

# Aplicação de redes neurais convolucionais e correntes de sequência zero para identificação de motor com fuga a terra em sistemas de baixa tensão de neutro aterrado com RAV

Lucas de Oliveira Soares\* Rodrigo Cesar Campos\*  
Marco Antonio de Souza Leite Cuadros\* Luiz Alberto Pinto\*

\* Instituto Federal do Espírito Santo, Serra, ES, Brasil (e-mail:  
lucassoares@hotmail.com; rodrigoccampos@gmail.com;  
madsouzacuadros@gmail.com; pintoluizalberto@gmail.com).

**Abstract:** This study proposes an approach to identify a ground fault motor in a low voltage three phase electrical system with a High Resistance Grounding (HRG) through the application of deep learning techniques. Electrical systems grounded by high value resistors have the advantage of limiting the leakage current to earth. However, the identification of the equipment that presented the fault is not simple, as such currents can be confused with eddy currents, which may eventually occur in the installation. The proposed method consists of using the zero sequence currents of the equipment in normal operating condition and in the ground fault condition, in order to classify these signals by their characteristics and create a model capable of separating these classes. This approach differs from existing techniques because it uses the fault current signature and not the RMS value. For the elaboration of classification models, raw signals were used for direct input into a one dimensional convolutional neural network. The best result (f1-score of 100.00%) demonstrates the feasibility of implementing the technique in industrial systems for detecting earth leakage equipment in this type of installation.

**Resumo:** Esse trabalho propõe uma abordagem para identificação de motor com fuga à terra, em sistema elétrico trifásico de baixa tensão aterrado com Resistor de Alto Valor ôhmico (RAV) através da aplicação de técnicas de aprendizado. Sistemas elétricos aterrados por resistor de alto valor apresentam a vantagem da limitação da corrente de fuga à terra. Contudo, a identificação do equipamento que apresentou a falha não é simples, pois tais correntes podem ser confundidas com correntes parasitas, que eventualmente possam ocorrer na instalação. O método proposto consiste na utilização das correntes de sequência zero dos equipamentos na condição de operação normal e na condição de falha por fuga à terra, a fim de classificar estes sinais por meio de suas características e criar um modelo capaz de separar estas classes. Essa abordagem se difere das técnicas existentes pelo fato de utilizar a assinatura das correntes de falha e não o valor RMS. Para a elaboração dos modelos de classificação, os sinais brutos foram utilizados para entrada direta em uma rede neural convolucional unidimensional. O melhor resultado (*f1-score* de 100,00%) demonstra a viabilidade da implementação da técnica em sistemas industriais para a detecção de equipamentos com fuga à terra neste tipo de instalação.

**Keywords:** bearing; fault; wavelet transform; classification algorithms; statistical descriptors.

**Palavras-chaves:** falha por fuga à terra, aprendizado profundo, corrente de sequência zero, rede neural convolucional, detecção de falhas.

## 1. INTRODUÇÃO

Interrupções na operação de equipamentos elétricos na indústria, motivadas por falhas em equipamentos ou nas instalações elétricas, causam grandes impactos, pois têm o potencial para alterar completamente as rotinas programadas de manutenção e mesmo para interferir no planejamento da produção. Dessa forma, as possibilidades de falhas nestes componentes, bem como em painéis, barramentos, entre outros, devem ser minimizadas com a utilização de técnicas de manutenção eficientes, que sejam capazes de manter estes ativos em condições operacionais.

Segundo Bowen (2011), 98% das falhas em sistemas elétricos de potência estão associadas a faltas 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 prevenção das faltas 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 à valores na faixa de 1 A a 10 A. 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 a mesma 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 faltas à terra (curto-circuitos fase-terra), em centros de controle de motores (CCM), nesses sistemas, é um desafio para as equipes de manutenção. As correntes de baixa intensidade que circulam entre fase e terra podem ser facilmente confundidas com as correntes provenientes de desbalanço de fases. Além disso, a grande quantidade de cargas no mesmo alimentador, pode dificultar a identificação da corrente de fuga. Dessa forma, torna-se necessária a medição pontual da corrente em cada carga, aumentando a probabilidade de erro humano na identificação do ponto com fuga à terra, ao mesmo tempo que aumenta a exposição dos técnicos aos circuitos energizados durante estas medições.

