. Trabalhos têm sido propostos sobre a utilização da TW na detecção de faltas em sistemas elétricos.

Uma metodologia para a localização de faltas em sistemas elétricos é apresentada no trabalho de Magnago e Abur (1999). Os autores utilizaram a TW para extrair informações relevantes das componentes de alta frequência do sinal de falta. Componentes de alta frequência são intrínsecos de transitórios na ocorrência de faltas elétricas. Baseado nas intensidades dos sinais de frequência, o local da falha pode ser identificado. O procedimento proposto consiste na divisão dos sinais transitórios em suas componentes modais, seguido pela decomposição com a utilização da transformada *wavelet*, o que resulta na obtenção dos coeficientes *wavelet* correspondentes que são utilizados para a estimação da distância da falha.

Figura 4 – Topologia de controle centralizada para detecção de falta a terra com injeção de corrente externa.



Fonte: Valdes, Papallo e Premerlani (2006)

De acordo com os autores, as faltas monofásicas apresentam sinais de pequena amplitude, mas que podem ser identificadas devido a singularidade de seu comportamento quando se utiliza a transformada *wavelet*. Neste trabalho não foram informados os níveis de decomposição do sinal, nem o o filtro *wavelet* utilizado.

Uma Pesquisa sobre detecção de correntes de falta à terra em sistemas de aterramento de alta impedância foi apresentada no trabalho de Samanfar e Mahamedi (2010). Os autores utilizaram um método baseado na utilização da TW em conjunto com a medição de tensão e corrente de sequência zero. A identificação da ocorrência da falta se dá pela análise dos coeficientes *wavelet* extraídos no período transitório do sinal de falta. Por sua vez, as componentes de sequência zero de tensão e corrente são utilizadas para distinguir a direção da falta, baseado na diferença entre os ângulos das correntes e tensões. Para a decomposição dos sinais de falta, os autores reportam a utilização do filtro *wavelet Db4* no primeiro nível de decomposição. Os autores apresentaram como vantagens da utilização do método proposto sua robustez a desbalanceamento entre fases sob condições normais das variáveis elétricas de tensão e corrente, e a alta sensibilidade para identificação de faltas em alta impedância.

Uma abordagem sobre o monitoramento das condições de funcionamento de motores de indução utilizando transformada *wavelet packet* e redes neurais artificiais foi proposta em Silva (2017). O procedimento consistiu na aquisição de sinais de corrente de motores em diversas condições de funcionamento, dos quais foram extraídas medidas estatísticas representativas das condições de

falta as quais os motores foram submetidos. Para a implementação do sistema, foram simuladas faltas de barras rompidas no rotor gaiola de esquilo, faltas nos rolamentos nas pistas internas e externas e faltas para a terra em pontos do enrolamento do motor. Foram utilizados 10 medidas estatísticas, entre elas curtose, RMS, assimetria, centroide, média e desvio padrão. Os melhores resultados, 92% de acurácia para as falhas elétricas e 93% para falhas mecânicas, foram obtidos com a utilização de uma rede *perceptron* com quatro camadas ocultas, cada uma contendo dez neurônios.

Sinais de corrente são, de fato, fontes de informação importantes para diagnósticos das condições de máquinas elétricas. Os autores em Widodo et al. (2009) utilizaram a transformada *wavelet* para investigar falhas de desbalanceamento de fases em circuitos de motores elétricos de indução, através da análise dos sinais de corrente. Os sinais foram adquiridos em uma bancada experimental, e para a simulação da falta de desbalanceamento, foi utilizada uma carga resistiva em série em uma das fases do circuito do motor. Os sinais de falta foram decompostos com a utilização do filtro *wavelet* da família *Daubechies*, *Db5*, no primeiro nível de decomposição. Para a classificação, foram extraídas dos sinais as medidas estatísticas, média, raiz média quadrada e fator de forma, e os modelos foram implementados pelo algoritmo *Support Vector Machine* (SVM) utilizando o *kernel radial basis function* (RBF). De acordo com os autores, as acurácias nas fases de treino e teste, foram respectivamente, 100% e 83,33%.

No trabalho de Guo et al. (2020) é proposto um método de localização da seção com falha à terra em redes de distribuição de média tensão com aterramento ressonante, utilizando uma rede neural convolucional 1-D (RNC 1-D) associada a concatenação da forma de onda de corrente registrada nos eventos. Depois que a falha à terra ocorre, um sistema de monitoramento eletrônico armazena as correntes transientes de sequência zero nas extremidades da linha dupla e estas são concatenadas para construir a forma de onda característica. As características das formas de onda são extraídas e classificadas adaptativamente por uma RNC 1-D para localizar a seção de falha. Os autores relatam que o problema em que os dados registrados no local são difíceis de coletar é resolvido pois a RNC 1-D só precisa de um pequeno número de amostras para treinamento em aplicações práticas. Os resultados experimentais verificaram que o método proposto pode funcionar efetivamente sob várias condições de falha, mesmo que alguns ramais de medição estejam fora de serviço. Neste trabalho é realizada uma comparação na etapa de classificação utilizando máquina de vetores de suporte e uma RNC em 2-D. Os resultados de acurácia apresentados (RNC 1-D - 95,68%, RNC 2-D - 81,25% e SVM 82,81%) indicam que a rede neural convolucional unidimensional possui melhor capacidade de classificação dos sinais de corrente de sequência zero para este sistema.

Lang (2019) propõe um método de identificação de linha de distribuição em média tensão com falha monofásica (fase-terra) baseado em rede neural convolucional (RNC) constituída por 4 camadas. No trabalho é utilizado um registrador para medição onde são extraídas a tensão de sequência negativa e os fasores de corrente em ambas as extremidades da linha de falha, e

o princípio de localização de falha de terminal duplo é aplicado à localização de falha de alta precisão. Os resultados da simulação do Simulink mostram que o método proposto pode realizar a seleção da linha e a localização precisa da falta à terra monofásica na rede de distribuição sem ser afetado pela frequência do sistema, ponto da localização da falta, resistência de transição ou outros fatores. Em todas as configurações testadas, os erros apresentados foram inferiores a 0,03%.

Não foram encontrados na literatura trabalhos que apresentam ferramentas de classificação dos sinais em sistemas elétricos de baixa tensão, sem a utilização de um sinal externo para a identificação de cargas com falha de fuga à terra em sistemas aterrados por resistor de alto valor ôhmico em baixa tensão. Este trabalho se distingue dos demais disponíveis na literatura, pois se baseia na aquisição e análise direta dos sinais medidos nos equipamentos para localização de pontos com fuga à terra, sem a necessidade de realizar alterações significativas no sistema elétrico. A abordagem proposta contorna os problemas oriundos de modificações de projetos originais e minimiza os custos de implantação de sistemas inteligentes de localização de faltas. A aplicação de uma ferramenta de diagnóstico sem intervenção ou interrupção dos equipamentos reduz a exposição de pessoas aos riscos inerentes às instalações elétricas, aspecto fundamental para a segurança nas instalações industriais. Os trabalhos citados necessitam alterar o projeto dos locais onde serão aplicados para introduzir elementos de medição, diferente do que é abordado neste estudo em que utiliza-se somente alicates de medição de corrente de forma indireta, sem realizar desconexão e parada dos equipamentos analisados.

3 ANÁLISE TÉCNICAS DE SISTEMAS DE ATERRAMENTO E PROTEÇÃO

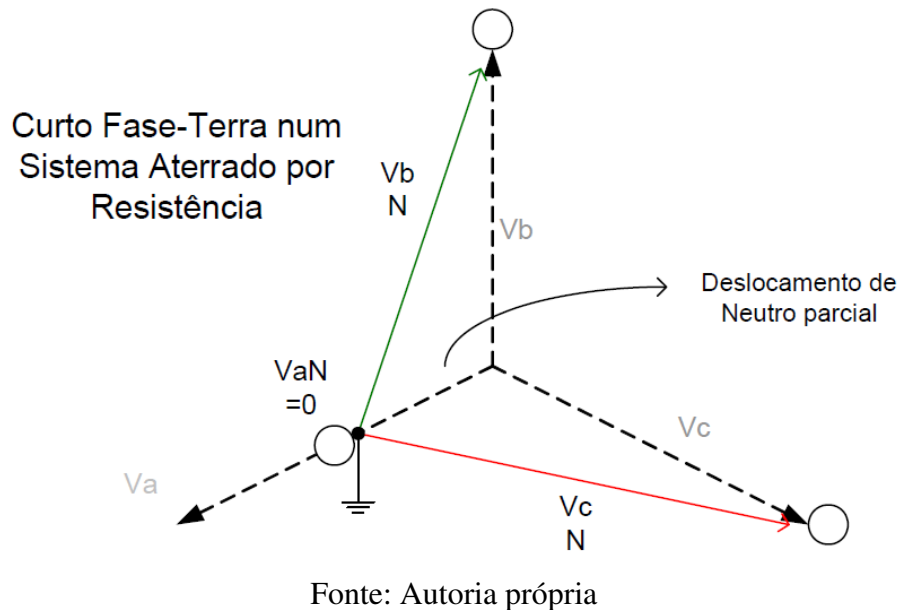
Esse capítulo apresenta uma abordagem teórica do tipo de aterramento das instalações elétricas industriais utilizado neste trabalho, faz uma descrição dos sistemas para detecção de falta à terra em instalações com aterramento de neutro por resistor de alto valor, e faz uma breve discussão sobre os problemas causados pela circulação de correntes de fuga à terra em instalações elétricas industriais. Outros tipos de aterramentos são apresentados no Anexo A.

3.1 SISTEMAS ATERRADOS POR RESISTOR DE ALTO VALOR

Construtivamente, os sistemas aterrados por resistor de alto e baixo valor são iguais, a diferença está no valor resistivo do elemento de interligação do neutro ao terra. Para ser considerado um sistema com aterramento por resistor de alto valor (RAV) ou “HGR” (*High Grounding Resistance*) o mesmo deve limitar as correntes de falta à terra entre 1A e 10A (BLACKBURN; DOMIN, 2015). Valores de corrente de fuga à terra nessa faixa são vantajosos, pois reduzem a probabilidade de danos nas instalações elétricas devido à baixa intensidade da corrente de curto-circuito. Uma grande vantagem deste sistema é a capacidade de operar de forma ininterrupta em condição permanente de falta fase-terra, por este motivo é muito comum em sistemas de baixa tensão industrial. Quando ocorrem falhas monofásicas, há um deslocamento do neutro conforme apresentado na Figura 5, onde o potencial da fase em curto-circuito será igual ao potencial do terra, mas deslocado ao ponto de neutro do sistema elétrico.

As correntes de falta fase-terra são de baixa intensidade em função da limitação imposta pelo RAV. Contudo, caso ocorra falha de outra fase para a terra, haverá um curto-circuito bifásico de alta intensidade pela conexão de duas fases do sistema em um mesmo ponto. Como consequência, poderá haver a ocorrência de arcos elétricos e a destruição de componentes (COSTA, 2014). Essa condição poderá levar a parada do sistema como um todo em função da atuação das proteções elétricas e pela impossibilidade da limitação das correntes de curto-circuito pelo RAV. Outra limitação desse sistema é a dificuldade para a identificação de ramais com falta à terra, em função da pequena intensidade da corrente de falta, que pode ser confundida com correntes provocadas pelo desbalanceamento de fases, por transitórios, distúrbios elétricos e correntes parasitas que possam ocorrer no sistema. Em seu trabalho, Paul (2020) apresenta uma visão geral do comportamento de sistemas com neutro aterrado por resistor de alto valor, em condição de fuga à terra. A Figura 6 mostra o fluxo da corrente de falta na fase C. Uma das características desses circuitos, é a circulação de uma corrente parasita produzida pelo efeito capacitivo do cabos isolados e demais circuitos associados. Esta corrente parasita capacitiva (I_{CF}) flui, simultaneamente, com a corrente resistiva da falta (I_{HRG}), e isto pode ser um problema para a sua detecção pelos métodos convencionais de identificação.

Figura 5 – Deslocamento parcial do neutro em sistema aterrado por resistência.



3.1.1 Principais vantagens e desvantagens da utilização dos resistores de alto valor

Em seu trabalho, Costa (2014) cita como principais vantagens da utilização de resistores de alto valor no aterramento do neutro:

- Redução de danos por queima nos equipamentos elétricos (painéis, transformadores, cabos e máquinas elétricas rotativas);
- Redução de estresses mecânicos dos condutores no momento da falta;
- Diminuição do risco de choque elétrico causado por correntes de falta à terra;
- Controle de sobretensões transitórias;
- Baixa intensidade das correntes provenientes de curtos fase-terra a valores, que de forma geral, não danificam nem causam estresses no sistema elétrico;
- Redução significativa da possibilidade da ocorrência de choques elétricos com consequências mais sérias, devido aos baixos valores das correntes fase-terra;
- A não formação de arcos na ocorrência de curtos fase-terra, evitando danos à pessoas e equipamentos;
- Redução significativa da ocorrência de sobretensões no sistema, o que aumenta a vida útil dos componentes elétricos;
- A continuidade operacional mesmo em condição de falta fase-terra;

- Alto custo para implementação de soluções visando a identificação de falhas pontuais (relés de proteção com módulos de detecção de falta a terra devem ser instalados nos ramais individuais de cada equipamento);
- Os equipamentos devem ser melhor isolados entre fases do que entre fase-terra;
- O aumento da tensão das duas fases sem falta quando da ocorrência de uma falta à terra;
- Não permite alimentação de cargas monofásicas;
- Atuação indevida de sistemas de localização de falhas por meio de dispositivos com *ground sensor*.

Além de proporcionar maior segurança para os equipamentos e para o pessoal, a capacidade da continuidade da operação do sistema, mesma na ocorrência de uma falha, é um fator relevante a ser considerado pelas indústrias para a escolha desse tipo de sistema de aterramento quando do projeto de suas instalações.

3.2 SISTEMAS PARA DETECÇÃO DE FALTA À TERRA EM INSTALAÇÕES COM ATERRAMENTO DO NEUTRO POR RAV

A proteção de fuga à terra que também é conhecida como "fuga de corrente", definida pelos números 50G e 51G (sobrecorrente instantânea e temporizada) (IEEE, 2008), é sensibilizada pela corrente que circula nos condutores de terra, na condição de redução da isolação de cabos elétricos, barramentos, motores, geradores, etc. Esta condição pode ser originada por temperatura elevada, presença de umidade, contaminação com materiais condutivos, presença de animais ou ataques químicos. Danos físicos a isolação também podem ocorrer em função de uma ação indevida por erro humano, problemas durante a montagem ou esforços decorrentes de sobretensão de regime ou transitórios (MARDEGAN, 2012). Essa corrente, mesmo que pequena, pode por em risco a vida de pessoas expostas a estas instalações, o que traz a necessidade de localização imediata da falha para as devidas tratativas.


Uma das formas de identificar fuga de corrente utiliza uma medição indireta de desequilíbrio, que é feita através de um transformador de corrente do tipo janela ou toroidal, envolvendo as três fases. Alguns modelos de transformadores de corrente (TC) tipo janela são apresentados na Figura 7. A Figura 8 apresenta o esquema de ligação deste tipo de sistema. Uma vez que haja uma fuga de corrente para a terra, o desequilíbrio do campo magnético trifásico faz surgir uma componente de sequência zero que faz circular uma corrente proporcional no sensor TC que é detectada pelo relé de proteção. Este tipo de proteção é muito utilizado em sistemas de baixa tensão com uso de relés inteligentes microprocessados e pode ser bastante sensível, levando assim a necessidade de ter cuidado na implantação para evitar abertura indevida do circuito por correntes que não possuem relação com a falta à terra.

Figura 7 – Modelos de transformadores de corrente tipo janela.



Fonte: Ward (2020)

Figura 8 – Esquema de ligação do sistema de detecção de falta a terra tipo ground sensor.

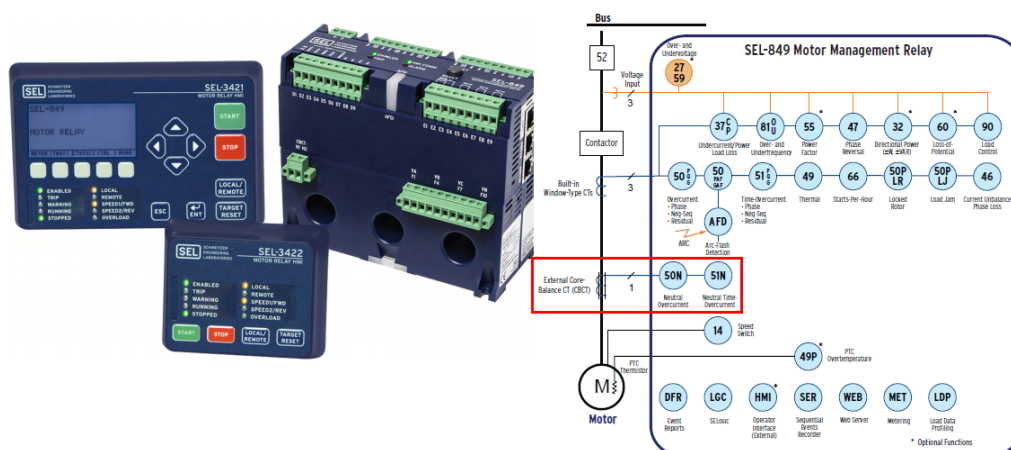


Fonte: Autoria Própria

Fabricantes renomados no mercado, como a Siemens AG e a Schweitzer Engineering Laboratories (SEL) utilizam relés de proteção para equipamentos de baixa tensão baseados neste princípio de medição de corrente de falta à terra com TC. Na Figura 9 é apresentado o modelo de relé do fabricante SEL e o diagrama funcional do mesmo.

Outro método para detecção de falta à terra é por meio da medição direta das correntes das fases de alimentação. Nesse caso, a fuga de corrente é detectada pela realização da somatória fasorial das correntes individuais das fases. A Figura 10 apresenta o esquema deste tipo de aplicação. Quando em condição normal, a corrente circulante no fechamento dos transformadores de corrente é nula mas na condição de falha, circulará uma corrente proporcional à corrente de fuga à terra.

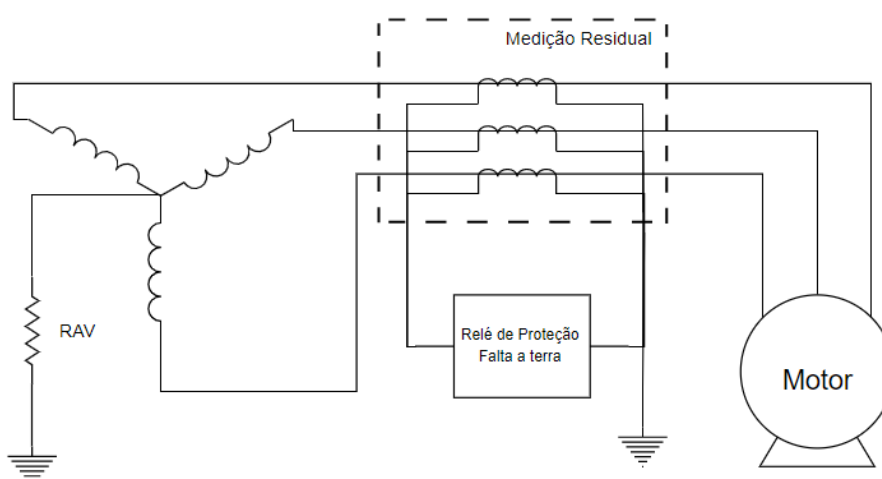
Figura 9 – Relé de proteção SEL-849 para proteção de motores de baixa tensão.



Fonte: Schweitzer (2020)

Este tipo de solução é mais utilizado em sistemas de média tensão, com pouca utilização em sistemas de baixa tensão (EL-SHERIF, 2017).

Figura 10 – Esquema de ligação do sistema de detecção de falta a terra tipo residual.



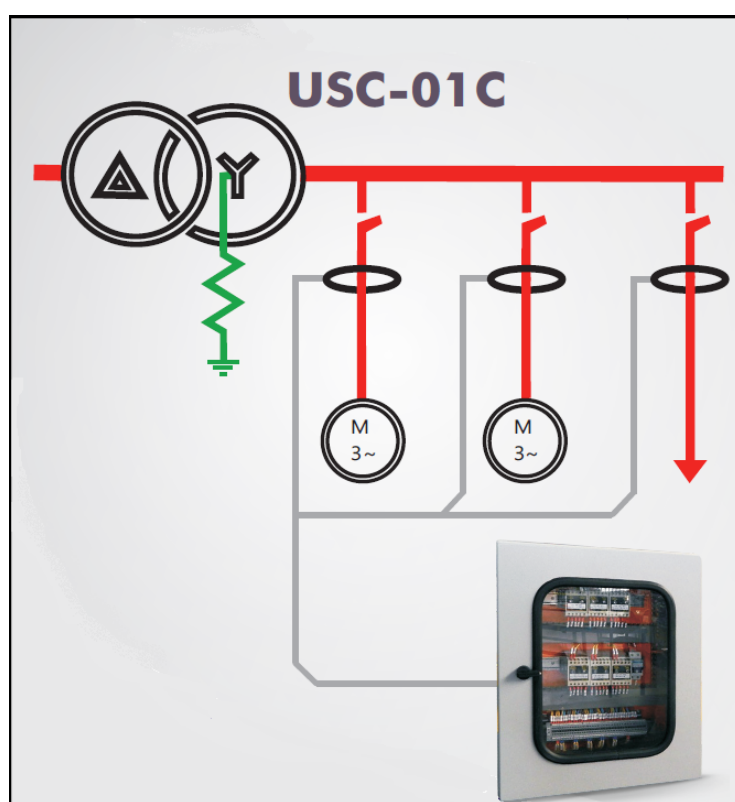
Fonte: Autoria Própria

Tanto o método de medição de corrente por *ground sensor*, quanto o método de medição residual possuem a característica de serem ativadas pela intensidade do sinal de falta à terra, dessa forma, essas técnicas podem não ser eficazes quando da ocorrência de desequilíbrios entre fases que possam causar desligamentos. Esse problema pode ser potencializado em sistemas com neutro aterrado por RAV, pois as correntes de fuga são pequenas, e podem levar os ajustes dos relés a ficarem pouco seletivos. Outro fator importante é que instalações antigas que não foram equipadas com esse tipo de proteção em sua concepção, devem passar por uma grande reforma para a implantação dos mesmos, o que implica em alto investimento para aplicação em muitos equipamentos, como é o caso das instalações industriais.

No Brasil a Senior Engenharia (2020) comercializa um sistema de identificação e localização *on-line* do local da ocorrência de uma falta fase-terra em sistemas com limitação

de corrente por resistores de alto valor ôhmico. O sistema, similar ao proposto pelos autores em Valdez, Papallo e Premerlani (2006), se baseia em um dispositivo de pesquisa *on-line* (similar a um relé de terra) chamado de USC, que indica em que ponto ocorreu a falta fase-terra nos sistemas elétricos de BT aterrados com RAV. Segundo a empresa, esta solução, além de facilitar a identificação do ponto, está de acordo com os pilares de segurança pessoal recomendados pela NR 10. Na Figura 11 é apresentado o produto da empresa em forma de diagrama simplificado. A técnica consiste em injetar um sinal com características distintas da rede para que uma central que recebe a informação de corrente residual de cada uma das cargas, identifique o ponto com falha.

Figura 11 – USC – Dispositivo para pesquisar o circuito em falta para à terra.



Fonte: Senior Engenharia (2020)

Nas instalações que possuem RAV aterrando o neutro, e não dispõem de nenhum dos sistemas supracitados, a localização de uma carga com falta à terra em meio a diversas outras é uma atividade trabalhosa e que muitas vezes pode não ser assertiva. Basicamente, a identificação, nestes casos, é realizada através de uma busca exaustiva da carga com falha, com o desligamento de cada carga individualmente até a identificação do alimentador que está em falha. Outra forma, pode ser a medição manual da corrente em cada alimentador, com a utilização de alicate amperímetro. Na primeira solução, o problema pode ser a impossibilidade do desligamento de equipamentos na linha de produção em condição normal de funcionamento da planta. No outro caso, além de colocar em risco as pessoas que estão interagindo com o sistema, a chance de errar e não encontrar o ponto em falha é grande, pois a corrente de fuga pode ser tão pequena

que não seja possível separá-la das correntes de carregamento capacitivas normais do sistema. A proposta abordada neste trabalho é de baixo custo e com valores significativos de assertividade. Para efeito de comparação, um relé de proteção da Schweitzer (2020) que é uma empresa especializada em proteção elétrica e consolidada no mercado, possui valor apresentado na Figura 12.

Figura 12 – Valor de um relé de proteção com módulo de detecção de falta à terra.

SEL-849 Motor Management Relay
Product Page | All Products Page

Configuration Summary

Part Number	084900100100200	Map
Configuration Number	849#66M6	
Configured Price	\$808.00 USD	

Selected Options

Power Supply	125-250 Vdc (110-240 Vac); 50/60 Hz	+\$0.00
Voltage Inputs	None	+\$0.00
Digital Inputs	6 Standard Plus 6 Additional Internally Wetted	+\$52.00
Digital Input Voltage	24 Vdc	+\$0.00
Analog Output	1 Analog Output 4-20 mA	+\$26.00
Communications Options	EIA-232/EIA-485 Serial	+\$0.00
IEC 61850 Protocol	No	+\$0.00
DNP3 Protocol	No	+\$0.00

PART LOOKUP
849#66M6

RECONFIGURE

ACTIONS

Quantity: 1

ADD TO CART

ADD TO PROJECT

REQUEST QUOTE

VIEW CART

VIEW PROJECT

ADD TO COMPARE

PRINT

Fonte: Schweitzer (2020)

Em uma indústria idêntica ao que foi realizado o levantamento do conjunto de dados para este estudo, onde não há esta tecnologia e que possui cerca de 5000 motores elegíveis a aplicação deste relé, considerando o valor do dólar atual em relação ao real (1USD = 5,46BRL em 16/10/2021), temos um valor de R\$ 22.058.400,00 de materiais.

3.3 PROBLEMAS CAUSADOS PELA CIRCULAÇÃO DE CORRENTES DE FUGA À TERRA EM INSTALAÇÕES ELÉTRICAS

Os sistemas de potência estão constantemente sujeitos à perturbações que provocam alterações nas grandezas elétricas (tensão, frequência, potência, etc.), que podem causar sérios riscos às instalações. Neste contexto, é necessário adotar medidas preventivas para mitigar as consequências destas falhas. Os modos de falhas mais comuns são os curto-circuitos que se originam pela ruptura entre fases ou fase e terra, estabelecendo a circulação de valores elevados de corrente, capazes de causar problemas de diversas naturezas.

As fugas de corrente fase-terra ou monofásicas, são as mais comuns entre os tipos de curto-circuito. Falhas desse tipo em sistemas de aterramento do neutro por resistor de alto valor, que podem permanecer em condições operacionais mesmo em condição de falta, devem ser identificadas e tratadas, ainda em fase incipiente, para que as mesmas não evoluam para curto-circuitos bifásicos ou trifásicos, que, de forma geral podem provocar mais danos ao sistema. As

correntes de curto-circuito provocam dissipação de elevadas quantidades de calor, que danificam diversos componentes do sistema, podendo evoluir para condições mais perigosas, como por exemplo incêndios.

No momento da falta, ocorrem subtensões que podem ser prejudiciais à outros componentes do circuito, principalmente componentes eletrônicos que são sensíveis a quedas de tensão. Quedas abruptas de tensão podem também gerar sobrecargas em motores em operação e distúrbios no funcionamento de geradores que estejam em paralelo. Sobretensões transitórias também podem ocorrer, e isso pode causar danos em sistemas de isolamento das máquinas elétricas. Durante o curto-circuito, variações de frequência também podem ocorrer, provocando fadiga e redução da vida útil de máquinas elétricas.

4 REFERENCIAL TEÓRICO

Esse capítulo apresenta as técnicas e ferramentas utilizadas para a extração dos descritores, para a construção dos modelos de aprendizado de máquina e para avaliação do desempenho dos modelos.


4.1 ALGORITMOS DE CLASSIFICAÇÃO

Para a construção dos modelos de classificação foram utilizados os algoritmos *SVM*, *k-NN*, *DT*, *RF* e rede neural convolucional. A seguir está apresentada uma breve descrição com os fundamentos de cada um desses algoritmos.

4.1.1 Máquinas de Vetores de Suporte (Support Vector Machine - SVM)

SVM são modelos de classificação supervisionada, lineares e binários, que procuram o hiperplano de separação entre as classes (Figura 13), de maneira a maximizar a distância entre as amostras mais próximas (CORTES; VAPNIK, 1995). O princípio deste algoritmo supervisionado, é que o mesmo encontre os melhores hiperplanos de forma que a separação seja a máxima possível entre as classes. A aplicação do *SVM* à problemas não lineares pode ser possível com a utilização de funções *kernel*, que projetam o espaço amostral sobre espaços de maior dimensão onde os dados são linearmente separáveis. Exemplos de funções *kernel* que podem ser utilizadas são, quadrática, polinomial e gaussiana, sendo esta última a utilizada nesta pesquisa (Equação 1).

Figura 13 – Exemplo ilustrativo do algoritmo SVM.



Fonte: Autoria própria

$$k(x, x_i) = \exp\left(\frac{-\|x - x_i\|^2}{2\sigma^2}\right) \quad (1)$$

Onde $\|x - x_i\|$ representa a distância euclidiana entre os pontos x e x_i e o σ a variância e o nosso hiperparâmetro. Embora seja, em sua forma convencional, um algoritmo binário, que suporta apenas problemas com duas classes, a utilização de métodos multiclasse torna o *SVM* aplicável a problemas com mais de duas classes. Uma *SVM* multiclasse visa classificar os atributos usando máquinas de vetores de suporte, onde os rótulos de diferentes classes são desenhados a partir de um conjunto finito. A implementação da estratégia multiclasse consiste na transformação do problema de várias classes em vários problemas envolvendo apenas duas classes. Dessa forma, cada instância do problema produz um classificador binário, que pressupostamente é capaz de produzir uma função de saída que fornece valores relativamente grandes para atributos de uma classe e valores relativamente pequenos para atributos de outra (SUJATHA, 2010).

Os métodos multiclasse mais utilizados são (i) *one-vs-one* e (ii) *one-vs-all*, que estão descritos a seguir. Nesse trabalho foi utilizado o método *one-vs-one*.

- *One-vs-one*: no método um-contra-um, dadas n classes, são gerados $\frac{n(n-1)}{2}$ classificadores binários sendo que cada um deles é responsável por determinar apenas um par de classes.
- *One-vs-all*: no método um-contra-todos, dado um problema com n classes, são gerados n classificadores binários, cada um especializado na sua classe. Essa técnica pode apresentar desvantagem quando ocorre um desbalanceamento considerável do conjunto de dados (FACELI et al., 2011).

4.1.2 k Vizinho Mais Próximo (k-Nearest Neighbour - k-NN)

Classificadores implementados com base no algoritmo k-NN classificam amostras desconhecidas com base na distância entre essas e as amostras atribuídas às classes envolvidas no problema. Segundo Duda, Hart e Stork (2001), de fato a técnica basicamente consiste em um método simples de estimativa de densidade. Por ser de fácil implementação, esses classificadores são amplamente utilizados em problemas de reconhecimento de padrões.

A probabilidade de que um ponto x' caia dentro de um volume V centrado em um ponto x é dada por

$$\theta = \int_{V(x)} p(x) dx \quad (2)$$

onde a integral está relacionada ao volume V . Para um volume pequeno, consideramos

$$\theta \sim p(x)V. \quad (3)$$

A probabilidade, θ , pode ser aproximada pela proporção de amostras caindo dentro de V . Se k for o número de amostras, de um total de n , caindo dentro de V (k é uma função de x), então

$$\theta \sim \frac{k}{n} \quad (4)$$

As Equações 3 e 4 podem ser combinadas resultando em uma aproximação para a densidade, como representado pela Equação 5.

$$\hat{p}(x) = \frac{k}{nV} \quad (5)$$

A abordagem k - NN consiste em fixar a probabilidade k/n (ou, equivalentemente, um dado número de amostras n , para um k fixo) e determinar o volume V que contém k amostras centradas no ponto x (WEBB, 2003).

O k - NN pode ser utilizado tanto para problemas de classificação quanto para problemas de regressão. Para sua implementação devem ser definidos, o número de vizinhos (k), da métrica para o cálculo da distância entre as amostras e a regra de decisão para atribuição de uma classe a uma amostra desconhecida. Uma regra de decisão comumente utilizada é atribuir à amostra desconhecida a classe da maioria das k amostras mais próximas. De forma geral, os valores atribuídos a k devem ser ímpares para reduzir a possibilidade de ocorrência de empate entre classes na predição.

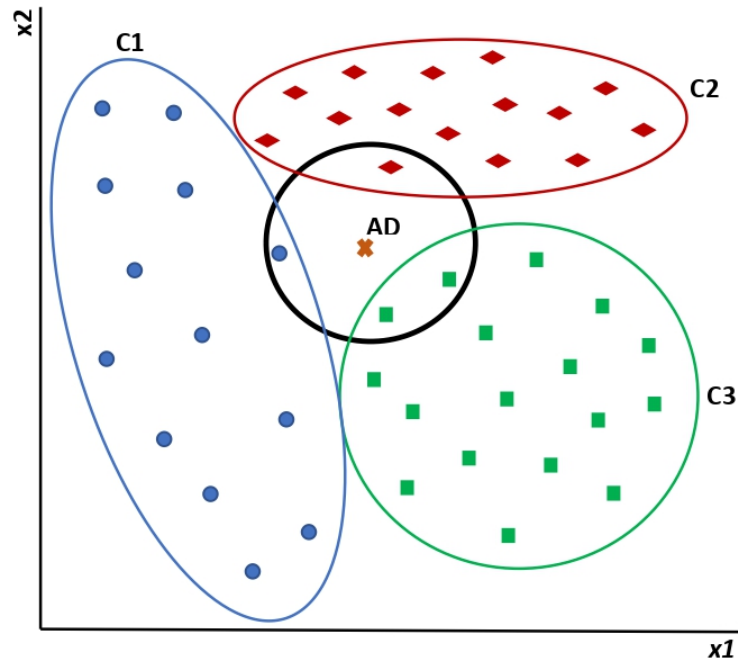
A Figura 14 apresenta uma ilustração de classificação utilizando o algoritmo k - NN em um problema de três classes. Um conjunto de dados cujos objetos pertencem à $C1$, $C2$ ou $C3$ é representado pelos descritores x_1 e x_2 . O objeto AD , cuja classe é desconhecida, será atribuído a uma das classes do problema. Com $k = 4$, AD será atribuído a $C3$, pois a maioria dos $k = 4$ objetos mais próximos de AD pertencem a $C3$.

4.1.3 Árvore de Decisão (Decision Tree - DT)

Os algoritmos de aprendizado baseados em DT têm sido amplamente utilizados em aprendizagem supervisionada, originando modelos com alta capacidade de predição, estabilidade e facilidade de interpretação. Ao contrário dos modelos lineares, DT têm a capacidade de mapear relações não-lineares na base de dados, podendo ser aplicadas a problemas de classificação ou regressão, que envolvam variáveis do tipo categóricas e contínuas.

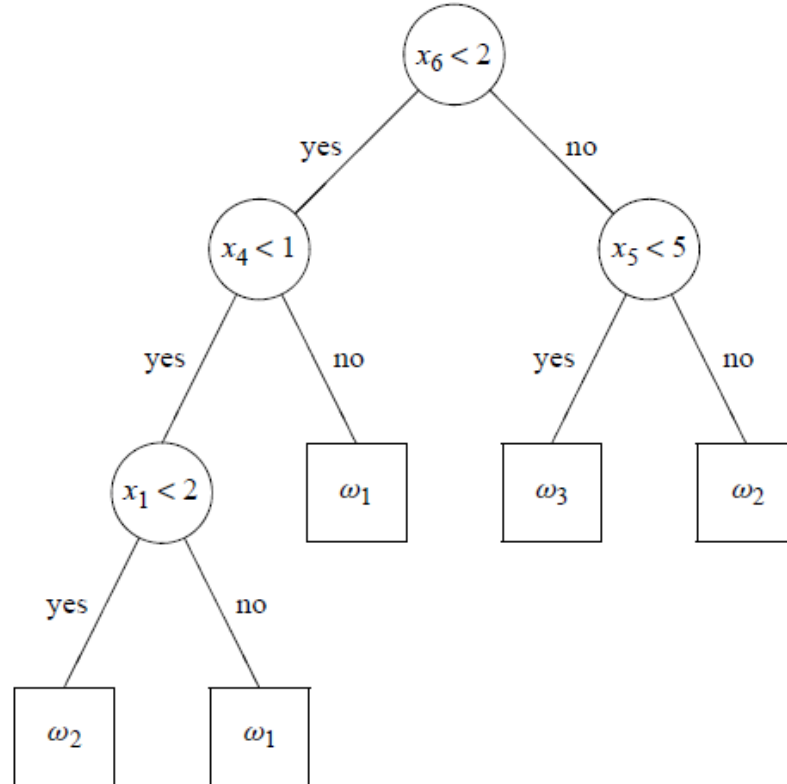
Quanto ao tipo de variável envolvida no problema as DT podem ser classificadas em DT categóricas e DT contínuas. Baseadas na estratégia de dividir para conquistar, as DT representam problemas complexos em problemas de mais simples solução, aos quais, recursivamente são aplicadas às mesmas estratégias (FACELI et al., 2011). Para a sua implementação, uma árvore de decisão é representada por um grafo.

Figura 14 – Exemplo ilustrativo do algoritmo k-NN com k=4.



Fonte: Autoria própria

Figura 15 – Exemplo ilustrativo do algoritmo *árvore de decisão*.



Fonte: Webb (2003)

A Figura 15 ilustra a estrutura de uma árvore de decisão, que é constituído pelos seguintes elementos:

- **Nó Raiz:** Representa a população inteira ou amostra, sendo ainda dividido em dois ou mais conjuntos homogêneos.
- **Divisão:** É o processo de dividir um nó em dois ou mais sub-nós.
- **Nó de Decisão:** Quando um sub-nó é dividido em sub-nós adicionais.
- **Folha ou Nó Terminal:** Os nós não divididos são chamados Folha ou Nó de Término.
- **Poda:** O processo de remover sub-nós de um nó de decisão é chamado poda. Podemos dizer que é o processo oposto ao de divisão.
- **Ramificação/Sub-Árvore:** Uma sub-seção da árvore inteira é chamada de ramificação ou sub-árvore.
- **Nó pai e nó filho:** Um nó que é dividido em sub-nós é chamado de nó pai. Os sub-nós são os nós filhos do nó pai.

Quando aplicada à problemas de classificação, cada região no espaço amostral é representado por um nó, e através do particionamento recursivo do espaço, novos nós podem ser gerados (nós filhos). Desta forma, cada percurso na árvore, da raiz à folha, corresponde a uma regra de classificação. A construção de modelos baseados em *DT* requer a configuração do número mínimo de amostras para a divisão de um nó, profundidade máxima da árvore, número máximo de nós folha e o número máximo de atributos que devem ser considerados para uma divisão. O processo de recursão para a busca na árvore é repetido até que um critério de parada seja alcançado. Além disso, a implementação de uma árvore de decisão requer a definição de uma regra de divisão, e de um critério de parada, que pode ser, por exemplo, o número máximo de divisões da árvore.

Como vantagens da utilização da árvore de decisão em relação a outros algoritmos de aprendizado de máquina, pode ser mencionadas: (i) Facilidade para interpretação dos resultados: A visualização de uma árvore de decisão simplifica a compreensão do problema, dispensando conhecimentos estatísticos para ler e interpretar. Sua representação gráfica é intuitiva e permite relacionar as hipóteses também facilmente. (ii) Útil em exploração de dados: A árvore de decisão têm se mostrado eficiente para identificar as variáveis mais significativas em problemas de classificação e regressão e a relação entre duas ou mais variáveis. Dessa forma, têm sido usadas como base de técnicas de seleção de variáveis. (iii) São mais robustas a presença de *outliers* e de *missing datas* (valores desconhecidos) na base de dados. (iv) Pelo fato de ser um método não paramétrico não pressupõe a distribuição do espaço amostral.

Um dos aspectos que influencia o desempenho das *DT* é a divisão dos nós. A divisão aumenta a homogeneidade dos nós resultantes. Na terminologia de árvore de decisão, diz-se que a pureza do nó aumenta em relação à variável alvo. A árvore de decisão divide os nós em todas as variáveis disponíveis e seleciona a divisão que resulta em nós mais homogêneos. Entre os critérios mais comumente adotados para a divisão dos nós de *DT* estão, o Índice Gini e a Entropia. O Índice

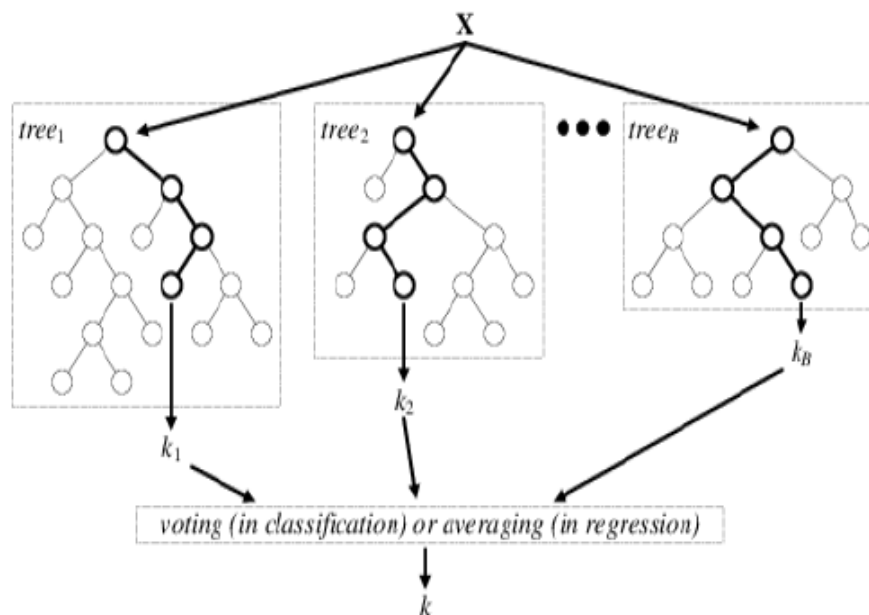
Gini mede a pureza de uma população resultante da divisão de um nó. Quanto maior o valor do Índice Gini, maior a homogeneidade dos elementos das novas populações, isto é, a maior parte dos elementos da população resultante de uma divisão pertencem a mesma classe. O Índice Gini será igual a 1 se todos os elementos de uma população pertencerem a uma mesma classe, nesse caso diz-se que a população é pura.