Existem no mercado dispositivos e sistemas para equipamentos elétricos de baixa tensão que realizam a detecção de falta à terra que, em sua maioria, se baseiam na identificação do simples valor de desbalanço de corrente por meio de um transformador toroidal. Além do custo de implantação destes dispositivos ser elevado, a medição de assimetria absoluta de corrente exige alta sensibilidade, e estes estão propensos a disparos incorretos, devido a correntes de partida, comutação de grandes cargas, desbalanço natural da alimentação no sistema elétrico e, principalmente, devido a circulação de correntes oriundas de componentes capacitivas, intrínsecas em instalações industriais. Outro fator importante é que nestes sistemas de aterramento podem ocorrer faltas à terra com alta impedância no local do contato do condutor energizado com a terra, resultando em correntes de baixa intensidade que não sensibilizam os dispositivos de proteção citados anteriormente.

Este trabalho apresenta uma proposta para a utilização de redes neurais convolucionais aplicado à identificação de falta envolvendo uma fase à terra por meio de características dos sinais de corrente de sequência zero em alimentadores de motores nos sistemas aterrados por resistor de alto valor em CCMs (Centro de Controle de motores) de uma planta industrial. Para a realização dos experimentos foram utilizadas as medições de corrente de sequência zero dos 76 motores de um dos CCMs da planta industrial. O conjunto de dados utilizado nos experimentos, é constituído de medições de correntes dos motores na condição de operação normal e com fuga à terra. No método proposto, o objetivo é a identificação individual do motor que apresenta a falta de fuga à terra. Para a construção dos modelos, os sinais de corrente de sequência zero no domínio do tempo alimentam uma rede neural convolucional que realizará a extração das características e classificará os sinais.

Na sequência, este trabalho está constituído pelas seguintes seções: a Seção II contém uma revisão bibliográfica sobre a detecção de falta à terra em sistemas elétricos; a Seção III faz uma breve descrição dos sistemas de aterramento utilizando resistor de alto valor ôhmico. A Seção IV, faz uma revisão das técnicas e ferramentas aplicadas

ao longo do trabalho. A Seção V apresenta a metodologia que orientou a realização do trabalho com uma detalhada descrição do conjunto de dados. A Seção VI apresenta e discute os resultados obtidos, e a Seção VII traz as conclusões.

## 2. REVISÃO DA BIBLIOGRAFIA

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 à peculiaridades de projeto, sistemas elétricos que não são aterrados, ou que são aterrados por resistência de alto valor têm apresentado particular interesse por parte dos pesquisadores (Zamboni, 2013). Tal interesse se deve ao fato de, dependendo da magnitude da falta, tais sistemas poderem 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 e risco para os operadores do sistema.

Os autores em Lubich (1997) propõem uma solução para a detecção do ponto de ocorrência da fuga, que consiste na injeção de um sinal de corrente pulsante com valor entre 3 A a 4 A no ponto de aterramento entre o neutro do transformador e a terra. A corrente injetada, superior a corrente capacitiva do circuito, circulará para à terra, pelo caminho da fase que está com baixa isolamento. 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 et al. (2003) apresentam um algoritmo para detecção de falta à terra em sistemas aterrados por resistor de alto valor em instalações de baixa tensão. 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 da 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”. 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 estimação 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 muito baixos, não há faltas de fuga à terra no sistema, caso contrário, existe fuga à terra em algum ponto do sistema em questão. 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%.

O trabalho de Valdes et al. (2006) propõe uma técnica para detecção de falta à terra em sistemas aterrados por alta resistência. Na proposição dos autores, um sinal externo da ordem de 4 A 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 coletadas por um sistema de monitoramento. Quando ocorre uma falta à terra, o sistema de monitoramento identifica o caminho da corrente injetada no circuito e indica com relativa precisão o ponto de ocorrência da falta. De acordo com os autores, comparativamente às demais técnicas existentes, o método proposto é um dos mais economicamente viáveis.