O ganho de informação está associado à *entropia*, ou seja, mede a aleatoriedade do atributo alvo (FACELI et al., 2011). Se a população for totalmente homogênea, logo a entropia é zero. Se a amostra for dividida em partes iguais (50% – 50%), a entropia será um. Aplicada como critério de divisão dos nós em *DT*, considera-se que quanto mais puro um nó, menor é a aleatoriedade de sua população. Assim, em cada nó de decisão, o atributo que mais reduz a aleatoriedade da variável alvo será escolhido para dividir os dados.

4.1.4 Floresta Aleatória (Random Forest - RF)

Floresta aleatória é um conjunto de árvores de decisão implementado por meio do *Bagging*. O *Bagging* combina diversos classificadores fracos, modelados a partir de diferentes sub-conjuntos do mesmo conjunto de dados. Para obter um classificador forte, ele faz um sorteio de todas as amostras; escolhe uma e, depois, faz outro sorteio e escolhe a segunda; e, dessa forma, ele segue sorteando todas as amostras. Dessas, algumas podem vir repetidas, uma vez que é usado o bootstrapping para fazer repetições. Assim ele forma o conjunto de dados que forma a primeira árvore de decisão. A segunda árvore é construída da mesma maneira através de um novo sorteio com a mesma quantidade de amostras. Para cada estimador, ele faz uma árvore diferente, porque ele trabalha com conjuntos de dados diferentes. Os modelos obtidos com a utilização do *Bagging*, geralmente, possuem menor variância, além de melhorarem a acurácia e de serem mais estáveis, comparativamente aos modelos individuais combinados. Em uma *RF*, cada árvore é responsável por um voto para a classe. A mais votada será atribuída a amostra desconhecida. O erro de uma *RF* converge para um limite à medida em que se aumenta o número de árvores na floresta (BREIMAN, 2001).

A Figura 16 mostra a estrutura de um modelo de *RF*. Para a sua implementação consideremos N o número de amostras no conjunto de treino e vamos constituir, aleatoriamente, mas com substituição, subconjuntos a partir do conjunto de treino. Os subconjuntos serão utilizados para a indução das árvores que formarão a floresta. Se as amostras tiverem M variáveis, define-se um número $m < M$ de variáveis para serem selecionadas aleatoriamente em cada nó. A melhor divisão nestes subconjuntos de m variáveis será usada para dividir o nó, de acordo com o critério de divisão adotado. O valor de m é mantido constante enquanto novas árvores são acrescentadas à floresta. A predição de uma nova classe será feita por votação de todas as árvores da floresta. A classe entre todas as possíveis que será atribuída à amostra desconhecida, será a que obtiver maior número de votos entre todas as árvores.

Figura 16 – Exemplo ilustrativo do algoritmo *Random Forest*.

Fonte: Adaptado de Suparwito (2019)

Entre as vantagens da RF comparada aos demais algoritmos pode-se destacar, sua capacidade para tratar problemas de classificação e regressão, e a facilidade para manejar grandes volumes de dados em muitas dimensões, podendo identificar as mais significativas. Uma das desvantagens é sua limitação para tratar variáveis contínuas, o que resulta em desempenhos apenas razoáveis em problemas de regressão.

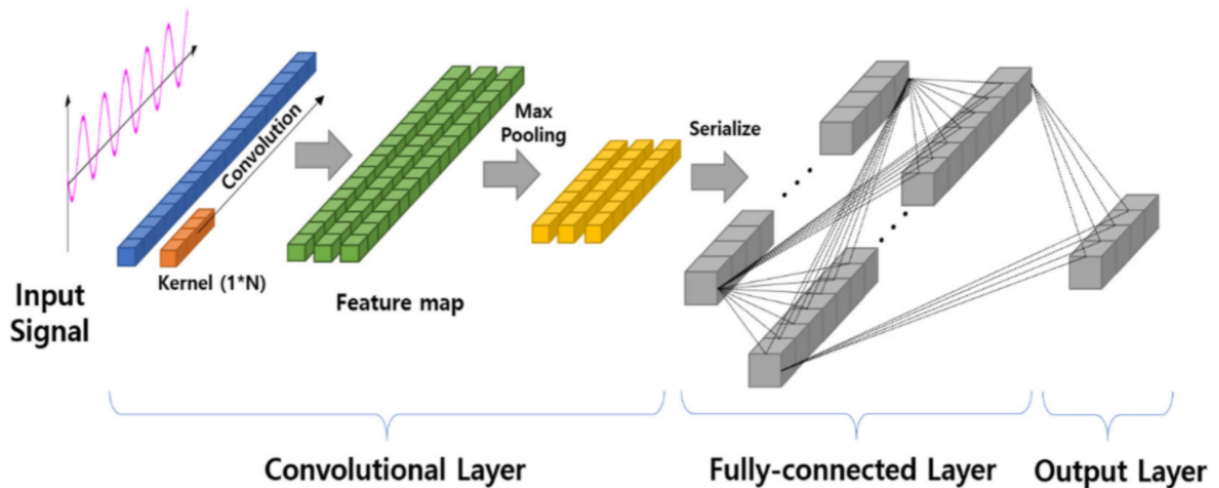
4.1.5 Redes Neurais Convolucionais

Aprendizado profundo ou *deep learning* é um subcampo do aprendizado de máquina relacionado a algoritmos inspirados na estrutura e função do cérebro, chamados de redes neurais artificiais. Essa classe de algoritmo utiliza várias camadas de processamento sendo que geralmente as primeiras camadas são utilizadas para extração de parâmetros, processo que é normalmente feito pelo projetista em algoritmos de aprendizado rasos. Dentre esses algoritmos, pode-se destacar as redes neurais convolucionais (RNC). Elas foram originalmente criadas para tarefas envolvendo imagens no trabalho de Lecun Boser e Denker (1990) com dados em duas dimensões e são basicamente alimentadas por dados processados através de convoluções na imagem de entrada por filtros (chamados de *kernels*). Uma camada convolucional apresenta o seguinte funcionamento: dada uma matriz com dados de entrada, faz-se a convolução desta por matrizes de menor ordem (os *kernels*). No resultado desta operação, pode ser aplicado o processo de *pooling* que realiza uma redução das matrizes geradas a partir da convolução. Na sequência, a informação contida na matriz de entrada é filtrada e concentrada em uma matriz de menor ordem, chamada de *feature map* (mapas de características). Os *feature maps* podem então alimentar outras camadas da rede neural.

Na análise de sinais em uma dimensão, pode-se substituir a convolução bidimensional realizada

na camada convolucional por uma convolução unidimensional, operando com vetores ao invés de matrizes. O processo de convolução unidimensional está ilustrado na Figura 17, note que a entrada da RNC é somente os dados em única dimensão que pode ou não passar por um pré-processamento.

Figura 17 – Arquitetura de rede convolucional unidimensional.



Fonte: Kim, Geem e Han (2020)

Dessa forma, uma camada convolucional unidimensional é utilizada para extrair informações do sinal de entrada por meio dos filtros e os dados filtrados podem servir como entrada de uma camada de classificação (TAO et al., 2019). Podemos definir como principais camadas e funções:

- **Camada de Convolução** : De acordo com Cerentini et al. (2018), uma camada de convolução tem como objetivo aprender de forma eficiente características importantes sobre os dados. Para isso é utilizada a técnica de conectividade local, que também é utilizada pelo córtex cerebral, onde o campo receptivo do neurônio é chamado de filtro. A tarefa do filtro é processar os dados ou a camada anterior, realizando a soma do produto de todos os valores de seu campo receptivo. Essa tarefa é executada em todas as posições de sua entrada.
- **Camada de Pooling** : De acordo com Cerentini et al. (2018) a camada de *pooling* tem a função de reduzir dimensionalmente cada mapa de característica, mantendo somente as informações mais relevantes. Essa técnica consiste em deslizar um filtro linear, sem que ele sobreponha regiões, com tamanho definido por toda a área do mapa e aplicar uma função de ativação que irá comprimir a informação da região que será observada pelo filtro. A técnica mais utilizada é a que usa o valor máximo encontrado na região, conhecida como *max pooling*.
- **Camada de Classificação** : A camada de classificação é a última camada da rede e é responsável por categorizar a entrada em uma das classes disponíveis com base nos processamentos realizados nas camadas anteriores.

4.1.5.1 Métodos de Otimização

Segundo Taqi et al. (2018), uma rede neural precisa que as variáveis de cada camada sejam alteradas de forma que esta funcione melhor no processo de classificação. Para esta tarefa é importante que o desempenho da rede seja continuamente medido através da comparação entre o resultado obtido e o resultado esperado. Sendo o objetivo da otimização minimizar o resultado da função *cross-entropy* (entropia cruzada), que é sempre positivo e se torna zero quando o resultado obtido é exatamente o mesmo resultado esperado. De acordo com Ruder (2016), o algoritmo Gradiente Descendente é um dos métodos mais populares utilizados na tarefa de otimizar redes neurais e cada biblioteca de aprendizado de máquina estado da arte contém diversas implementações de versões otimizadas desse algoritmo. Dentre elas destacam-se:

- *Stochastic Gradient Descent with Momentum (SGDM)* : O método *SGDM*, proposto por Sutskever et al. (2013) executa uma atualização de parâmetros para cada amostra de treino e de cada rótulo. O *SGDM* executa uma atualização de parâmetro por vez, o que o torna, geralmente, um algoritmo rápido e que pode ser utilizado para aprendizado online. Esse algoritmo realiza atualizações com uma alta variância que leva a função objetivo a sofrer grandes flutuações (RUDER, 2016).
- *Adaptive Moment Estimation (ADAM)* : *ADAM*, proposto por Kingma e Ba (2014), é um método de otimização que calcula as taxas de aprendizado adaptativas para cada parâmetro. Segundo Taqi et al. (2018), *ADAM* mantém uma média exponencial decrescente dos gradientes anteriores, realizando estimações do primeiro momento, a média, e no segundo momento, realiza a variação não centralizada dos gradientes respectivamente.
- *Root Mean Square Propagation (RMSPROP)* : O método *RMSPROP*, proposto por Hinton, Srivastava e Swerky (2012), é baseado em uma taxa de aprendizagem adaptativa que combina os objetivos, utilizar apenas o sinal do gradiente e adaptar separadamente o tamanho de passo para cada peso. Segundo Taqi et al. (2018), a média de execução num tamanho de passo depende da média anterior e do gradiente atual. Esse algoritmo divide a taxa de aprendizado por uma média exponencial decrescente do quadrado dos gradientes (RUDER, 2016).

4.2 TRANSFORMADA WAVELET

A transformada *Wavelet* (TW) é um recurso matemático que traz uma abordagem de análise de sinais no domínio tempo/escala, decompondo o sinal com base em famílias de *wavelets*. A forma como a TW localiza as informações do sinal no domínio da frequência e do tempo, torna-o um método de análise alternativo ao método *Short Time Fourier Transform (STFT)* para a análise de sinais não estacionários. Ao contrário da janela usada com o *STFT*, as famílias *wavelet* têm formas, como por exemplo Haar, Daubechies, symlets, Morlets, Coiflets, etc., mas a função

wavelet é escalável, o que significa que a transformação *wavelet* é adaptável a uma ampla gama de resoluções baseadas em frequência e tempo (NANDI; AHMED, 2019). A *wavelet* mãe $\psi(t)$ pode ser expressa matematicamente pela equação 6.

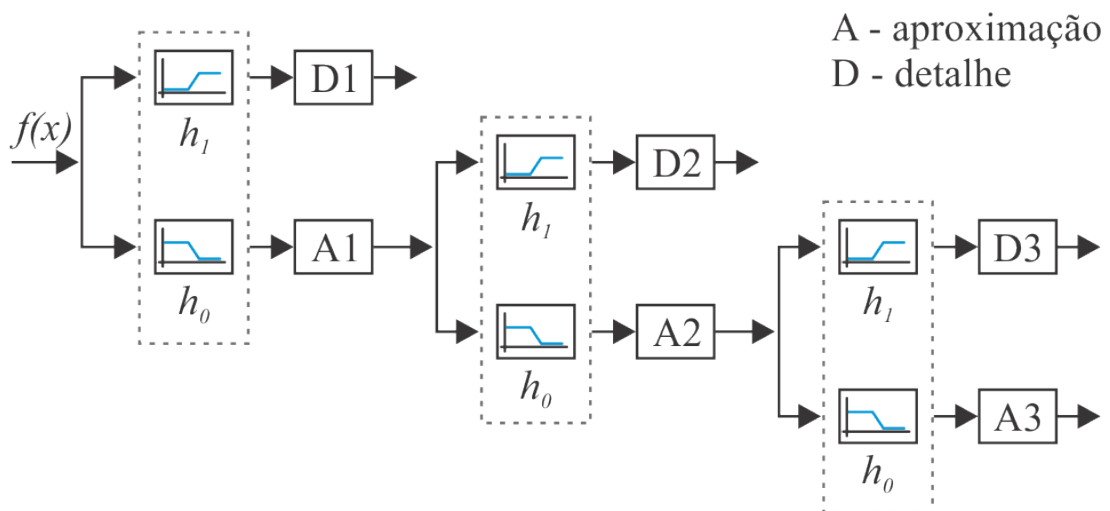
$$s, \tau = \frac{1}{\sqrt{s}} \left(\frac{t - \tau}{s} \right), \tag{6}$$

onde s representa o parâmetro de escala, τ o parâmetro de transformação e t é o tempo. As três principais transformadas na análise de *wavelets* são a transformada *wavelet* contínua (CWT), a transformada *wavelet* discreta (DWT) e a transformada *wavelet* de pacote (WPT) (BURRUS; GOPINATH; GUO, 1998). A CWT para um dado sinal $x(t)$ é definida como a soma ao longo de todo o tempo de um sinal, multiplicada por versões escalonadas e deslocadas da função *wavelet* mãe (ψ) (MISITI et al., 2002). A equação 7 apresenta a definição da CWT como:

$$CWT(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t - b}{a}\right) dt, \tag{7}$$

na qual $a \neq 0$, $x(t)$ é o sinal a ser analisado e $\psi(t)$ é a função base com duração limitada no tempo denominada *wavelet* mãe (STRANG; NGUYEN, 1996). A versão discreta da transformada (DWT) pode ser diretamente obtida da CWT fazendo $a = a_0^j$ e $b = kb_0 a_0^j$, sendo j, k valores inteiros e $a_0 > 1, b_0 > 0$. Para $a_0 = 2$ e $b_0 = 1$, obtém-se um caso particular da transformada *wavelet* discreta denominada discretização diádica (STRANG; NGUYEN, 1996). Neste caso, pode-se obter a transformada *wavelet* discreta de forma computacionalmente eficiente através do uso de bancos de filtros digitais passa-altas e passa-baixas. Na Figura 18 é apresentada a estrutura da análise multirresolução para decomposição do sinal até o terceiro nível de resolução.

Figura 18 – Análise multirresolução do sinal $f(x)$ com bancos de filtros passa-alta e passa-baixa.



Fonte: Lobão e Pinto (2020)

4.2.1 Extração de características derivadas da transformada *wavelet*

Existem diversas formas de se trabalhar com os coeficientes extraídos de um sinal com o uso da transformada *wavelet*. Nos tópicos a seguir serão explanados brevemente algumas maneiras de obter parâmetros que ressaltam características relevantes dos sinais e que serão utilizados neste estudo.

4.2.1.1 Extração de características por entropia de *Shannon*

A aleatoriedade do sinal é medida pela entropia. Em outras palavras, ele reflete a quantidade de informação no sinal dado (AYDIN; SARAÖĞLU; KARA, 2009). A entropia é definida como:

$$H(x) = - \sum_{i=0}^{N-1} p_i(x) \log_2(p_i(x)) \quad (8)$$

onde, para a variável aleatória discreta finita, $x = [x(0), x(1), \dots, x(N-1)]$, $p(x)$ denota a função de distribuição de probabilidade que indica um dos estados discretos. Portanto, a entropia é maior quando os estados discretos têm igual probabilidade de ocorrência. A entropia de *Shannon* ou Entropia de Informação foi introduzida por Claude *Shannon* em seu artigo. Em termos simplistas, a Entropia de *Shannon* reflete a distribuição de energia contida num sinal, sendo definida matematicamente na equação 9 (CORREA; GUZMAN, 2020), onde, $p_j = P(A_i|A)$, ou seja, é definido como a probabilidade de que um valor A_i apareça no sinal A (SHANNON, 1948).

$$H_E = - \sum_{j=1}^n p_j \log p_j. \quad (9)$$

Para a representação dos sinais de corrente no domínio tempo-frequência, foi calculado o valor da entropia de *Shannon* nos coeficientes obtidos pela transformada *wavelet* discreta. A utilização desse descritor para sinais decompostos com a transformada *wavelet* pode evidenciar características intrínsecas dos sinais.

4.2.1.2 Extração de características por medidas estatísticas

Sinais constituídos por uma quantidade grande de amostras, podem ser representados por um número reduzido de descritores que evidenciem características intrínsecas dos mesmos. Uma forma de redução e representação de sinais é com a utilização de medidas estatísticas que representem as principais fontes de variabilidade do sistema. A tabela 1, apresenta as principais medidas estatísticas utilizados na literatura para tratamento de sinais oriundos do domínio do tempo. A utilização dos referidos parâmetros para representar os sinais, pode resultar em sistemas de diagnósticos sensíveis a falhas incipientes, que, contudo, mantenham o desempenho para falhas consolidadas (LEI, 2016). As medidas estatísticas da Tabela 1 serão utilizados para extração de descritores no domínio do tempo e no domínio *wavelet*.

Tabela 1 – medidas estatísticas extraídas do sinal no domínio do tempo e tempo/escala .

Parâmetro	Descrição Matemática
Valor médio	$X_m = \frac{\sum_{n=1}^N x(n)}{N}$
Curtose	$X_{kurtosis} = \frac{\sum_{n=1}^N (x(n) - X_m)^4}{(N-1)X_{std}^4}$
Desvio padrão	$X_{std} = \sqrt{\frac{\sum_{n=1}^N (x(n) - X_m)^2}{N-1}}$
Skewness	$X_{skewness} = \frac{\sum_{n=1}^N (x(n) - X_m)^3}{(N-1)X_{std}^3}$
Raiz quadrada média	$X_{rms} = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$
Fator de crista	$X_{crest} = \frac{X_{peak}}{X_{rms}}$

Fonte: Lei (2016)

4.3 NORMALIZAÇÃO DOS DADOS

Frequentemente é necessário realizar transformações numéricas quando o conjunto de dados possui atributos com escalas e ordens de grandeza diferentes. Transformações dessa natureza são realizadas para evitar que atributos com maiores valores absolutos predominem sobre os demais, mesmo não sendo os mais relevantes para a obtenção dos modelos (FACELI et al., 2011). Entre as técnicas de transformação de dados, a normalização é a mais comum, e pode ser realizada por duas abordagens, a normalização por (i) reescala ou por (ii) padronização.

4.3.1 Normalização por reescala

A normalização por reescala, define uma nova escala para a representação dos atributos, e nessa escala os valores variam no intervalo de zero a um. A transformação por reescala é definida na equação 10. O novo valor do atributo é definido por x_n , x_i representa o valor atual, e min e max representam, respectivamente, os valores mínimos e máximos dos atributos na escala original.

$$x_n = \frac{x_i - min}{max - min}. \quad (10)$$

4.3.2 Normalização por padronização

Também conhecido como *Z-score*, a conversão é realizada subtraindo o valor atual (x_i) pela média (μ), e dividindo pelo desvio padrão (σ). O processo de normalização por padronização converte os valores obtendo uma média igual a zero e um desvio padrão igual a um, eliminando o viés introduzido pelas diferenças nas escalas das variáveis do conjunto. A equação 11 apresenta a formulação matemática que resulta na normalização por padronização. Para uma melhor compreensão, adotaremos neste trabalho o termo normalização quando esta for por reescala e padronização quando esta for pelo método *Z-score*.

$$x_n = \frac{x_i - \mu}{\sigma}. \quad (11)$$

4.4 MÉTRICAS DE DESEMPENHO

Em problemas de classificação é comum o uso da matriz de confusão para verificar o desempenho dos modelos. Essa matriz reúne as informações sobre o número de predições corretas e incorretas de cada classe. A partir da matriz de confusão várias outras métricas podem ser obtidas para a análise de desempenho dos classificadores.

A Figura 19 apresenta a matriz de confusão num problema de duas classes no qual a classe positiva é denotada pelo sinal (+) e a classe negativa é denotada pelo sinal (-), dessa forma:

- TP (*True Positive*): corresponde ao número de exemplos da classe positiva classificados corretamente.
- TN (*True Negative*): corresponde ao número de exemplos da classe negativa classificados corretamente.
- FP (*False Positive*): número de exemplos que pertencem à classe negativa mas foram classificados incorretamente como sendo da classe positiva.
- FN (*False Negative*): número de exemplos pertencentes à classe positiva que foram incorretamente classificados como sendo da classe negativa.

Figura 19 – Matriz de confusão de 2 classes.

		Classe Preditada	
		+	-
Classe Verdadeira	+	TP	FN
	-	FP	TN

Fonte: Autoria própria

Sendo n o número total de amostras, então $n = TP + TN + FP + FN$.

A partir da matriz de confusão, várias outras medidas de desempenhos podem ser calculadas, entre elas temos:

- *Accuracy* ou acurácia: corresponde à taxa de acerto, calculada pela soma dos valores da diagonal principal, dividido pelo número total de elementos da matriz.

$$accuracy = \frac{TP + TN}{n}. \quad (12)$$

- *Precision* ou precisão: quantidade de exemplos positivos classificados corretamente entre todos aqueles preditos como positivos.

$$precision = \frac{TP}{TP + FP}. \quad (13)$$

- *Recall* ou revocação: corresponde à taxa de acerto na classe positiva.

$$recall = \frac{TP}{TP + FN}. \quad (14)$$

- *F-measure* ou *f1-score*: média harmônica ponderada da precisão e revocação.

$$F_1 = \frac{2 \times prec \times recall}{prec + recall}. \quad (15)$$

As métricas citadas podem ser generalizadas em problemas que envolvem mais de duas classes. Para isso, a classe que está sendo observada é vista como positiva e as demais são consideradas negativas, desta forma, o cálculo das métricas podem ser realizados para cada tipo de classe. Situações que envolvem conjuntos de dados desbalanceados, a métrica *f1-score* é a mais adequada para representar o desempenho do classificador (GÉRON, 2017). Neste trabalho foi utilizado o *f1-score* como medida de desempenho pelo fato de já reunir informações sobre a precisão e a revocação.

5 METODOLOGIA

Este capítulo apresenta a metodologia que orientou a realização da pesquisa. Inicialmente é apresentado como foi realizada a aquisição dos dados, em seguida as técnicas de processamento dos sinais de corrente e de extração de características são descritas. Por último o procedimento para construção dos classificadores e validação dos resultados é apresentado. No Anexo B é apresentado o sistema onde foi adquirido o conjunto de dados.

5.1 AQUISIÇÃO DO SINAIS DE FUGA À TERRA

Para a implementação dos sistemas de identificação dos motores com falta à terra e em condições de operação normais, foram realizadas medições de correntes de sequência zero nos cabos de alimentação destes equipamentos em CCMs de uma sala elétrica no setor de secagem da indústria de celulose outrora referida. O CCM possui diversos compartimentos que são responsáveis por realizar o acionamento dos motores, sendo esses compartimentos chamados de "demarradores" ou "gavetas". Cada gaveta é composta por elementos de força, controle e proteção (contatores, disjuntores, relés térmicos, fusíveis) responsáveis por proteger e ligar/desligar estes equipamentos. Cabos de alimentação são conectados na saída dos demarradores, alimentando os motores em campo, conforme Figura 20.

Figura 20 – Detalhe construtivo do CCM.



Fonte: Acervo pessoal

A coleta das informações de corrente de sequência zero são obtidas inserindo uma garra ou pinça de medição de corrente nos cabos que saem dos alimentadores do CCM, envolvendo todas os condutores, simultaneamente, conforme detalhe à direita da Figura 20. Os instrumentos que

foram utilizados para medição das correntes estão apresentados na Figura 21. O kit de medição é composto por um oscilógrafo digital de alto processamento e garra de medição de corrente com capacidade de até 50 A.

Figura 21 – Equipamentos utilizados para aquisição de dados em campo - Oscilógrafo Yokogawa DL350 e Garra de Medição de Corrente Yokogawa 96033.



Fonte: Acervo pessoal

Ao todo foram realizadas 76 medições úteis, sendo 67 sinais de motores em condições normais e 9 com falta de fuga à terra. Cada medição foi realizada por um período de 10 segundos a uma taxa de amostragem de 100 kHz, totalizando 1000001 pontos amostrais por medição. A Tabela 2 apresenta o número de amostras por cada classe.

Tabela 2 – Número de amostras por classe

Classe	Nº de Amostras
Normal	67
Falha	9
Total	76

Fonte: Autoria Própria

Os dados foram coletados entre dezembro de 2019 e novembro de 2020, sendo que as medições nas condições de fuga à terra, foram obtidas no momento em que ocorriam as falhas, de forma natural, ao longo do processo de funcionamento da planta. O procedimento utilizado para a certificação que, de fato, ocorreu uma falta à terra, consistiu na medição das correntes de todos os motores conectados ao CCM em questão, juntamente com o desligamento voluntário das cargas, quando o equipamento podia ser desligado.

O instrumento utilizado para a coleta das informações armazena os dados no formato Matlab (*.mat), sendo que cada arquivo foi nomeado sequencialmente de 0000.mat a 0080.mat conforme apresentador na Tabela 3.

Os arquivos 0051, 0069, 0070, 0071, 0073 foram desconsiderados, pois houve falha no processo e aquisição dos dados, resultando na perda de parte das informações.

Tabela 3 – Arquivos coletados em campo

Condição	Nome do Arquivo (*.mat)
Normal	0000, 0001, 0002, 0003, 0004, 0005, 0006, 0007, 0008, 0009, 0010, 0011, 0012, 0013, 0014, 0015, 0016, 0017, 0018, 0019, 0020, 0021, 0022, 0023, 0024, 0025, 0026, 0027, 0028, 0029, 0030, 0031, 0032, 0033, 0034, 0035, 0036, 0037, 0038, 0039, 0040, 0041, 0042, 0043, 0044, 0045, 0046, 0047, 0048, 0049, 0050, 0052, 0053, 0054, 0055, 0056, 0057, 0058, 0060, 0061, 0062, 0063, 0064, 0065, 0066, 0067, 0068
Falha	0059, 0073, 0074, 0075, 0076, 0077, 0078, 0079, 0080
Desconsiderados	0051, 0069, 0070, 0071, 0073

Fonte:Autoria Própria

5.2 SEGMENTAÇÃO DOS SINAIS

Cada arquivo íntegro com os sinais nas condições normal e falta, foi segmentado em 100 amostras com 10000 *timesteps*. As amostras correspondentes a uma mesma condição (normal ou falta) foram reunidas para constituírem as classes que compõem o conjunto de dados. Dessa forma, as classes normal e falta à terra, possuem, respectivamente, 6700 e 900 amostras, sendo o conjunto constituído por 7600 amostras e 10000 *timesteps*, Tabela 4.


A Figura 22 ilustra o espaço amostral representado no plano bidimensional, em quatro situações. Em cada caso as duas dimensões do plano bidimensional foi representado por variáveis escolhidas aleatoriamente. Em todos os casos pode ser notado que as duas classes possuem regiões superpostas, que pode representar o desafio para a separação das amostras das duas classes.

Tabela 4 – Divisão de pontos amostrais para cada classe

Classe	Nº de Amostras	Nº de <i>Timesteps</i>
Normal	6700	10000
Falha	900	10000

Fonte:Autoria Própria

Figura 22 – Espaço amostral das correntes de motores normais e com fuga a terra no domínio do tempo.



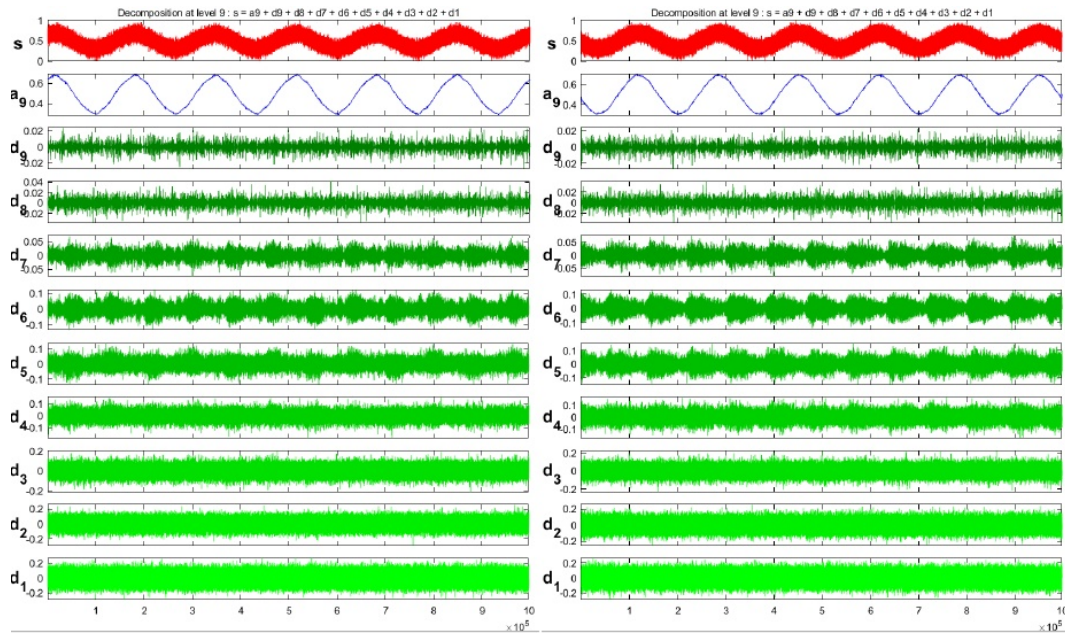
Fonte: Autoria Própria

5.3 ANÁLISE DOS DADOS E EXTRAÇÃO DE CARACTERÍSTICAS

Por ser tratar de um conjunto de dados único e exclusivo, foram realizadas várias análises e testadas diversas configurações para extração de características, a fim de encontrar a técnica que leve aos melhores resultados. Uma análise visual foi realizada nos sinais das classes normal e falha, após suas decomposições com a utilização do filtro *wavelet* da família *Coiflet 1*. Na Figura 23 vemos os sinais com o filtro *Coiflet 1* até o nível de resolução 9 de dois motores em condição normal de operação e na Figura 24, o mesmo filtro aplicado a sinais de dois equipamentos com fuga à terra.


Uma análise das figuras 23 e 24, nota-se que as diferenças mais acentuadas entre os sinais das classes “normal” e “falha” aparecem nos coeficientes de detalhe ” d_1 ” a ” d_9 ”, o que pode indicar que descritores extraídos desses coeficientes podem apresentar boa separabilidade entre as classes. Outro aspecto relevante a ser destacado, é que, de fato, os coeficientes de aproximação, que se assemelham aos sinais originais no domínio do tempo, não possuem características distintivas entre as classes “normal” e “falha”, visualmente. Como foi mencionado anteriormente, as correntes para terra em condição de funcionamento normal podem ser facilmente confundidas com as correntes de fuga, quando analisadas no domínio do tempo, considerando informações de amplitude.

Figura 23 – Coeficientes de detalhe e aproximação de sinais de corrente de sequência zero em motores normais com filtro *Coiflet 1*.



Fonte: Autoria Própria

Figura 24 – Coeficientes de detalhe e aproximação de sinais de corrente de sequência zero em motores com fuga à terra com filtro *Coiflet 1*.



Fonte: Autoria Própria

Da mesma forma, pode-se notar que, caso ocorram falhas simultâneas em mais de um motor, a identificação desses motores pode ser uma tarefa difícil pela abordagem proposta, pois esta condição não está inserida no conjunto de dados estudado. Dessa forma, o método proposto nesse trabalho se limita a identificação de falta quando envolve apenas um motor por vez. Para a realização dos experimentos, os sinais foram decompostos com os filtros wavelet *Daubechies (Db4)*, *Coiflet (Coif1)* e *Symlet(Sym8)*, em todos os níveis de resolução possíveis.

Quatro abordagens para a extração de descritores foram utilizadas. Na primeira etapa os descritores foram extraídos pelas medidas estatísticas apresentados na Tabela 1 no domínio do tempo. Na segunda abordagem, as mesmas medidas estatísticas foram utilizados para a extração de descritores a partir dos coeficientes resultantes da decomposição dos sinais pelos filtros wavelet. Na terceira, foi calculado o valor da entropia de *Shannon* também descrito na Seção 4.2.1.1 a partir dos coeficientes wavelet. Por último, os modelos de classificação foram obtidos utilizando uma rede neural convolucional unidimensional baseada no trabalho de (SELVA, 2021).

5.4 TREINAMENTO DO CLASSIFICADOR

Após a segmentação e normalização dos sinais no conjunto de dados, o conjunto foi particionado em subconjuntos de treinamento/validação e teste com 70% e 30% das amostras respectivamente. Os modelos de classificação foram obtidos utilizando os algoritmos de classificação *k-NN*, *DT*, *SVM* e *RF* tanto para os dados no domínio do tempo, quanto no domínio *wavelet*. Na utilização de RNC os sinais brutos foram inseridos diretamente na rede. Para avaliar o desempenho dos modelos na etapa de validação foi utilizado método *k-Fold Cross-Validation* com 10 partições. Para a avaliação do desempenho na etapa de testes foi utilizada a métrica de *f1-score*, que pode ser calculada diretamente da matriz de confusão, conforme visto na Seção 4.4. Todos os testes foram realizados no *software* Matlab®, R2021a.

Para a construção dos modelos foi necessário a configuração de alguns parâmetros dos algoritmos de classificação. As configurações utilizadas em cada caso estão descritas a seguir.

- *k-NN*: os valores de *k* foram ajustados para $k = 1, 3$ e 5 . A métrica de distância utilizada foi a euclidiana.
- *DT*: Como critério de divisão dos nós foi utilizada a entropia. A quantidade de nós não foi limitada.
- *SVM*: Foi utilizado o método *multiclass* um-contra-um. Por definição de projeto, foi utilizado o *kernel* do tipo gaussiano.
- *RF*: Para floresta aleatória foi utilizada uma coleção de 100 árvores de classificação para o treinamento do algoritmo.

Para a construção dos modelos com rede neural convolucional foram testadas as configurações descritas a seguir:

- Camadas: A rede neural convolucional possui 7 camadas, sendo 1 de entrada, 1 de convolução, 1 camada de *pooling*, 3 *fully connected* e 1 camada de classificação na saída.
- Filtros: foram testados as quantidades de filtros 5, 10, 20, 40 e 80 respectivamente.

- Otimizadores: Para este trabalho foram escolhidos os seguintes métodos de otimização para comparação de desempenho, conhecidos *SGDM*, *RMSPROP* e *ADAM*.
- *Kernel*: Foi utilizado $k=3$.

Outros testes realizados utilizando Transformada Curta de Fourier, *Maximal Overlap Discrete Wavelet Transform (MODWT)* e Análise de Componentes Principais são apresentados no Apêndice A. Os resultados obtidos nestes testes não foram satisfatórios e servem como referência a trabalhos futuros que possam utilizar o mesmo conjunto de dados.

6 RESULTADOS

Este capítulo apresenta os resultados referentes ao estudo de caso em identificação de falhas de fuga à terra, por meio de medição de corrente de sequência zero. Os resultados foram obtidos, após a etapa de treinamento do classificador, através dos dados reservados para testes, que constituem de 30% da quantidade de amostras do conjunto original. Conforme descrito na Seção 4.4, as métricas utilizadas para avaliação do desempenho dos modelos foi o *f1-score*.

6.1 RESULTADO DA CLASSIFICAÇÃO COM OS MODELOS CONSTRUÍDOS COM DESCRITORES ESTATÍSTICOS NO DOMÍNIO DO TEMPO

Nessa abordagem, foram extraídos seis descritores estatísticos dos sinais que constituem as amostras na matriz de dados: valor médio, curtose, desvio padrão, assimetria, *RMS* e fator de crista. Na Tabela 5 são apresentadas as dimensões das matrizes, original (coluna 2) e após a extração dos descritores estatísticos (coluna 3), por classe. Pode-se observar, inicialmente que a estratégia de extrair descritores a partir de medidas estatísticas, apresenta a vantagem visível da redução do número de variáveis que serão utilizadas para a construção dos modelos, dessa forma, espera-se que o custo computacional dessa estratégia seja significativamente menos quando comparado a estratégia anterior.

Tabela 5 – Dimensões das matrizes por classe

Classes	Matrizes de Atributos	
	Original	Estatístico
Normal	6700x10000	6700x6
Falha	900x10000	900x6

Fonte: Autoria Própria

A Tabela 6 mostra os resultados dos testes dos modelos dos classificadores. Todos os classificadores, em todas as configurações de teste obtiveram bons resultados de *f1-score*, sendo que os melhores foram alcançados pelos modelos dos algoritmos *k-NN* com 1-vizinho-mais-próximo e o *RF* (em destaque), ambos com com 88,96%. O modelo criado com *DT* foi o que obteve o pior desempenho de todos os testes realizados nesta etapa com 81,9% de *f1-score*.

Os classificadores *k-NN* na configuração de 3 e 5 vizinhos e o *SVM* alcançaram respectivamente 82,11% de *f1-score*. De forma geral, a utilização de descritores estatísticos resultou em modelos com boa capacidade de predição. Os resultados completos são apresentados no Apêndice A.4, onde estão contemplados os valores de acurácia da etapa de treinamento e *f1-score* para cada classe.

Tabela 6 – Resultado classificação no domínio do tempo com descritores estatísticos

Classificador	f1-score
DT	81,9
1-NN	88,96
3-NN	82,11
5-NN	82,11
SVM	82,11
RF	88,96

Fonte: Autoria Própria

6.2 RESULTADO DA CLASSIFICAÇÃO COM OS MODELOS CONSTRUÍDOS COM A UTILIZAÇÃO DE DESCRITORES NO DOMÍNIO WAVELET

Para classificação dos sinais de corrente de sequência zero dos equipamentos, foram extraídos os coeficientes no domínio tempo-escala com a utilização de filtros *wavelet*. Foram analisados os dados dos coeficientes de aproximação no primeiro nível de resolução (ca1) e todos os coeficientes de detalhe do primeiro até o nono nível de resolução (cd1 a cd9). Após o cálculo dos coeficientes *wavelet*, foram extraídos os mesmos seis descritores estatísticos da seção 6.2; valor médio, curtose, desvio padrão, assimetria, *RMS* e fator de crista. Na Tabela 7 são apresentadas as matrizes de coeficientes *wavelet* para cada nível de resolução (coluna 2) e as matrizes de descritores obtidos por meio das medidas estatísticas (coluna 3 - 7600 linhas e 6 colunas), sendo estes últimos utilizados para treinamento e teste dos modelos obtidos com os algoritmos de classificação.

Tabela 7 – Dimensões das matrizes por coeficientes e níveis de resolução

Coeficientes e níveis de resolução	Número de descritores tempo/escala	Número de descritores estatísticos tempo/escala
ca1	7600x5007	7600x6
cd1	7600x5007	7600x6
cd2	7600x2511	7600x6
cd3	7600x1263	7600x6
cd4	7600x639	7600x6
cd5	7600x327	7600x6
cd6	7600x171	7600x6
cd7	7600x93	7600x6
cd8	7600x54	7600x6
cd9	7600x34	7600x6

Fonte: Autoria Própria

Para a decomposição dos sinais originais foram utilizados os filtros *wavelet* das famílias,

Daubechies-4 (Db4), *Symlet-8 (Sym8)* e *Coiflet-1 (Coif1)*. A Tabela 8 apresenta os resultados da classificação dos algoritmos *DT*, *SVM* e *RF*, e a Figura 9 mostra os resultados da classificação obtidos pelas diferentes configuração do classificador *k-NN*. Na coluna 2 (Coef.) são apresentados os níveis de resolução utilizados, com a descrição de "ca" para os coeficientes de aproximação e "cd" para os coeficientes de detalhe. Com os descritores obtidos a partir do filtro *Db4* (colunas 3 e 4), os melhores resultados foram encontrados com *DT* nos coeficientes de detalhe no nível 1, sendo o valor de 95,87% para *f1-score*. Esses mesmos valores foram alcançados com o *SVM* e *RF* com os cd1, cd2, cd3 e cd4, para o mesmo filtro. Com o filtro *Coif1*, os melhores resultados foram obtidos com a *RF*, utilizando os descritores do cd2, atingindo 97,04% de *f1-score*. O filtro da família *Sym8* obteve os melhores resultados globais com uso destes descritores (em destaque na tabela), 97,27% de *f1-score*. Estes resultados se repetiram e foram obtidos nos algoritmos *SVM*, com os coeficientes de detalhe nos níveis de resolução 1 e 3 e com *RF* nos coeficientes de detalhe do primeiro nível de resolução. É possível observar que em todos os testes, os coeficientes de detalhe dos primeiros níveis de resolução, sempre apresentam maiores valores de *f1-score* e vão diminuindo até o oitavo nível. Os desempenhos inferiores são observados nos níveis de resolução 7 e 8 em todos os modelos e filtros.

De forma geral, todos os testes alcançaram ótimos resultados, mesmo nos modelos com pior desempenho. Isso demonstra que os filtros utilizados em conjunto com os descritores estatísticos obtidos, extraem características dos sinais que facilitam a separabilidade das classes. Os resultados completos são apresentados nos Apêndices A.5, A.6 e A.7 onde estão contemplados os valores de acurácia da etapa de treinamento e *f1-score* para cada classe.