Uma pesquisa sobre detecção de correntes de falta à terra em sistemas de aterramento de alta impedância foi apresentada no trabalho de Samanfar and Mahamedi (2010). Os autores utilizaram um método baseado na utilização da transformada *wavelet* 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, foi utilizado o filtro *wavelet Db4* no primeiro nível de decomposição. Os autores apresentaram como vantagens da utilização do método proposto sua robustez ao desbalanceamento entre fases sob condições normais das variáveis elétricas de tensão e corrente, e a alta sensibilidade para identificação de faltas em alta impedância.

Os autores em Widodo et al. (2009) utilizaram a transformada *wavelet* para investigar faltas 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 extraídos dos sinais os parâmetros estatísticos, 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%.

Não foram encontrados na literatura trabalhos sobre a identificação de cargas com fuga à terra em sistemas ater-

rados com resistor de alto valor ôhmico em baixa tensão, sem a utilização de sinal externo. O presente trabalho se distingue dos demais disponíveis na literatura, por se basear 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 dos sistemas de localização dos pontos com falta à terra. A aplicação de uma ferramenta de diagnóstico eficaz reduz a exposição de pessoas aos riscos inerentes às instalações elétricas, aspecto fundamental para a segurança nas instalações industriais.

### 3. SISTEMAS DE ATERRAMENTO POR RESISTOR DE ALTO VALOR

Sistemas aterrados por resistor de alto valor (RAV) ou "HGR" (*High Grounding Resistance*), possuem, entre o neutro e o terra, um elemento que limita as correntes de falta à terra entre 1 A e 10 A (Blackburn and Domin, 2015). Valores de corrente de fuga à terra nessa faixa reduzem a probabilidade de danos nas instalações elétricas. 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, onde o potencial da fase em curto-circuito é igual ao potencial do terra deslocado ao ponto de neutro do sistema elétrico. Nessa configuração, 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 ao 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.

Uma importante 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 capacitivas intrínsecas do 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 Fig. 1 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.

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

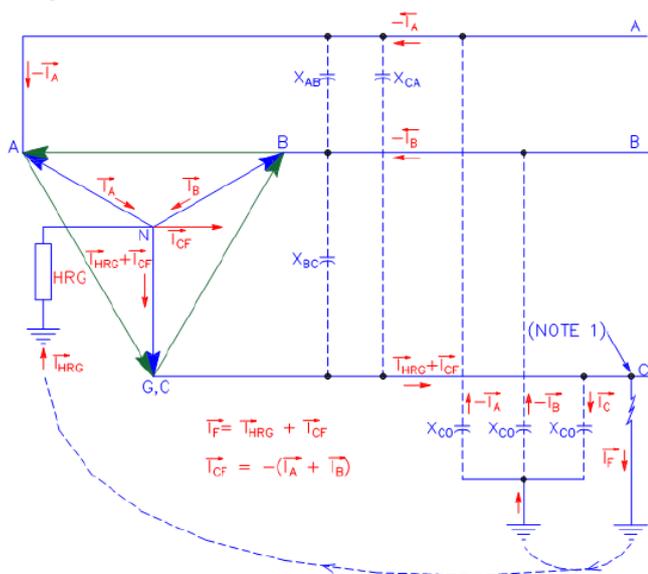


Figura 1. Diagrama fasorial de corrente da fase C para a terra em sistema RAV. Fonte: Paul (2020)

um fator relevante a ser considerado pelas indústrias para a escolha desse tipo de sistema de aterramento quando do projeto de suas instalações.

#### 4. REFERENCIAL TEÓRICO

Essa seção apresenta uma descrição das Redes Neurais Convolucionais (*Convolutional Neural Network - CNN*), técnica de aprendizado profundo aplicado neste trabalho para extração de características e classificação dos sinais de corrente de sequência zero.