Tabela 8 – Resultados de desempenho nos testes dos classificadores DT, SVM e RF com descritores estatísticos obtidos dos coeficientes no domínio tempo-escala

Classif.	Coef.	Db4 f1 score	Sym8 f1 score	Coif1 f1 score
DT	ca1	87,87	88,51	87,70
	cd1	95,87	97,16	96,60
	cd2	95,76	96,47	96,93
	cd3	95,76	96,86	96,36
	cd4	95,66	96,70	95,93
	cd5	94,63	94,59	93,19
	cd6	93,22	95,94	95,55
	cd7	81,49	79,46	81,51
	cd8	80,90	82,76	82,97
	cd9	86,95	89,62	89,39
SVM	ca1	92,04	92,33	92,43
	cd1	95,87	97,27	96,80
	cd2	95,87	96,46	96,93
	cd3	95,87	97,27	96,46
	cd4	95,87	96,70	96,24
	cd5	94,69	95,57	94,00
	cd6	92,73	95,84	95,59
	cd7	85,70	85,80	85,53
	cd8	80,24	83,69	85,41
	cd9	90,34	91,12	91,19
RF	ca1	92,94	91,92	92,23
	cd1	95,87	97,27	96,70
	cd2	95,87	96,46	97,04
	cd3	95,87	97,38	96,46
	cd4	95,87	96,80	96,34
	cd5	94,80	95,16	94,00
	cd6	93,33	96,12	96,15
	cd7	85,94	84,23	85,10
	cd8	83,10	84,50	85,62
	cd9	90,37	91,15	91,22

Fonte: Autoria Própria

Tabela 9 – Resultados de desempenho nos testes do classificador k-NN com k igual a 1, 3 e 5 com descritores estatísticos obtidos dos coeficientes no domínio tempo-escala

Classif.	Coef.	Db4 f1 score	Sym8 f1 score	Coif1 f1 score
1-NN	ca1	87,32	88,08	88,56
	cd1	92,79	94,86	94,22
	cd2	91,96	94,83	93,95
	cd3	92,28	93,18	92,07
	cd4	91,26	92,10	91,73
	cd5	89,80	89,75	87,78
	cd6	88,51	91,01	89,66
	cd7	75,05	74,70	76,25
	cd8	74,59	76,31	77,22
	cd9	85,17	86,77	87,02
3-NN	ca1	90,05	90,56	90,58
	cd1	95,32	96,64	96,70
	cd2	95,45	95,90	96,39
	cd3	95,11	96,39	95,47
	cd4	92,53	94,30	94,00
	cd5	91,45	92,50	91,69
	cd6	89,29	91,08	92,00
	cd7	78,78	75,88	78,06
	cd8	79,04	81,85	80,79
	cd9	89,29	89,69	90,79
5-NN	ca1	90,76	90,49	90,51
	cd1	95,63	97,05	96,69
	cd2	95,45	95,88	96,26
	cd3	95,08	96,49	95,11
	cd4	92,35	94,61	94,32
	cd5	91,73	92,19	92,03
	cd6	89,22	91,15	91,86
	cd7	77,00	76,75	76,98
	cd8	79,54	79,63	81,50
	cd9	88,81	89,82	90,00

Fonte: Autoria Própria

6.3 RESULTADO DA CLASSIFICAÇÃO COM OS MODELOS CONSTRUÍDOS COM DESCRITORES OBTIDOS PELA ENTROPIA DE SHANNON NO DOMÍNIO WAVELET

Uma outra abordagem utilizada, foi a classificação dos sinais de corrente por meio do cálculo da entropia de *Shannon* dos coeficientes no domínio *wavelet*. O valor da entropia é calculado para cada linha do conjunto de dados, reduzindo a dimensão da matriz de descritores, conforme apresentado na Tabela 10.

Tabela 10 – Dimensões das matrizes por coeficientes e níveis de resolução

Coeficientes e níveis de resolução	Número de descritores tempo/escala	Número de descritores Entropia de <i>Shannon</i>
ca1	7600x5007	7600x1
cd1	7600x5007	7600x1
cd2	7600x2511	7600x1
cd3	7600x1263	7600x1
cd4	7600x639	7600x1
cd5	7600x327	7600x1
cd6	7600x171	7600x1
cd7	7600x93	7600x1
cd8	7600x54	7600x1
cd9	7600x34	7600x1

Fonte: Autoria Própria

Para o cálculo dos coeficientes no domínio *wavelet*, foi realizado o mesmo procedimento da Seção 6.2 com os filtros *wavelet* das famílias *Db4*, *Sym8* e *Coif1*. Nas Tabelas 11 e 12 são apresentados os valores de desempenho de cada algoritmo testado. Os descritores do filtro *Db4* (colunas 3 e 4), obtiveram os melhores resultados com *DT* nos coeficientes de detalhe no nível 2, sendo o valor de 97,15% para *f1-score*. Esse mesmo valor foi alcançado com o *SVM* nos cd2 e cd3, para o mesmo filtro. Com o filtro *Coif1*, os melhores resultados foram obtidos com a *DT*, utilizando os descritores do cd2, atingindo 97,39% de *f1-score*. O melhor resultado geral foi obtido com filtro da família *Sym8* (em destaque na tabela), alcançando 97,49% de *f1-score*.

É possível observar o mesmo comportamento dos testes da Seção 6.2 onde os coeficientes de detalhe dos primeiros níveis de resolução apresentam maiores valores *f1-score* e vão reduzindo até o oitavo nível. Os piores resultados são observados nos níveis de resolução 7 e 8 em todos os modelos e filtros. Os resultados completos são apresentados nos Apêndices A.8, A.9 e A.10 onde estão contemplados os valores de acurácia da etapa de treinamento e *f1-score* para cada classe.

Tabela 11 – Resultados de desempenho nos testes dos classificadores DT, SVM e RF com descritores de entropia de *Shannon* obtidos dos coeficientes no domínio tempo-escala

Classif.	Coef.	Db4	Sym8	Coif1
		f1 score	f1 score	f1 score
DT	ca1	82,41	84,41	84,28
	cd1	96,71	96,48	96,48
	cd2	97,15	97,39	97,39
	cd3	96,94	96,00	96,00
	cd4	96,25	96,69	96,69
	cd5	92,42	92,26	92,26
	cd6	93,75	92,94	92,94
	cd7	80,55	79,20	79,20
	cd8	78,15	75,45	75,45
	cd9	86,97	85,31	85,31
SVM	ca1	80,66	81,28	81,71
	cd1	96,92	96,69	96,69
	cd2	97,15	97,49	96,57
	cd3	97,15	96,10	96,34
	cd4	96,46	96,69	96,22
	cd5	92,62	92,36	92,26
	cd6	94,06	93,55	94,06
	cd7	79,46	78,90	81,47
	cd8	72,17	71,84	74,16
	cd9	86,40	85,36	86,80
RF	ca1	73,92	76,03	75,88
	cd1	94,91	93,62	95,12
	cd2	94,65	94,89	94,10
	cd3	94,35	93,60	93,30
	cd4	94,14	93,25	93,71
	cd5	86,68	88,41	86,18
	cd6	89,89	91,13	90,85
	cd7	74,12	73,69	74,45
	cd8	69,77	67,71	70,27
	cd9	80,81	79,78	78,92

Fonte: Autoria Própria

Tabela 12 – Resultados de desempenho nos testes do classificador k-NN com k igual a 1, 3 e 5 com descritores de entropia de *Shannon* obtidos dos coeficientes no domínio tempo-escala

Classif.	Coef.	Db4	Sym8	Coif1
		f1 score	f1 score	f1 score
1NN	ca1	73,92	75,97	75,88
	cd1	94,81	93,62	95,12
	cd2	94,65	94,89	94,10
	cd3	94,35	93,60	93,30
	cd4	94,14	93,25	93,71
	cd5	86,68	88,41	86,18
	cd6	89,89	91,13	90,85
	cd7	74,12	73,63	74,45
	cd8	69,77	67,71	70,27
	cd9	80,81	79,63	78,91
3NN	ca1	80,32	82,00	80,40
	cd1	94,81	93,62	95,12
	cd2	94,65	94,89	94,10
	cd3	94,35	93,60	93,30
	cd4	94,14	93,25	93,71
	cd5	86,68	88,41	86,18
	cd6	89,89	91,13	90,85
	cd7	74,12	73,63	74,45
	cd8	69,77	67,71	70,27
	cd9	80,81	79,63	78,91
5NN	ca1	81,68	84,01	82,63
	cd1	94,81	93,62	95,12
	cd2	94,65	94,89	94,10
	cd3	94,35	93,60	93,30
	cd4	94,14	93,25	93,71
	cd5	86,68	88,41	86,18
	cd6	89,89	91,13	90,85
	cd7	74,12	73,63	74,45
	cd8	69,77	67,71	70,27
	cd9	80,81	79,63	78,91

Fonte: Autoria Própria

6.4 RESULTADO DA CLASSIFICAÇÃO COM OS MODELOS CONSTRUÍDOS REDE NEURAL CONVOLUCIONAL

Essa seção apresenta o desempenho dos modelos de classificação construídos com rede neural convolucional. A Tabela 13 mostra os resultados dos testes dos modelos de classificação utilizando o otimizador *SGDM*. O melhor resultado foi obtido no teste com 10 filtros onde foi alcançado o valor de 96,31% de f1-score e o pior foi obtido com 80 filtros, com 91,96% de f1-score.

Tabela 13 – Resultados com otimizador *SGDM*

N° Filtros	f1-score
5	94,03
10	96,31
20	95,87
40	95,14
80	91,96

Fonte: A autoria Própria

A Tabela 14 mostra os resultados dos testes dos modelos de classificação utilizando o otimizador *RMSPROP*. Os melhores resultados foram obtidos no teste com 10 e 80 filtros onde foi alcançado o valor de 100,00% de f1-score e o pior foi obtido com 5 filtros, com 88,47% de f1-score.

Tabela 14 – Resultados com otimizador *RMSPROP*

N° Filtros	f1-score
5	88,47
10	100,00
20	98,76
40	99,79
80	100,00

Fonte: A autoria Própria

A Tabela 15 mostra os resultados dos testes dos modelos de classificação utilizando o otimizador *ADAM*. O melhor resultado foi obtido no teste com 10 filtros onde foi alcançado o valor de 99,26% de f1-score e o pior foi obtido com 40 filtros, com 94,86% de f1-score.

No Apêndice A são apresentadas informações adicionais dos resultados dos testes realizados com RNC.

Tabela 15 – Resultados com otimizador *ADAM*

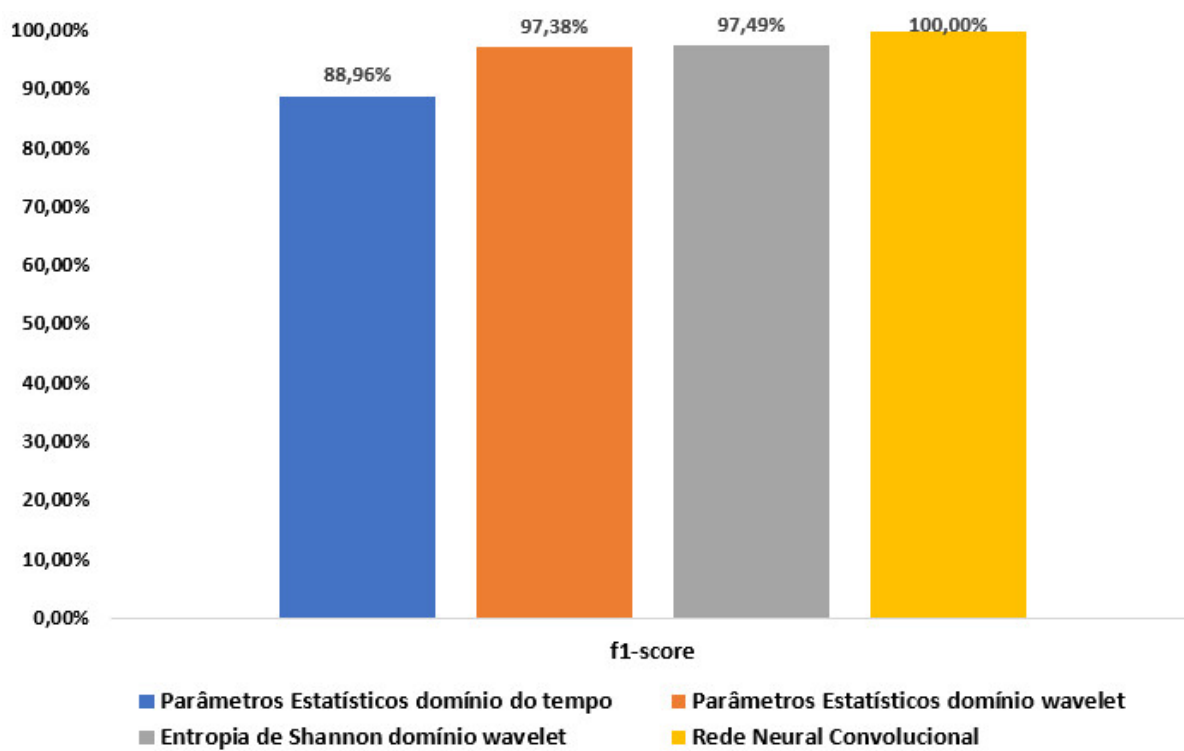
N° Filtros	f1-score
5	97,07
10	99,26
20	96,07
40	94,86
80	97,94

Fonte: Aatoria Própria

6.5 COMPARAÇÃO DOS RESULTADOS

Os melhores resultados alcançados na etapa de teste dos modelos implementados, são apresentados na Figura 25. Os parâmetros estatísticos aplicados diretamente no sinal no domínio do tempo com os classificadores *k-NN* e *RF*, atingiram valor 83,96% de *f1-score*, sendo este o menor resultado dentre as quatro abordagens realizadas, entretanto é um modelo com um desempenho apropriado, pois tem alta taxa de acerto e indica que frequentemente o classificador está correto. Nas abordagens utilizando dados no domínio tempo-escala, foram encontrados os melhores desempenhos dos classificadores, com 97,38% de *f1-score* nos descritores obtidos de medidas estatísticas utilizando o filtro *Sym8* e o algoritmo *RF*. Com uso da entropia de *Shannon*, o filtro *Sym8* e o *SVM* foi obtido 97,49% de *f1-score*. Na aplicação de RNC, houve 100,00% de acerto de todas as classes, na configuração com o otimizador *RMSPROP* utilizando 10 e 80 filtros. De forma geral, os resultados utilizando a rede neural foi superior aos demais classificadores. Os valores finais apresentados na Figura 25 demonstram que é possível detectar problemas de fuga à terra, baseando-se somente na medição de correntes de sequência zero com alta taxa de acerto. Estes resultados comprovam a eficiência do método.

Figura 25 – Melhores Resultados de f1-score para cada conjunto de descritores.



Fonte: Autoria Própria

7 CONCLUSÃO

Este trabalho apresenta uma proposta de metodologia para detecção de falhas em motores com fuga à terra em CCM's com aterramento do neutro por resistor de alto valor, usando modelos de aprendizado de máquina com dados obtidos da transformada wavelet e dados no domínio do tempo. Neste estudo é utilizado um conjunto de dados original que nunca foi utilizado em outro trabalho, sendo que este foi coletado em uma indústria de celulose, em equipamentos do processo produtivo em pleno funcionamento na planta. Os resultados obtidos nos testes para diagnóstico das falhas mostram a viabilidade de implementação desses sistemas nos sistemas elétricos onde há a característica de aterramento do neutro com resistor de alto valor ôhmico. As amostras são separáveis pelos métodos de classificação investigados, o que foi confirmado pelo desempenho dos classificadores, que na maioria dos casos obteve valores de acurácia e *f1-score* superiores a 92%.

Os melhores desempenhos em cada caso (três das quatro abordagens com valores superiores a 97% de *f1-score*) demonstram a possibilidade da aplicação destas técnicas em sistemas inteligentes para diagnóstico automático de equipamentos em condição de falha, com alta precisão e confiabilidade. A utilização de descritores estatísticos, apesar de não ter alcançado o melhor resultado, atinge um valor de *f1-score* de 88,96% que indica boa taxa de acerto na classificação dos sinais dos motores com falha. Os descritores extraídos a partir dos coeficientes *wavelet* apresentaram os bons resultados entre todos os testes realizados , sendo o melhor desempenho com o algoritmo *SVM* em conjunto com o filtro *Sym8* associado a os valores da entropia de *Shannon* (97,49% de *f1-score*). Isso demonstra que entropia de *Shannon* calculada a partir dos coeficientes *wavelet* ressaltam características importantes do sinal de corrente de sequência zero, que descrevem o conjunto com precisão. A classificação dos sinais com uso da rede neural convolucional alcançou 100,00% de acerto, com uso de uma rede simples com poucas camadas. Os resultados obtidos mostram que os classificadores construídos com otimizador *RMSPROP* apresentam valores superiores em relação aos modelos construídos com os demais otimizadores. O melhor desempenho foi obtido com o *RMSPROP* aplicando 10 e 80 filtros, tendo sido alcançado 100,00% de *f1-score*. Esse resultado pode ser justificado pelo fato de o otimizador *RMSPROP* utilizar uma taxa de aprendizado adaptativa em vez de tratar a taxa de aprendizado fixa, fazendo com que a taxa de aprendizagem mude com o tempo alcançando os melhores resultados. O número de 10 filtros apresentou os melhores resultados em todos os otimizadores utilizados nesta abordagem, isso indica que essa quantidade de filtros evidencia melhor as características do sinal, facilitando a classificação pelo algoritmo. Os resultados mostram ainda que, em circuitos elétricos de baixa tensão com aterramento do neutro com resistor de alto valor ôhmico, é factível a implementação de sistema para detecção de faltas à terra utilizando as características intrínsecas dos sinais de corrente de sequência zero e RNC, sem realizar alterações significativas no projeto

elétrico das instalações originais, pois os elementos de medição de corrente e de processamento dos sinais utilizados neste estudo não precisam desligar nem modificar os circuitos existentes. A princípio, esta metodologia pode ser aplicada a quaisquer cargas trifásicas e não somente motores, sendo isso um estudo para trabalhos futuros. Com base nos resultados obtidos, fica evidente que essa metodologia para detecção e classificação de falhas pode ser implementada e aplicada em sistemas de monitoramento online de falhas, o que traz maior segurança também as pessoas que estão em contato direto com estes circuitos.

7.1 TRABALHOS FUTUROS

A partir dos estudos realizados, é possível avaliar outras técnicas e configurações neste mesmo conjunto de dados, desta forma, a continuidade deste trabalho será contemplada por:

- Criar um sistema de medição embarcado com diagnóstico de motor com fuga a terra;
- Testes de outras configurações de classificação baseados em Redes Neurais e *Machine Learning*;
- Testar o quanto o sinal é influenciado pela impedância da falta a terra e se esta técnica pode ser empregada em outros sistemas de aterramento do neutro;

REFERÊNCIAS

- ABDESH, M.; KHAN, S.; RAHMAN, M. A. A new wavelet based diagnosis and protection of faults in induction motor drives. In: IEEE. *2008 IEEE Power Electronics Specialists Conference*. [S.l.], 2008. p. 1536–1541. Citado na página 22.
- ALMEIDA, P. S. d. *Manutenção mecânica industrial: Conceitos básicos e tecnologia aplicada*. 1º. ed. [S.l.]: Editora Érica, 2018. 256 p. ISBN 978-8536511825. Citado na página 16.
- AYDIN, S.; SARAOĞLU, H. M.; KARA, S. Log energy entropy-based eeg classification with multilayer neural networks in seizure. *Annals of biomedical engineering*, Springer, v. 37, n. 12, p. 2626, 2009. Citado na página 45.
- BALDWIN, T.; RENOVICH, F.; SAUNDERS, L. F. Directional ground-fault indicator for high-resistance grounded systems. *IEEE Transactions on Industry Applications*, IEEE, v. 39, n. 2, p. 325–332, 2003. Citado 2 vezes nas páginas 19 e 21.
- BERNARDI, G. d. A. F. Aterramento de neutro em subestações industriais e suas implicações no sistema de proteção. 2015. Citado na página 100.
- BLACKBURN, J. L.; DOMIN, T. J. *Protective relaying: principles and applications*. [S.l.]: CRC press, 2015. Citado 2 vezes nas páginas 26 e 100.
- BOWEN, J. Grounding for industrial systems. Institute of Electrical and Electronics Engineers (IEEE), 2011. Citado na página 16.
- BREIMAN, L. Random forests. *Machine Learning*, Kluwer Academic Publishers, v. 45, n. 1, p. 5–32, 2001. ISSN 0885-6125. Disponível em: <<https://doi.org/10.1023/A:1010933404324>>. Citado na página 40.
- BURRUS, C.; GOPINATH, R.; GUO, H. A primer introduction to wavelets and wavelet transforms. *New Jersey: Prentice Hall*, v. 1, 1998. Citado na página 44.
- CAI, X. W. et al. The design of location system for single-phase grounded fault in distribution network based on zero-sequence current. In: TRANS TECH PUBL. *Advanced Materials Research*. [S.l.], 2014. v. 986, p. 1677–1681. Citado na página 20.
- CERENTINI, A. et al. Identificação do glaucoma em imagens do fundo do olho utilizando aprendizagem profunda. In: . [S.l.]: Universidade Federal de Santa Maria, 2018. Citado na página 42.
- COMMITTEE, I. I. A. S. P. S. T. *IEEE recommended practice for grounding of industrial and commercial power systems*. [S.l.]: IEEE, 2007. Citado na página 100.
- CORREA, J. C. J.; GUZMAN, A. L. *Mechanical vibrations and condition monitoring*. [S.l.]: Elsevier, 2020. Citado na página 45.
- CORTES, C.; VAPNIK, V. Support-vector networks. In: *Machine Learning*. [S.l.: s.n.], 1995. p. 273–297. Citado na página 35.