##### 4.1 Redes Neurais Convolucionais

As redes neurais convolucionais foram originalmente propostas para tarefas envolvendo imagens (LeCun et al., 1990). As *CNNs* são constituídas por diferentes tipos de camadas com diferentes funções, como por exemplo, camadas de convolução, camadas de *pooling* e camada de classificação.

Uma camada convolucional típica tem a seguinte função em uma *CNN*: dada uma matriz com dados de entrada, faz-se a convolução desta por matrizes de menor ordem (*kernels*). O resultado dessa operação possui valores selecionados em matrizes de ordem inferior, por um processo conhecido como *pooling*. Dessa forma, a informação contida na matriz de entrada é filtrada e concentrada em uma matriz de menor ordem, chamadas de *feature maps* (mapas de parâmetros). Os *feature maps* podem então alimentar outras camadas da rede neural, como por exemplo, a camada de classificação, onde a classe é estimada.

Na análise de sinais em uma dimensão, substitui-se 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 Fig. 2, onde pode ser notado que a entrada da *CNN* é um vetor unidimensional que pode ou não passar por um estágio de pré-processamento.

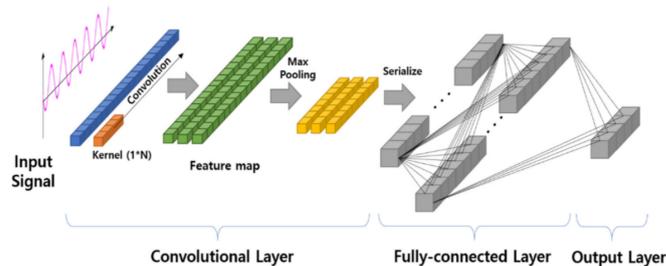


Figura 2. Arquitetura de rede convolucional unidimensional.

Fonte: Adaptado de Kim et al. (2020)

Dessa forma, uma camada convolucional unidimensional é utilizada para extrair informações do sinal de entrada por meio dos filtros e, após vários estágios de convolução e *pooling*, os dados filtrados podem ser a entrada de uma camada de classificação (Tao et al., 2019). As principais camadas e suas descrições estão apresentadas a seguir:

**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, realizando a soma do produto de todos os valores de seu campo receptivo. Essa tarefa é executada em todas as posições de 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, 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 de *pooling* mais utilizada é o *maxpooling*, que consiste em adotar o valor máximo encontrado na região.

**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.

##### 4.2 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 de otimização mais populares. Na sequência são apresentadas três versões do Gradiente Descendente.

**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 muito rápido e que pode ser utilizado para aprendizado online. Uma das desvantagens do *SGDM* é a realização de atualizações com a alta variância que leva a função objetivo a sofrer grandes flutuações (Ruder, 2016).

*Adaptive Moment Estimation (ADAM)*: *ADAM*, proposto por Kingma and 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 estimativas 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 et al. (2012), é um método de 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).

## 5. METODOLOGIA

Essa seção apresenta a metodologia que orientou a realização do trabalho. Inicialmente, o procedimento para aquisição do conjunto de dados é apresentado. Em seguida as técnicas de pré-processamento dos sinais de corrente são descritas. Por último o procedimento para construção dos classificadores e avaliação do desempenho dos mesmos é apresentado. A Fig. 3 ilustra as etapas da metodologia aplicada para a obtenção dos modelos e classificação das falhas.

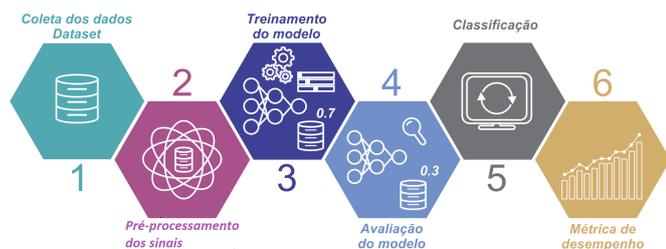


Figura 3. Etapas da metodologia de modelagem e classificação das falhas.