COSTA, P. F. Capítulo iii-avanços na especificação e aplicação dos resistores de aterramento do neutro dos sistemas elétricos industriais em baixa tensão. *Revista O Setor Elétrico, Setembro 2014*, 2014. Citado 3 vezes nas páginas 20, 26 e 27.

DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. 2. ed. New York: Wiley, 2001. ISBN 978-0-471-05669-0. Citado na página 36.

DUNKI-JACOBS, J. R. The effects of arcing ground faults on low-voltage system design. *IEEE Transactions on Industry Applications*, IEEE, n. 3, p. 223–230, 1972. Citado na página 99.

EL-SHERIF, N. Ground-fault protection: All you need to know. *IEEE Transactions on Industry Applications*, IEEE, v. 53, n. 6, p. 6047–6056, 2017. Citado na página 31.

FACELI, K. et al. *Inteligência Artificial: Uma abordagem de aprendizado de máquina*. Rio de Janeiro: LTC, 2011. Citado 4 vezes nas páginas 36, 37, 40 e 46.

GÉRON, A. *Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems*. [S.l.]: "O'Reilly Media, Inc.", 2017. Citado na página 48.

GUO, M.-F. et al. Location of single-line-to-ground fault using 1-d convolutional neural network and waveform concatenation in resonant grounding distribution systems. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 70, p. 1–9, 2020. Citado na página 24.

HINTON, G.; SRIVASTAVA, N.; SWERSKY, K. Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. In: . [S.l.: s.n.], 2012. v. 14, n. 8, p. 2. Citado na página 43.

HUSSEY, M. R.; DRZYMALA, S. Ground fault protection applications in low voltage motor control systems for process industries. In: IEEE. *2019 IEEE-IAS/PCA Cement Industry Conference (IAS/PCA)*. [S.l.], 2019. p. 1–8. Citado na página 17.

IEEE. Ieee standard electrical power system device function numbers, acronyms, and contact designations. *IEEE Std C37.2-2008 (Revision of IEEE Std C37.2-1996)*, p. 1–48, 2008. Citado na página 29.

KIM, S.-H.; GEEM, Z. W.; HAN, G.-T. Hyperparameter optimization method based on harmony search algorithm to improve performance of 1d cnn human respiration pattern recognition system. *Sensors, Multidisciplinary Digital Publishing Institute*, v. 20, n. 13, p. 3697, 2020. Citado 2 vezes nas páginas 7 e 42.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. In: . [S.l.: s.n.], 2014. Citado na página 43.

LECUN, Y.; BOSER, B.; DENKER, J. D. henderson, re howard, w. hubbard, and lj jackel. *Handwritten digit recognition with a back-propagation network*, p. 396–404, 1990. Citado na página 41.

LEI, Y. *Intelligent fault diagnosis and remaining useful life prediction of rotating machinery*. [S.l.]: Butterworth-Heinemann, 2016. Citado 2 vezes nas páginas 45 e 46.

LIANG, J. Single-phase grounding fault location method for distribution network based on convolutional neural network. In: IEEE. *2019 IEEE 3rd International Electrical and Energy Conference (CIEEC)*. [S.l.], 2019. p. 672–677. Citado na página 24.

- LOBAO, D. A.; PINTO, L. A. Diagnóstico inteligente de falhas em equipamentos dinâmicos através da transformada wavelet e dados estatístico. In: *Congresso Brasileiro de Automática-CBA*. [S.l.: s.n.], 2020. v. 2, n. 1. Citado na página 44.
- LUBICH, D. High resistance grounding and fault finding on three phase three wire (delta) power systems. In: IEEE. *1997 IEEE Annual Textile, Fiber and Film Industry Technical Conference*. [S.l.], 1997. p. 10–5. Citado na página 19.
- MAGNAGO, F. H.; ABUR, A. A new fault location technique for radial distribution systems based on high frequency signals. In: IEEE. *1999 IEEE Power Engineering Society Summer Meeting. Conference Proceedings (Cat. No. 99CH36364)*. [S.l.], 1999. v. 1, p. 426–431. Citado na página 22.
- MARDEGAN, C. Proteção e seletividade em sistemas elétricos industriais. *São Paulo: Atitude Editorial*, p. 42, 2012. Citado na página 29.
- MISITI, M. et al. *Wavelet Toolbox User's Guide*. 2002. The MathWorks Inc., Natick, MA, USA. Citado na página 44.
- NANDI, A.; AHMED, H. Condition monitoring with vibration signals: Compressive sampling and learning algorithms for rotating machine. In: _____. John Wiley & Sons, Ltd, 2019. cap. 5, p. 79–114. ISBN 9781119544678. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/9781119544678.ch5>>. Citado na página 44.
- NELSON, J. P.; SEN, P. K. High-resistance grounding of low-voltage systems: A standard for the petroleum and chemical industry. *IEEE Transactions on Industry Applications*, IEEE, v. 35, n. 4, p. 941–948, 1999. Citado na página 19.
- PAUL, D. Phase-ground fault current analysis and protection of a high-resistance grounded power system. *IEEE Transactions on Industry Applications*, IEEE, 2020. Citado 2 vezes nas páginas 26 e 28.
- ROBERTS, J. et al. Análise dos métodos de proteção contra faltas à terra nos sistemas da distribuição aterrados, não aterrados e compensados. *Schweitzer Engineering Laboratories, Inc., Pullman, WA USA*, 2001. Citado na página 98.
- ROCA, R. G. A general formulation for computational design of grounding systems in underground electrical substations. 2018. Citado na página 98.
- RUDER, S. An overview of gradient descent optimization algorithms. In: . [S.l.: s.n.], 2016. Citado na página 43.
- SAMANFAR, A.; MAHAMED, B. Directional high-resistance earth fault detector based on zero-sequence components and wavelet transform. In: IEEE. *2010 IEEE International Conference on Power and Energy*. [S.l.], 2010. p. 151–155. Citado na página 23.
- SATO, F.; FREITAS, W. Análise de curto-circuito e princípios de proteção em sistemas de energia elétrica. *Rio de Janeiro: Elsevier*, 2015. Citado na página 99.
- SCHWEITZER. *SEL-849 Motor Management Relay*. 2020. Disponível em: <<https://bitly.com/8VKJy>>. Acesso em: 27 dez. 2020. Citado 2 vezes nas páginas 31 e 33.

- SELVA. Cnn classifier using 1d, 2d and 3d feature vectors. In: <https://in.mathworks.com/matlabcentral/fileexchange/68882-cnn-classifier-using-1d-2d-and-3d-feature-vectors>. [S.l.]: MathWorks, 2021. Citado na página 54.
- SENIOR ENGENHARIA. *Sistema de pesquisa online do local onde ocorreu uma falta fase-terra limitada através de resistores de alto valor ohmico*. 2020. Disponível em: <<http://seniorengenharia.com.br/wp-content/uploads/2018/06/USC.pdf>>. Acesso em: 27 dez. 2020. Citado 2 vezes nas páginas 31 e 32.
- SHANNON, C. E. A mathematical theory of communication. *The Bell system technical journal*, Nokia Bell Labs, v. 27, n. 3, p. 379–423, 1948. Citado na página 45.
- SILVA, J. M. P. L. Aplicação da transformada wavelet packet e redes neurais artificiais para monitoramento de condição de motores de indução. Universidade Federal de Pernambuco, 2017. Citado na página 23.
- SOBRINHO, C. A. N. Estudo comparativo de técnicas para diagnóstico de falhas em motores de indução trifásicos. Universidade Federal da Paraíba, 2015. Citado na página 16.
- STRANG, G.; NGUYEN, T. *Wavelet and Filter Banks*. [S.l.]: Wellesley: Cambridge Press, 1996. Citado na página 44.
- SUJATHA, C. *Vibration and Acoustics Measurement and Signal Analysis*. [S.l.]: Tata McGraw-Hill Education, 2010. Citado na página 36.
- SUPARWITO, H. Factors influencing the difficulty level of the subject: Machine learning technique approaches. *International Journal of Applied Sciences and Smart Technologies*, v. 1, n. 1, p. 65–82, 2019. Citado na página 41.
- SUTSKEVER, I. et al. On the importance of initialization and momentum in deep learning. In: PMLR. *International conference on machine learning*. [S.l.], 2013. p. 1139–1147. Citado na página 43.
- TAO, Q. et al. Air pollution forecasting using a deep learning model based on 1d convnets and bidirectional gru. *IEEE access*, IEEE, v. 7, p. 76690–76698, 2019. Citado na página 42.
- TAQI, A. M. et al. The impact of multi-optimizers and data augmentation on tensorflow convolutional neural network performance. In: IEEE. *2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*. [S.l.], 2018. p. 140–145. Citado na página 43.
- TOPOLANEK, D. et al. Earth fault location based on evaluation of voltage sag at secondary side of medium voltage/low voltage transformers. *IET Generation, Transmission & Distribution*, IET, v. 9, n. 14, p. 2069–2077, 2015. Citado 2 vezes nas páginas 21 e 22.
- VALDES, M.; PAPALLO, T.; PREMERLANI, B. Ground fault location in low-voltage high-resistance grounded systems via the single-processor concept for circuit protection. In: IEEE. *Conference Record of 2006 Annual Pulp and Paper Industry Technical Conference*. [S.l.], 2006. p. 1–8. Citado 3 vezes nas páginas 21, 23 e 32.
- WARD. *Tipos de transformadores de corrente tipo janela*. 2020. Disponível em: <<http://www.ward.com.br/trafocorrente.html>>. Acesso em: 27 dez. 2020. Citado na página 30.
- WEBB, A. R. *Statistical pattern recognition*. [S.l.]: John Wiley & Sons, 2003. Citado 2 vezes nas páginas 37 e 38.

WIDODO, A. et al. Intelligent fault diagnosis system of induction motor based on transient current signal. *Mechatronics*, Elsevier, v. 19, n. 5, p. 680–689, 2009. Citado na página 24.

Apêndices

APÊNDICE A – Resultados dos Modelos

Resultados classificação com *STFT*+Descritores EstatísticosTabela 1 – Testes utilizando *STFT* Janela Gaussiana de tamanhos 128, 256 e 512

Gaussiano - Janela 128				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
DT	86,957	88,679	<missing>	94,000
1-NN	82,609	81,132	16,667	89,362
3-NN	78,261	88,679	<missing>	94,000
5-NN	86,957	88,679	<missing>	94,000
SVM	86,957	88,679	<missing>	94,000
RF	69,565	83,019	30,769	90,323

Gaussiano - Janela 256				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
DT	86,957	71,698	34,783	81,928
1-NN	86,957	84,906	<missing>	91,837
3-NN	78,261	88,679	<missing>	94,000
5-NN	86,957	88,679	<missing>	94,000
SVM	86,957	88,679	<missing>	94,000
RF	78,261	77,359	333333,000	86,364

Gaussiano - Janela 512				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
DT	73,913	88,679	<missing>	94,000
1-NN	73,913	83,019	<missing>	90,722
3-NN	86,957	88,679	<missing>	94,000
5-NN	86,957	88,679	<missing>	94,000
SVM	86,957	88,679	<missing>	94,000
RF	73,913	75,472	23,529	85,393

Tabela 2 – Testes utilizando *STFT* Janela *Hamming* de tamanhos 128, 256 e 512

Hamming - Janela 128				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
DT	86,957	81,132	<missing>	89,583
1-NN	78,261	69,811	20,000	81,395
3-NN	86,957	88,679	<missing>	94,000
5-NN	86,957	88,679	<missing>	94,000
SVM	86,957	88,679	<missing>	94,000
RF	78,261	83,019	<missing>	90,722

Hamming - Janela 256				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
DT	69,565	88,679	<missing>	94,000
1-NN	69,565	84,906	20,000	91,667
3-NN	86,957	88,679	<missing>	94,000
5-NN	86,957	88,679	<missing>	94,000
SVM	86,957	88,679	<missing>	94,000
RF	82,609	86,793	<missing>	92,929

Hamming - Janela 512				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
DT	82,609	66,038	10,000	79,070
1-NN	82,609	73,585	12,500	84,444
3-NN	78,261	88,679	<missing>	94,000
5-NN	86,957	88,679	<missing>	94,000
SVM	86,957	88,679	<missing>	94,000
RF	78,261	75,472	13,333	85,714

Tabela 3 – Testes utilizando *STFT* Janela *Hanning* de tamanhos 128, 256 e 512

Hanning - Janela 128				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
DT	86,957	79,245	<missing>	88,421
1-NN	82,609	69,811	20,000	81,395
3-NN	86,957	88,679	<missing>	94,000
5-NN	86,957	88,679	<missing>	94,000
SVM	86,957	88,679	<missing>	94,000
RF	78,261	79,245	266667,000	87,912

Hanning - Janela 256				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
DT	78,261	79,245	<missing>	88,421
1-NN	69,565	83,019	<missing>	90,722
3-NN	82,609	88,679	<missing>	94,000
5-NN	86,957	88,679	<missing>	94,000
SVM	86,957	88,679	<missing>	94,000
RF	78,261	86,793	<missing>	92,929

Hanning - Janela 512				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
DT	78,261	75,472	23,529	85,393
1-NN	73,913	67,925	10,526	80,460
3-NN	78,261	86,793	22,222	92,784
5-NN	86,957	88,679	<missing>	94,000
SVM	86,957	88,679	<missing>	94,000
RF	82,609	81,132	16,667	89,362

Resultados para classificação com descritores obtidos por *MODWT*Tabela 4 – Testes utilizando *MODWT* com filtros *Coif1*, *Sym8* e *Db4* + Descritores Estatísticos

MODWT Coif1+ Estatístico				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
SVM	94,102	93,082	56,000	96,246
DT	91,421	96,855	84,849	98,246
1-NN	92,761	95,598	77,419	97,561
3-NN	94,638	95,598	77,419	97,561
5-NN	95,711	96,855	83,871	98,258
RF	94,638	96,226	80,000	97,917

MODWT Sym8+ Estatístico				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
SVM	93,030	92,453	45,455	95,946
DT	94,370	93,082	62,069	96,194
1-NN	94,638	92,453	60,000	95,833
3-NN	96,783	93,082	62,069	96,194
5-NN	95,174	94,969	71,429	97,241
RF	95,442	94,340	66,667	96,907

MODWT Db4+ Estatístico				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
SVM	94,906	93,082	66,667	96,140
DT	94,906	91,824	62,857	95,406
1-NN	94,102	94,969	77,778	97,163
3-NN	95,979	94,969	73,333	97,222
5-NN	95,979	95,598	77,419	97,561
RF	95,174	94,340	68,966	96,886

Tabela 5 – Testes utilizando *MODWT* com filtros *Coif1*, *Sym8* e *Db4* + *Shannon*

MODWT Coif1 + Shannon				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
SVM	89,544	89,308	<missing>	94,352
DT	89,812	88,050	24,000	93,515
1-NN	83,914	85,535	30,303	91,930
3-NN	89,276	90,566	34,783	94,915
5-NN	90,617	89,937	20,000	94,631
RF	83,914	85,535	30,303	91,930

MODWT Sym8 + Shannon				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
SVM	89,276	89,937	<missing>	94,702
DT	90,080	89,937	20,000	94,631
1-NN	83,646	89,308	26,087	94,237
3-NN	89,544	89,937	20,000	94,631
5-NN	90,080	90,566	21,053	94,983
RF	83,914	89,308	26,087	94,237

MODWT Db4 + Shannon				
Acurácia			f1-score	
Classif.	Treino	Teste	Falha	Normal
SVM	89,544	89,308	<missing>	94,352
DT	90,885	90,566	34,783	94,915
1-NN	83,646	86,164	26,667	92,361
3-NN	89,544	88,679	25,000	93,878
5-NN	89,812	90,566	28,571	94,950
RF	84,987	86,164	26,667	92,361

Resultados para classificação com descritores obtidos por PCA

Inicialmente, as componentes principais da matriz de dados originais, extraídas com a aplicação da *PCA* foram utilizadas como descritores para a obtenção dos modelos. Nesse caso, deseja-se avaliar o desempenho dos modelos a partir de um formato reduzido dos dados diretamente obtidos do processo. Para garantir que a quase totalidade das informações relevantes se mantenham na forma reduzida dos dados originais, foi assegurado que, no mínimo 95% da variabilidade contida na base de dados original fosse preservada na forma reduzida. A coluna 3 da Tabela 6, mostra as dimensões das matrizes de descritores por classes, obtidos com a aplicação da *PCA* sobre o conjunto original. Importante destacar que a extração das componentes principais utilizadas para a modelagem foi realizada posteriormente ao particionamento dos conjuntos de treino e teste, não havendo portanto influência do conjunto de treino sobre o de teste.

Tabela 6 – Dimensão das matrizes originais e com PCA


Classes	Matrizes de atributos	
	Original	PCA
Normal	6700x10000	6700x1817
Falha	900x10000	900x1817

Na Figura 1 é possível observar a variabilidade explicada pelas 10 primeiras componentes principais. Como pode ser notado as duas primeiras componentes são responsáveis por 81,79% da representatividade dos dados, sendo as contribuições das demais componentes praticamente desprezíveis. Para assegurar o percentual mínimo de 95% da variabilidade do conjunto de dados, foram utilizadas 1817 componentes. A fim de apresentar a distribuição dos dados, na Figura 2 é mostrada a relação das duas principais componentes supracitadas. Visualmente, a princípio, os dados não parecem ter boa separabilidade e isto será verificado com o uso das técnicas de aprendizagem de máquina.

O resultado da etapa de classificação está apresentado na Tabela 7. O classificador *DT* obteve 92,90% de acurácia e 83,79% de *f1-score*. Todos os classificadores implementados com o algoritmo *k-NN*, nas configurações com 1, 3 e 5 vizinhos, tiveram desempenho ruins, e apresentaram os mesmos valores de acurácia e *f1-score*, sendo 14,60% e 13,54% respectivamente. O classificador *SVM* alcançou 88,15% de acurácia e não obteve um valor de *f1-score* válido (NaN). Isso é explicado pelo fato do modelo não ter acertado nenhum valor da classe em falha na etapa de teste do classificador (Figura 3).


O melhor resultado dos testes com os descritores obtidos diretamente com a *PCA*, foi alcançado com o classificador implementado pelo algoritmo *RF*, com 98,25% de acurácia e 95,51% de *f1-score*. Estes resultados demonstram um desempenho eficaz para o modelo utilizado que possui a vantagem de não ser necessário a escolha manual das características. Os melhores resultados na

Figura 1 – Variabilidade explicada dos componentes extraídos com PCA.



Fonte: Autoria Própria

Figura 2 – Espaço amostral com duas componentes principais obtidas com PCA.



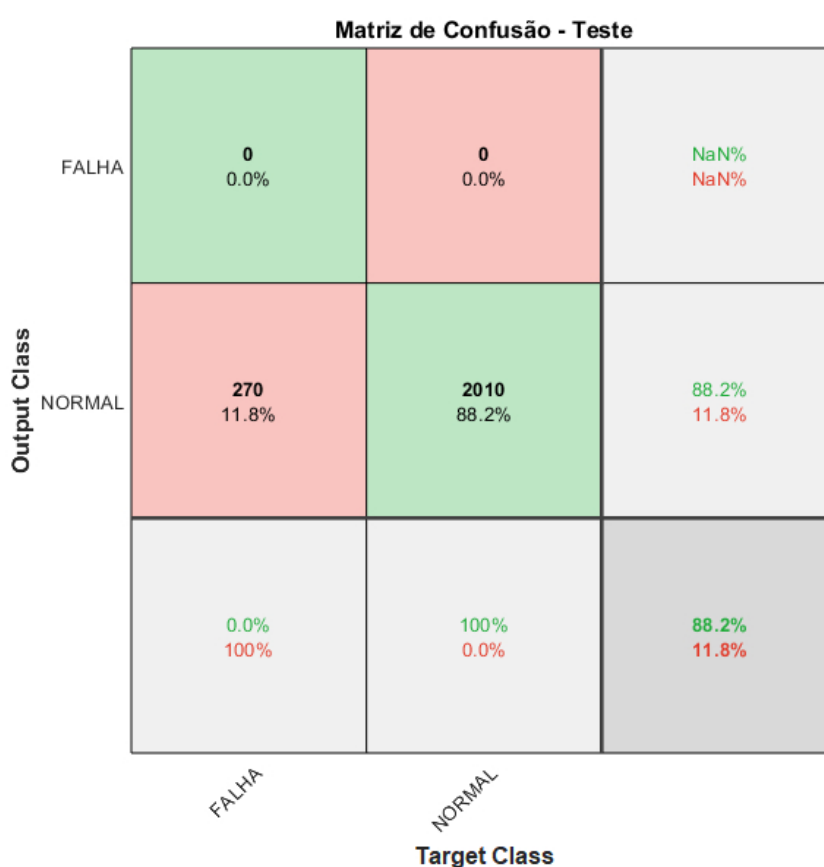
Fonte: Autoria Própria

classificação com os descritores oriundos da *PCA* foram obtidos pelos classificadores construídos com a *DT* e *RF*, que são estratégias de classificação baseadas no particionamento do espaço amostral. Essas estratégias são utilizadas para otimizar o problema de classificação, e reduzem

Tabela 7 – Resultados com PCA

Classif.	Acurácia		f1-score	
	Treino	Teste	Falha	Normal
DT	95,20	92,90	71,60	95,97
1-NN	14,57	14,30	21,65	5,42
3-NN	14,61	14,30	21,65	5,42
5-NN	14,64	14,25	21,64	5,33
SVM	88,16	88,15	NaN	93,70
RF	98,63	98,25	92,00	99,01

Figura 3 – Matriz de confusão algoritmo SVM com PCA.



Fonte: Autoria Própria

problemas complexos em vários problemas de solução mais simples.

Resultados para classificação com descritores obtidos descritores estatísticos no domínio do tempo

Tabela 8 – Resultados descritores estatísticos

Classif.	Acurácia		f1-score	
	Treino	Teste	Falha	Normal
DT	97,40	94,70	66,67	97,14
1-NN	91,30	96,20	80,00	97,92
3-NN	96,30	95,45	66,67	97,56
5-NN	98,15	95,45	66,67	97,56
SVM	96,30	95,45	66,67	97,56
RF	94,40	96,20	80,00	97,92

Resultados para classificação com descritores estatísticos no domínio tempo/escala com filtro Db4

Tabela 9 – Resultados com os classificadores *DT*, *SVM* e *RF* - Db4 + Estatísticos

Classificador	Coeficientes	Db4			
		Treino	Teste	f1 falha	f1 normal
DT	ca1	95,35	95,26	78,40	97,34
	cd1	98,72	98,38	92,64	99,09
	cd2	98,78	98,33	92,46	99,06
	cd3	98,74	98,33	92,46	99,06
	cd4	98,70	98,29	92,28	99,04
	cd5	98,10	97,89	90,44	98,82
	cd6	97,80	97,41	87,89	98,55
	cd7	93,83	93,80	66,35	96,62
	cd8	93,23	93,38	65,45	96,34
	cd9	95,06	95,22	76,56	97,34
SVM	ca1	96,90	96,90	85,77	98,31
	cd1	98,76	98,38	92,64	99,09
	cd2	98,80	98,38	92,64	99,09
	cd3	98,78	98,38	92,64	99,09
	cd4	98,78	98,38	92,64	99,09
	cd5	98,12	97,94	90,54	98,84
	cd6	97,82	97,24	87,01	98,45
	cd7	95,26	94,91	74,22	97,18
	cd8	93,91	93,33	64,15	96,32
	cd9	95,92	96,45	82,66	98,02
RF	ca1	97,30	97,28	87,40	98,48
	cd1	98,82	98,38	92,64	99,09
	cd2	98,78	98,38	92,64	99,09
	cd3	98,82	98,38	92,64	99,09
	cd4	98,82	98,38	92,64	99,09
	cd5	98,29	97,98	90,73	98,87
	cd6	98,08	97,46	88,07	98,58
	cd7	94,92	94,87	74,73	97,14
	cd8	93,97	94,04	69,51	96,69
	cd9	96,03	96,32	82,79	97,94

Tabela 10 – Resultados com o classificador k -NN com 1-NN, 3-NN e 5-NN - Db4 + Estatísticos

Classificador	Coeficientes	Db4			
		Treino	Teste	f1 falha	f1 normal
1-NN	ca1	95,06	94,87	77,54	97,10
	cd1	97,59	97,02	87,27	98,31
	cd2	97,31	96,40	85,96	97,96
	cd3	97,26	96,80	86,36	98,19
	cd4	96,69	96,49	84,50	98,02
	cd5	96,11	95,88	81,92	97,67
	cd6	95,21	95,39	79,61	97,40
	cd7	90,90	90,31	55,53	94,56
	cd8	90,32	89,96	54,83	94,35
	cd9	93,87	93,95	73,76	96,58
3-NN	ca1	96,30	96,10	82,18	97,92
	cd1	98,57	98,16	91,67	98,96
	cd2	98,65	98,20	91,91	98,99
	cd3	98,36	98,07	91,30	98,91
	cd4	97,61	97,15	86,65	98,40
	cd5	97,31	96,71	84,73	98,16
	cd6	96,48	95,88	80,89	97,69
	cd7	92,84	92,72	61,57	95,98
	cd8	93,25	92,76	62,07	96,00
	cd9	95,45	95,88	80,89	97,69
5-NN	ca1	96,00	96,00	83,44	98,07
	cd1	98,67	98,29	92,22	99,04
	cd2	98,61	98,29	92,28	99,04
	cd3	98,35	98,07	91,24	98,92
	cd4	97,56	97,11	86,31	98,38
	cd5	96,94	96,80	85,25	98,20
	cd6	96,48	95,88	80,74	97,69
	cd7	92,86	92,32	58,23	95,77
	cd8	93,63	93,11	62,88	96,20
	cd9	95,77	95,75	80,00	97,62

Resultados para classificação com descritores estatísticos no domínio tempo/escala com filtro Sym8

Tabela 11 – Resultados com os classificadores *DT*, *SVM* e *RF* - Sym8 + Estatísticos

Classificador	Coeficientes	Sym8			
		Treino	Teste	f1 normal	f1 falha
DT	ca1	95,62	95,70	79,41	97,60
	cd1	98,48	98,86	94,96	99,36
	cd2	98,60	98,60	93,73	99,21
	cd3	98,50	98,86	94,36	99,36
	cd4	98,57	98,68	94,14	99,26
	cd5	97,63	97,80	90,42	98,76
	cd6	98,18	98,38	92,79	99,09
	cd7	93,91	93,11	62,71	96,21
	cd8	93,63	93,90	68,90	96,62
SVM	ca1	96,60	97,06	86,30	98,35
	cd1	98,57	98,90	95,15	99,38
	cd2	98,70	98,60	93,70	99,21
	cd3	98,57	98,90	95,16	99,38
	cd4	98,60	98,60	94,14	99,26
	cd5	97,71	98,25	92,13	99,01
	cd6	98,23	98,23	92,61	99,06
	cd7	95,09	94,96	74,39	97,20
	cd8	94,21	94,47	70,42	96,95
RF	ca1	96,95	96,84	85,60	98,23
	cd1	98,59	98,90	95,15	99,38
	cd2	98,72	98,60	93,70	99,21
	cd3	98,57	98,95	95,35	99,41
	cd4	98,67	98,73	94,32	99,28
	cd5	97,84	98,07	91,41	98,91
	cd6	98,40	98,40	93,10	99,14
	cd7	94,74	97,12	71,73	96,72
	cd8	94,55	94,43	72,09	96,91
cd9	96,73	96,58	84,21	98,08	

Tabela 12 – Resultados com o classificador k -NN com 1-NN, 3-NN e 5-NN - Sym8 + Estatísticos

Classificador	Coeficientes	Sym8			
		Treino	Teste	f1 normal	f1 falha
1-NN	ca1	94,96	95,04	78,96	97,19
	cd1	97,24	97,85	90,94	98,78
	cd2	97,24	97,89	90,84	98,81
	cd3	96,67	97,11	88,00	98,35
	cd4	96,18	96,75	86,04	98,16
	cd5	95,62	95,66	81,97	97,53
	cd6	95,51	96,32	84,09	97,92
	cd7	90,94	89,91	55,08	94,32
	cd8	90,62	90,57	57,93	94,69
	cd9	94,21	94,47	76,67	96,87
3-NN	ca1	96,05	96,36	83,16	97,96
	cd1	98,48	98,64	94,05	99,23
	cd2	98,46	98,38	92,70	99,09
	cd3	98,06	98,55	93,59	99,18
	cd4	97,50	97,76	89,86	98,74
	cd5	96,94	97,02	86,67	98,32
	cd6	96,40	96,40	84,13	98,03
	cd7	92,80	91,93	56,19	95,56
	cd8	93,03	93,77	67,13	96,56
	cd9	96,02	96,01	81,62	97,76
5-NN	ca1	96,20	96,40	82,99	97,99
	cd1	98,48	98,82	94,76	99,33
	cd2	98,52	98,38	92,67	99,09
	cd3	98,06	98,06	93,77	99,21
	cd4	97,41	97,89	90,40	98,82
	cd5	96,79	96,93	86,11	98,27
	cd6	96,64	96,58	84,21	98,08
	cd7	92,59	92,46	57,64	95,86
	cd8	93,44	93,42	62,87	96,39
	cd9	96,17	96,17	81,76	97,87

Resultados para classificação com descritores estatísticos no domínio tempo/escala com filtro Coif1

Tabela 13 – Resultados com os classificadores *DT*, *SVM* e *RF* - Coif1 + Estatísticos

Classificador	Coeficientes	Coif1			
		Treino	Teste	f1 normal	f1 falha
DT	ca1	95,68	98,26	78,05	97,35
	cd1	98,52	98,64	93,96	99,23
	cd2	98,46	98,77	94,55	99,31
	cd3	98,68	98,55	93,52	99,19
	cd4	98,67	98,38	92,76	99,09
	cd5	97,71	97,37	87,85	98,52
	cd6	98,25	98,25	92,09	99,01
	cd7	93,36	93,68	66,51	96,51
	cd8	93,74	93,77	69,40	96,53
SVM	ca1	96,67	97,11	86,48	98,38
	cd1	98,67	98,73	94,32	99,28
	cd2	98,61	98,77	94,55	99,31
	cd3	98,70	98,60	93,70	99,21
	cd4	98,70	98,51	93,31	99,16
	cd5	98,03	97,68	89,29	98,70
	cd6	98,25	98,25	92,16	99,01
	cd7	95,21	94,91	73,87	97,18
	cd8	94,36	94,91	73,64	97,18
cd9	96,62	96,67	84,23	98,14	
RF	ca1	96,77	97,02	86,12	98,33
	cd1	98,63	98,68	94,14	99,26
	cd2	98,63	98,82	94,74	99,33
	cd3	98,70	98,60	93,70	99,21
	cd4	98,74	98,55	93,49	99,19
	cd5	97,89	97,68	89,29	98,70
	cd6	98,35	98,46	93,15	99,14
	cd7	94,68	94,61	73,20	97,00
	cd8	94,53	94,82	74,12	97,12
cd9	96,77	96,62	84,32	98,11	

Tabela 14 – Resultados com o classificador k -NN com 1-NN, 3-NN e 5-NN - Coif1 + Estatísticos

Classificador	Coeficientes	Coif1			
		Treino	Teste	f1 normal	f1 falha
1-NN	ca1	94,66	95,44	79,69	97,43
	cd1	97,29	97,59	89,8	98,63
	cd2	97,44	97,44	89,34	98,56
	cd3	97,05	96,67	86,03	98,11
	cd4	96,56	96,58	85,39	98,06
	cd5	95,96	94,91	78,44	97,12
	cd6	96,6	95,75	81,73	97,59
	cd7	90,58	90,48	57,86	94,64
	cd8	90,75	90,7	59,7	94,74
3-NN	ca1	96,24	96,49	83,12	98,04
	cd1	98,61	98,68	94,14	99,26
	cd2	98,42	98,55	93,59	99,18
	cd3	98,18	98,20	91,94	98,99
	cd4	97,50	97,63	89,33	98,67
	cd5	97,01	96,75	85,20	98,18
	cd6	96,60	96,84	85,77	98,22
	cd7	92,86	92,28	60,36	95,75
	cd8	92,82	93,25	65,32	96,26
5-NN	ca1	96,09	96,49	82,98	98,04
	cd1	98,55	98,68	94,12	99,26
	cd2	98,40	98,51	93,36	99,16
	cd3	98,16	98,07	91,30	98,91
	cd4	97,46	97,76	89,90	98,74
	cd5	96,95	96,93	85,77	98,28
	cd6	96,60	96,84	85,48	98,23
	cd7	92,69	92,15	58,28	95,67
	cd8	93,36	93,64	66,51	96,49
cd9	96,45	96,18	82,14	97,86	

**Resultados para classificação com descritores entropia de Shannon no domínio tempo/escala
com filtro Db4**

Tabela 15 – Resultados com os classificadores *DT*, *SVM* e *RF* - Db4 + Shannon

Classificador	Coeficientes	Db4			
		Treino	Teste	f1 falha	f1 normal
DT	ca1	94,27	93,73	68,29	96,52
	cd1	98,53	98,68	94,16	99,26
	cd2	98,55	98,86	94,94	99,36
	cd3	98,55	98,77	94,57	99,31
	cd4	98,70	98,51	93,33	99,16
	cd5	97,31	97,15	86,43	98,41
	cd6	97,69	97,59	88,84	98,65
	cd7	93,78	93,25	64,84	96,26
	cd8	92,58	92,68	60,33	95,97
SVM	ca1	93,67	93,42	64,95	96,37
	cd1	98,65	98,77	94,53	99,31
	cd2	98,61	98,86	94,94	99,36
	cd3	98,61	98,86	94,94	99,36
	cd4	98,72	98,60	93,70	99,21
	cd5	97,42	97,24	86,79	98,46
	cd6	97,78	97,72	89,39	98,72
	cd7	93,68	93,20	62,65	96,26
	cd8	91,97	91,89	48,75	95,59
RF	ca1	90,28	88,82	54,22	93,63
	cd1	97,58	97,89	91,01	98,81
	cd2	97,27	97,76	90,57	98,73
	cd3	97,37	97,63	90,04	98,66
	cd4	97,54	97,59	89,64	98,63
	cd5	94,96	94,39	76,56	96,81
	cd6	96,09	95,75	82,20	97,58
	cd7	89,14	89,30	54,31	93,94
	cd8	86,97	87,76	46,45	93,09
cd9	91,84	92,19	66,03	95,59	

Tabela 16 – Resultados com o classificador k -NN com 1-NN, 3-NN e 5-NN - Db4 + Shannon

Classificador	Coeficientes	Db4			
		Treino	Teste	f1 falha	f1 normal
1-NN	ca1	90,32	88,82	54,22	93,63
	cd1	97,44	97,85	90,84	98,78
	cd2	97,05	97,76	90,57	98,73
	cd3	97,33	97,63	90,04	98,66
	cd4	97,52	97,59	89,64	98,63
	cd5	94,81	94,39	76,56	96,81
	cd6	96,00	95,75	82,20	97,58
	cd7	88,97	89,30	54,31	93,94
	cd8	87,07	87,76	46,45	93,09
	cd9	91,88	92,19	66,03	95,59
3-NN	ca1	93,40	92,76	64,67	95,97
	cd1	97,44	97,85	90,84	98,78
	cd2	97,05	97,76	90,57	98,73
	cd3	97,33	97,63	90,04	98,66
	cd4	97,52	97,59	89,64	98,63
	cd5	94,81	94,39	76,56	96,81
	cd6	96,00	95,75	82,20	97,58
	cd7	88,97	89,30	54,31	93,94
	cd8	87,07	87,76	46,45	93,09
	cd9	91,88	92,19	66,03	95,59
5-NN	ca1	94,02	93,51	66,96	96,40
	cd1	97,44	97,85	90,84	98,78
	cd2	97,05	97,76	90,57	98,73
	cd3	97,33	97,63	90,04	98,66
	cd4	97,52	97,59	89,64	98,63
	cd5	94,81	94,39	76,56	96,81
	cd6	96,00	95,75	82,20	97,58
	cd7	88,97	89,30	54,31	93,94
	cd8	87,07	87,76	46,45	93,09
	cd9	91,88	92,19	66,03	95,59

Resultados para classificação com descritores entropia de Shannon no domínio tempo/escala com filtro Sym8

Tabela 17 – Resultados com os classificadores *DT*, *SVM* e *RF* - Sym8 + Shannon

Classificador	Coeficientes	Sym8			
		Treino	Teste	f1 falha	f1 normal
DT	ca1	93,83	94,39	71,93	96,88
	cd1	98,61	98,60	93,75	99,21
	cd2	98,46	98,95	95,37	99,41
	cd3	98,74	98,42	92,89	99,11
	cd4	98,53	98,68	94,12	99,26
	cd5	97,33	97,11	86,13	98,38
	cd6	97,82	97,28	87,40	98,48
	cd7	93,83	92,94	62,30	96,10
	cd8	92,99	91,93	55,34	95,56
	cd9	95,19	94,52	73,68	96,94
SVM	ca1	93,46	93,68	66,04	96,52
	cd1	98,68	98,68	94,12	99,26
	cd2	98,55	98,99	95,55	99,43
	cd3	98,78	98,46	93,07	99,14
	cd4	98,68	98,68	94,12	99,26
	cd5	97,44	97,15	86,32	98,41
	cd6	97,80	97,54	88,48	98,63
	cd7	93,50	93,20	61,54	96,27
	cd8	92,27	91,62	48,24	95,44
	cd9	94,96	94,78	73,61	97,10
RF	ca1	88,95	89,74	57,91	94,16
	cd1	97,82	97,32	88,77	98,48
	cd2	97,41	97,85	91,01	98,78
	cd3	97,69	97,37	88,68	98,51
	cd4	97,59	97,15	88,12	98,38
	cd5	94,98	95,31	79,46	97,35
	cd6	96,09	96,40	84,29	97,97
	cd7	89,55	89,78	53,12	94,27
	cd8	88,27	86,80	42,88	92,54
	cd9	91,80	91,62	64,30	95,25

Tabela 18 – Resultados com o classificador k -NN com 1-NN, 3-NN e 5-NN - Sym8 + Shannon

Classificador	Coeficientes	Sym8			
		Treino	Teste	f1 falha	f1 normal
1-NN	ca1	88,82	89,69	57,81	94,13
	cd1	97,73	97,32	88,77	98,48
	cd2	97,37	97,85	91,01	98,78
	cd3	97,78	97,37	88,68	98,51
	cd4	97,58	97,15	88,12	98,38
	cd5	94,89	95,31	79,46	97,35
	cd6	96,00	96,40	84,29	97,97
	cd7	89,25	89,74	53,01	94,24
	cd8	88,35	86,80	42,88	92,54
	cd9	91,67	91,54	64,06	95,20
3-NN	ca1	92,84	93,25	67,78	96,23
	cd1	97,73	97,32	88,77	98,48
	cd2	97,37	97,85	91,01	98,78
	cd3	97,78	97,37	88,68	98,51
	cd4	97,58	97,15	88,12	98,38
	cd5	94,89	95,31	79,46	97,35
	cd6	96,00	96,40	84,29	97,97
	cd7	89,25	89,74	53,01	94,24
	cd8	88,35	86,80	42,88	92,54
	cd9	91,67	91,54	64,06	95,20
5-NN	ca1	93,57	94,25	71,21	96,81
	cd1	97,73	97,32	88,77	98,48
	cd2	97,37	97,85	91,01	98,78
	cd3	97,78	97,37	88,68	98,51
	cd4	97,58	97,15	88,12	98,38
	cd5	94,89	95,31	79,46	97,35
	cd6	96,00	96,40	84,29	97,97
	cd7	89,25	89,74	53,01	94,24
	cd8	88,35	86,80	42,88	92,54
	cd9	91,67	91,54	64,06	95,20

Resultados para classificação com descritores entropia de Shannon no domínio tempo/escala com filtro Coif1

Tabela 19 – Resultados com os classificadores *DT*, *SVM* e *RF* - Coif1 + Shannon

Classificador	Coeficientes	Coif1			
		Treino	Teste	f1 falha	f1 normal
DT	ca1	93,97	94,30	71,74	96,83
	cd1	98,59	98,60	93,75	99,21
	cd2	98,50	98,95	95,37	99,41
	cd3	98,68	98,42	92,89	99,11
	cd4	98,57	98,68	94,12	99,26
	cd5	97,31	97,11	86,13	98,38
	cd6	97,76	97,28	87,40	98,48
	cd7	93,68	92,94	62,30	96,10
	cd8	93,05	91,93	55,34	95,56
	cd9	95,15	94,52	73,68	96,94
SVM	ca1	93,42	93,82	66,82	96,59
	cd1	98,68	98,68	94,12	99,26
	cd2	98,70	98,64	93,91	99,23
	cd3	98,74	98,55	93,49	99,19
	cd4	98,76	98,51	93,28	99,16
	cd5	97,46	97,11	86,13	98,38
	cd6	97,80	97,72	89,39	98,72
	cd7	93,36	93,82	66,35	96,60
	cd8	91,88	92,24	52,55	95,77
	cd9	94,76	95,22	76,25	97,34
RF	ca1	89,81	90,09	57,36	94,39
	cd1	97,37	97,98	91,39	98,86
	cd2	97,52	97,54	89,59	98,61
	cd3	97,67	97,19	88,19	98,41
	cd4	97,74	97,41	88,89	98,54
	cd5	95,17	94,21	75,65	96,71
	cd6	96,13	96,18	83,86	97,84
	cd7	89,00	89,30	54,98	93,93
	cd8	87,22	87,54	47,60	92,93
	cd9	91,94	91,14	62,87	94,97

Tabela 20 – Resultados com o classificador k -NN com 1-NN, 3-NN e 5-NN - Coif1 + Shannon

Classificador	Coeficientes	Coif1			
		Treino	Teste	f1 falha	f1 normal
1-NN	ca1	89,74	90,09	57,36	94,39
	cd1	97,35	97,98	91,39	98,86
	cd2	97,59	97,54	89,59	98,61
	cd3	97,61	97,19	88,19	98,41
	cd4	97,73	97,41	88,89	98,54
	cd5	95,21	94,21	75,65	96,71
	cd6	96,03	96,18	83,86	97,84
	cd7	88,82	89,30	54,98	93,93
	cd8	87,22	87,54	47,60	92,93
3-NN	ca1	92,54	92,81	64,81	95,99
	cd1	97,35	97,98	91,39	98,86
	cd2	97,59	97,54	89,59	98,61
	cd3	97,61	97,19	88,19	98,41
	cd4	97,73	97,41	88,89	98,54
	cd5	95,21	94,21	75,65	96,71
	cd6	96,03	96,18	83,86	97,84
	cd7	88,82	89,30	54,98	93,93
	cd8	87,22	87,54	47,60	92,93
5-NN	ca1	93,55	93,77	68,72	96,54
	cd1	97,35	97,98	91,39	98,86
	cd2	97,59	97,54	89,59	98,61
	cd3	97,61	97,19	88,19	98,41
	cd4	97,73	97,41	88,89	98,54
	cd5	95,21	94,21	75,65	96,71
	cd6	96,03	96,18	83,86	97,84
	cd7	88,82	89,30	54,98	93,93
	cd8	87,22	87,54	47,60	92,93
cd9	91,97	91,10	62,89	94,94	

Resultados classificação com Rede Neural Convolutacional

Tabela 21 – Resultados com otimizador *SGDM*

N° Filtros	Precisão	Revocação	f1-score
5	98,74	90,37	94,03
10	97,93	94,83	96,31
20	99,10	93,15	95,87
40	98,42	92,19	95,14
80	97,81	87,01	91,96

Tabela 37 – Resultados com otimizador *RMSPROP*

N° Filtros	Precisão	Revocação	f1-score
5	97,09	82,11	88,47
10	100,00	100,00	100,00
20	97,87	99,70	98,76
40	99,95	99,63	99,79
80	100,00	100,00	100,00

Tabela 38 – Resultados com otimizador *ADAM*

N° Filtros	Precisão	Revocação	f1-score
5	95,37	98,96	97,07
10	99,83	98,70	99,26
20	98,04	94,30	96,07
40	91,80	98,68	94,86
80	99,53	96,48	97,94

Anexos

ANEXO A – Tipos de Aterramentos em Sistemas Elétricos Industriais

O aterramento pode ser definido como uma estratégia para possibilitar o escoamento de corrente elétrica para o solo sob condições de operação normal ou de falha no sistema elétrico, garantindo a segurança da instalação e de pessoas, evitando choque elétrico (ROCA, 2018). Em termos conceituais, o aterramento consiste na ligação intencional de condutores à terra com os objetivos de:

- Controlar potenciais elétricos de partes metálicas não energizadas;
- Possibilitar o escoamento para a terra das correntes resultantes de falhas em isolamentos, que podem ser causados por sobretensões transisórias ou descargas atmosféricas;
- Propiciar a atuação dos sistemas de proteção elétrica nas condições de circulação de correntes nestes circuitos.


Para a efetiva execução do aterramento de sistemas elétricos industriais, três estratégias podem ser utilizadas. Os sistemas podem ser solidamente aterrados. Nesse caso, o condutor de terra é conectado diretamente à malha de aterramento no solo. Outra possibilidade é a utilização de um resistor de aterramento, que pode ser de baixo valor ôhmico, o que caracteriza os sistemas de aterramento por resistor de baixo, ou de alto valor ôhmico, o que caracteriza os sistemas de aterramento com resistor de alto valor.

Sistemas Solidamente Aterrados

Este tipo de sistema, que também é conhecido como "eficazmente aterrado", possui a característica de todos os neutros do sistema elétrico de potência estarem conectados diretamente à terra (ROBERTS et al., 2001). A Figura 1 apresenta o diagrama de um circuito com o neutro solidamente aterrado, onde é mostrada uma falta a terra na fase "T".

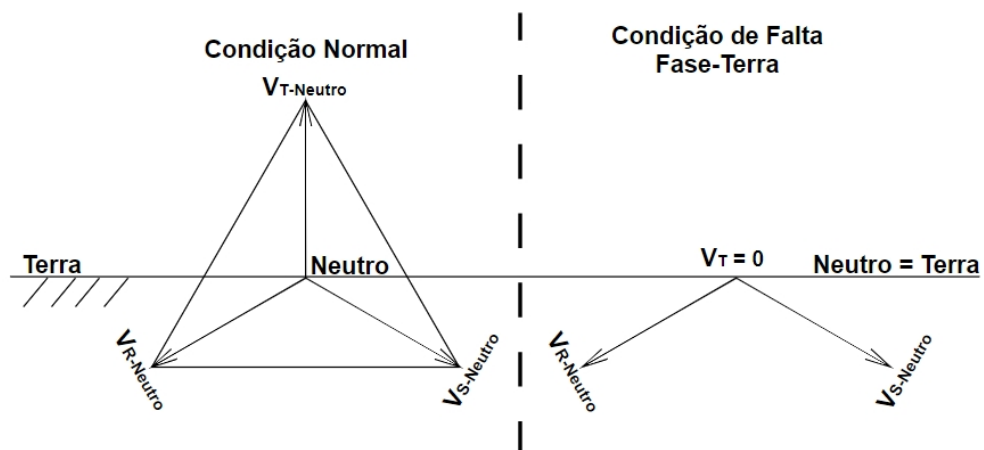
Uma vantagem da aplicação deste tipo de sistema é a capacidade de controle de sobretensões transitórias que possam ocorrer em condições de falta elétrica nas fases que estão em condições normais. A Figura 2 ilustra o deslocamento do neutro em uma mesma condição de falha na fase "T". Pode-se observar que na falta a tensão da fase que tem o contato com a terra, tem seu potencial equipotencializado com a mesma ao valor de zero, enquanto as fases normais não alteram seu valor. Isto demonstra que não há sobretensões neste momento que possam causar danos aos circuitos que são alimentados pelas mesmas.

Figura 1 – Diagrama do sistema solidamente aterrado em condição de falta a terra na fase "T".



Fonte: Autoria própria

Figura 2 – Diagrama de tensões em condição normal e de falta a terra na fase "T".



Fonte: Adaptado de Sato e Freitas (2015)

Em contrapartida, este tipo de esquema favorece o surgimento de altos valores de corrente em eventuais curto-circuitos fase-terra, o que torna fundamental a atuação da proteção elétrica de forma rápida para a interrupção da alimentação (SATO; FREITAS, 2015). Essa situação pode acarretar problemas ao sistema elétrico, pois como são comuns as falhas monofásicas, um número maior de paradas dos equipamentos eventualmente ocorrerá. Este tipo de esquema de aterramento do neutro não é comum em sistemas produtivos críticos, que não podem ser interrompidos contantemente. Para a proteção de falta à terra nestes sistemas elétricos, os autores Dunki e Jacobs (1972), afirmam que devem ser considerados os seguintes aspectos:

- Proteção de arco elétrico nos dispositivos de proteção de fase-terra;
- Seletividade do conjunto de dispositivos constituído pelo dispositivo de proteção de falta à terra e os dispositivos de proteção à jusante;

- Proteção do transformador de alimentação para faltas passantes fase-terra, e faltas à terra nos enrolamentos do secundário do transformador.

A possibilidade da existência de correntes de falta com valores elevados, e a necessidade de se assegurar os fatores de proteção adicionais de forma confiável, têm limitado a utilização desse tipo de aterramento em instalações industriais.


Sistemas Aterrados por Resistor de Baixo Valor

São considerados sistemas aterrados por resistor de baixo valor, aqueles que possuem reator ou um resistor conectado entre o neutro e o terra de forma que haja limitação na corrente de falta fase-terra para valores da ordem de 50A a 600A (BLACKBURN; DOMIN, 2015). Com isso há uma redução significativa do nível de corrente de faltas para a terra, reduzindo custos de alguns componentes físicos desses circuitos. A norma IEEE Std 142 de Committee (2007) cita algumas vantagens no uso de resistência de baixo valor (RBV, ou “*LGR - Low Grounding Resistance*”) no neutro do sistema elétrico:

- Redução de danos por queima nos equipamentos elétricos (painéis, transformadores, cabos e máquinas elétricas rotativas);
- Redução de estresses mecânicos dos condutores no momento da falta;
- Diminuição do risco de choque elétrico causado por correntes de falta à terra;
- Controle de sobretensões transitórias.

Na Figura 3 é apresentado um diagrama de um circuito com o neutro aterrado por meio de um RBV, onde há uma falta a terra na fase "T". Este tipo de aterramento é mais utilizado em sistemas de média tensão. Na baixa tensão é menos usual em função da necessidade de se equipar todos os alimentadores com proteção de falta à terra do tipo *ground sensor*, o que é economicamente inviável. Mas esta perspectiva pode ser alterada em função das novas tecnologias que podem ser utilizadas com conjuntos TCS/*ground sensor* com bobinas de Rogowski (BERNARDI, 2015).

Figura 3 – Diagrama do sistema aterrado por RBV em condição de falta a terra na fase "T".




Fonte: Autoria própria

ANEXO B – Descrição do sistema elétrico onde foi adquirido o conjunto de dados

Muitos sistemas industriais, com o propósito de manter ao máximo o processo produtivo, adotam a configuração de aterramento por resistor de alto valor no neutro dos transformadores de distribuição. Esse resistor limita a corrente que circulará em uma eventual falta à terra, mantendo em operação a carga afetada, não impactando, a princípio, o processo produtivo. Os dados utilizados nesse estudo foram obtidos em uma planta de celulose onde é adotado o aterramento do neutro por RAV. Todas as cargas em baixa tensão são alimentadas por transformadores de 2 MVA de potência, na configuração triângulo-estrela, sendo o primário alimentado por 13.800V e o secundário com uma tensão de 460V. A estrutura do sistema estudado é apresentado na Figura 1, onde pode ser visto o transformador que alimenta um Centro de Distribuição de Cargas (CDC), que por sua vez alimenta o Centro de Controle de Motores (CCM), que é protegido por um disjuntor de potência.

Figura 1 – Equipamentos do Sistema Elétrico Utilizado para a Aquisição dos Dados.

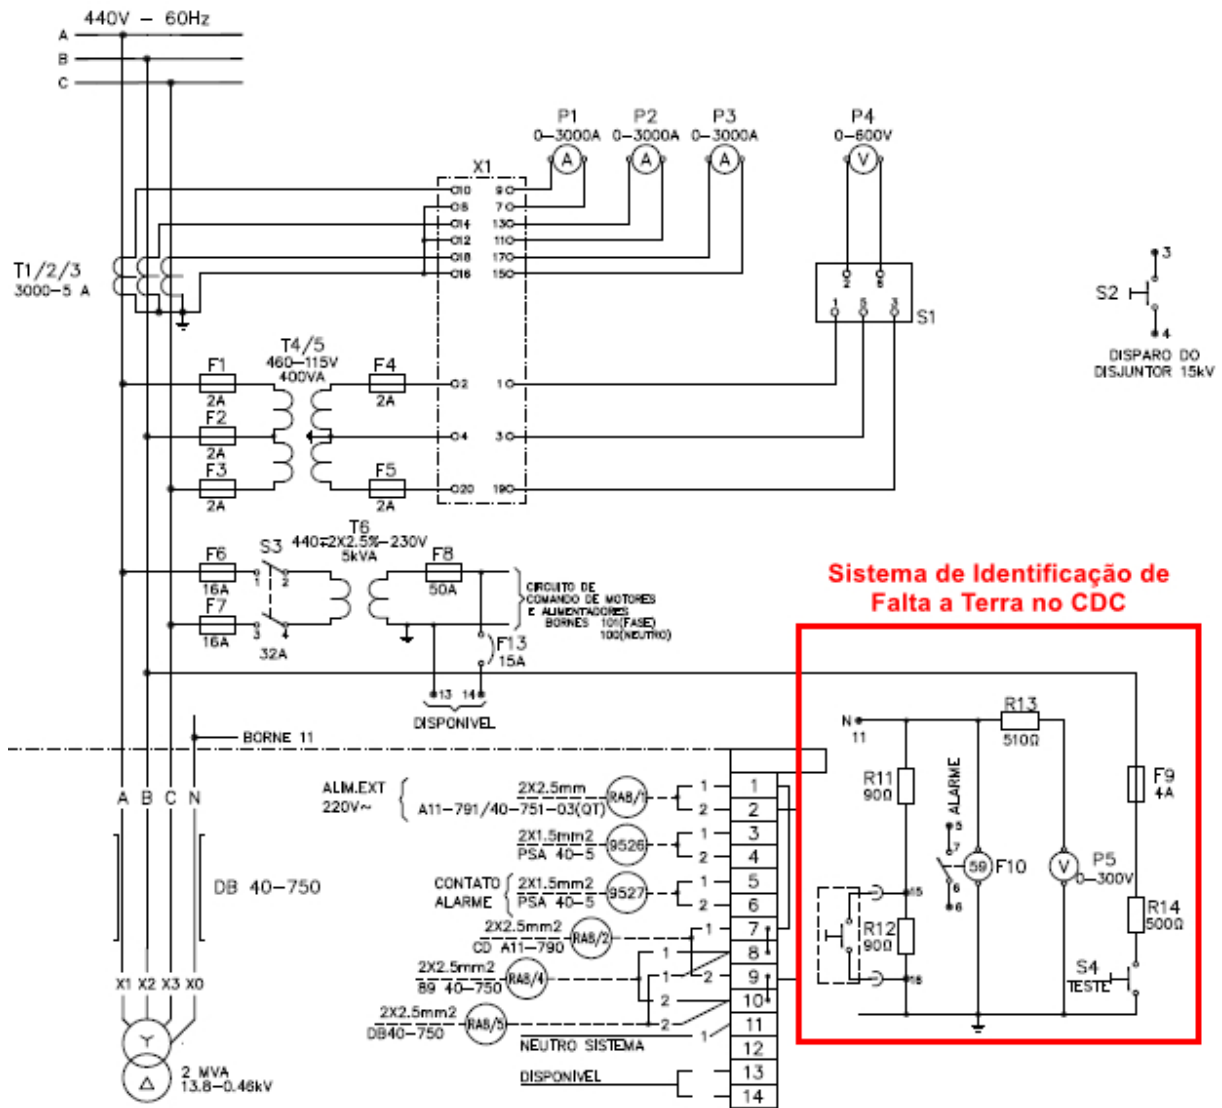


Fonte: Acervo pessoal

Os barramentos de baixa tensão saem do transformador e são conectados diretamente ao CDC, onde o neutro (centro da estrela secundária) é ligado a dois resistores de 90Ω associados em série, totalizando 180Ω interligando o neutro a terra (RAV), conforme apresentado na Figura 2. Neste sistema há um circuito que supervisiona a tensão sobre o conjunto resistivo de aterramento (em destaque na imagem), indicando quando há circulação de corrente de fuga à terra em alguma das cargas alimentadas por essa instalação.

Os resistores que conectam o centro da estrela do transformador ao terra, limitam a corrente de

Figura 2 – Diagrama Elétrico CDC com sistema de aterramento por RAV e supervisão de tensão no Neutro .



Fonte: Acervo pessoal


falta à terra em no máximo 1,47 A conforme apresentado na Equação 1.

$$I_{Neutro} = \frac{V_{Fase-Neutro}}{R_{Neutro}} \rightarrow \frac{265V}{180\Omega} = 1,47A \quad (1)$$

onde I_{Neutro} é a corrente máxima que circulará no neutro, $V_{Fase-Neutro}$ é a tensão de fase do circuito (tensão de linha 460 V dividido por raiz de 3) e R_{Neutro} é o valor total da resistência que interliga o neutro do sistema ao terra. Essa corrente irá variar, dependendo da impedância da falta, por exemplo conforme Figura 3, caso o contato da fase com a terra tenha uma conexão ruim, com impedância de 120Ω , teremos uma corrente de fuga a terra na ordem de 885 mA. O cálculo desta corrente é apresentado na Equação 2.

$$I_{Neutro} = \frac{265V}{180\Omega + 120\Omega} = 0,885A = 885mA. \quad (2)$$

Figura 3 – Exemplo de falta a terra com alta impedância em sistema com aterramento por RAV.




Fonte: Autoria Própria

Essa condição de falta à terra, é uma das condições mais difíceis para a localização da falta à terra com a realização da medição direta de corrente utilizando amperímetro nos cabos de saída dos motores, pois, para valores nessa ordem de grandeza, as correntes de fuga podem ser facilmente confundidas com as correntes capacitivas intrínsecas da instalação, conforme previamente explicado.

Outra característica destas instalações é que quando há a condição de fuga à terra, o relé presente no CDC indica por meio de um led e um contato digital (chave com duas posições) que há sobretensão no neutro. Essa sinalização também pode ser visualizada no painel por meio de um voltímetro presente na instalação, conforme Figura 4. O relé é ajustado para identificar tensões no resistor do neutro superiores a 150 V . O esquema elétrico deste sistema está em destaque na Figura 4.

O CDC deste trabalho alimenta dois CCM's que acionam 148 motores e caso uma destas cargas tenha uma fuga à terra, o sistema do CDC indica que há a presença da falta elétrica, mas não é possível identificar de imediato qual ou quais destas cargas estão em falha, pois as gavetas citadas anteriormente não possuem sistema de detecção de falta à terra individual. Essa configuração é comum em sistemas com mais de 15 anos de operação. Estes sistemas de identificação de fuga à terra de forma individual é muitas vezes economicamente inviável, pois os custos de implantação são elevados.

Figura 4 – Detalhe do relé de sobretensão de neutro e voltímetro do CDC na condição de fuga à terra.



Fonte: Acervo pessoal

ANEXO C – Publicações

- Lucas de O. Soares; Diego A. Lobão; Luiz A. Pinto. “*Intelligent failure monitoring in rotating electrical machines using vibration signals and Machine Learning*”. Artigo submetido para o “*XLI Ibero-Latin-American Congress on Computational Methods in Engineering, CILAMCE*”, ISSN 2675-6269, Novembro de 2020.
- Lucas de O. Soares; Diego A. Lobão; Luiz A. Pinto. “*Aplicação de Machine Learning e Descritores Estatísticos para Diagnóstico de Falhas em Rolamentos de Motores Elétricos Industriais*”. Artigo submetido para o “*XXIII Congresso Brasileiro de Automática*”, <https://doi.org/10.48011/asba.v2i1.1303> Novembro de 2020.
- Lucas de O. Soares; Diego A. Lobão; Luiz A. Pinto. “*Uma abordagem baseada em aprendizado de máquina e descritores estatísticos para o diagnóstico de falhas em rolamentos de máquinas rotativas*”. Artigo publicado como capítulo do Livro “*Engenharia Elétrica: O Mundo sob Perspectivas Avançadas*”, ISBN 978-65-5983-013-8 e DOI 10.22533/at.ed.13821130528. Maio de 2021.
- L. de Oliveira Soares, L. A. Pinto and M. A. de Souza Leite Cuadros, “*Detecção de Fuga à Terra em Sistemas de Neutro aterrado com Resistor de Alto Valor Utilizando Transformada Wavelet e Aprendizado de Máquina*” 2021 14th IEEE International Conference on Industry Applications (INDUSCON), 2021, pp. 447-454, doi: 10.1109/INDUSCON51756.2021.9529729, Agosto de 2021.
- L. de Oliveira Soares, L. A. Pinto and M. A. de Souza Leite Cuadros, “*Aplicação de Aprendizagem de Máquina para Identificar Motores com Fuga à Terra em Sistemas de Neutro aterrado com Resistor de Alto Valor*” 2021 XV Simpósio Brasileiro de Automação Inteligente, ISSN: 2175-8905 , DOI: 10.20906/sbai2021/216476, Outubro de 2021.
- L. de Oliveira Soares, L. A. Pinto and M. A. de Souza Leite Cuadros, “*Uma Arquitetura de Sistema Embarcado Utilizando técnicas de Deep Learning e Sinais de Vibração para Diagnóstico de Falhas em Rolamentos de Motores Elétricos*”, XV Simpósio Brasileiro de Automação Inteligente, ISSN: 2175-8905, DOI: 10.20906/sbai2021/216478, Outubro de 2021.
- L. de Oliveira Soares, L. A. Pinto and M. A. de Souza Leite Cuadros, “*Identificação de motor com fuga a terra em sistemas de baixa tensão de neutro aterrado com RAV utilizando rede neural convolucional*”, Simpósio V Jornada de Integração do Ifes, Outubro de 2021.