Fonte: Autor

### 5.1 Aquisição do Sinais de Fuga à Terra

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 onde os barramentos de baixa tensão saem do transformador e são conectados diretamente ao Centro de Distribuição de Cargas (CDC), onde o neutro (centro da estrela secundária) é ligado a dois resistores de 90  $\Omega$  associados em série,

totalizando 180  $\Omega$  interligando o neutro a terra (RAV). A primeira etapa para a implementação dos sistemas para identificação dos motores com falta à terra, foi a coleta dos sinais de correntes de sequência zero. As medições das corrente de sequência zero foram realizadas inserindo uma garra de medição de corrente nos cabos que saem dos alimentadores do CCM, envolvendo todas os condutores, simultaneamente.

O CCM é constituído por diversos compartimentos que são responsáveis por realizar o acionamento dos motores denominados “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.

O *kit* de medição utilizado neste trabalho foi constituído por um oscilógrafo digital de alto processamento e uma garra de medição de corrente com capacidade de até 50 A. 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 1.000.001 pontos amostrais por medição.

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 quando identificadas pela equipe de manutenção responsável.

### 5.2 Segmentação dos Sinais

Cada arquivo com os sinais nas condições normal e falta, foi segmentado em 100 amostras com 10000 pontos. 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, 6.700 e 900 amostras, sendo o conjunto completo constituído por 7.600 amostras e 10.000 variáveis por amostra, como indicado na Tabela 1. Como pode ser notado, existe um desbalanceamento entre o número de amostras das classes “normal” e “falha”.

Tabela 1. Divisão de pontos amostrais por classe

Classe	Nº de Amostras	Nº de Variáveis
Normal	6.700	10.000
Falha	900	10.000

### 5.3 Treinamento do Classificador

Após a segmentação e normalização dos sinais, o conjunto foi particionado em subconjuntos de treinamento/validação e teste com 70% e 30% das amostras, respectivamente. Para avaliar o desempenho dos modelos na etapa de validação foi utilizado método *k-Fold Cross-Validation* com 10 partições. Para avaliação do desempenho na etapa de testes foi utilizada a métrica *f1-score* (1), que pode ser diretamente calculada da matriz de confusão. O *f1-score* é

a média harmônica entre a precisão e *recall*, e pode aferir de forma mais adequada o desempenho de modelos obtidos a partir de conjuntos de dados desbalanceados. Todos os testes foram realizados no *software* Matlab®<sup>®</sup>, R2021a.

$$f1score = \frac{2 \times precision \times recall}{precision + recall}. \quad (1)$$

Os modelos de classificação foram obtidos utilizando uma rede neural convolucional unidimensional cuja configuração dos parâmetros, que foram definidos empiricamente, estão 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*.

Na Tabela 2 são apresentados os valores dos principais hiperparâmetros utilizados para o treinamento do modelo.

Tabela 2. Hiperparâmetros aplicados para o treinamento do modelo

Hiperparâmetro	Valor
Epochs	20
Validation Frequency	50
Mini Batch Size	64
Learn Rate	0,001
Momentum	0,9

## 6. RESULTADOS

Essa seção apresenta o desempenho dos modelos de classificação construídos com rede neural convolucional. A Tabela 3 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%.

Tabela 3. Resultados com otimizador *SGDM*

N° Filtros	Precisão	Recall	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

A Tabela 4 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%.

A Tabela 5 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

Tabela 4. Resultados com otimizador *RMSPROP*

N° Filtros	Precisão	Recall	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

alcançado o valor de 99,26% de *f1-score* e o pior foi obtido com 40 filtros, com 94,86%.

Tabela 5. Resultados com otimizador *ADAM*

N° Filtros	Precisão	Recall	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

## 7. CONCLUSÃO

Este trabalho apresenta uma proposta para detecção de falhas em motores com fuga de uma das fases para a terra em CCM's com aterramento do neutro por resistor de alto valor aplicando rede neural convolucional. O conjunto de dados utilizado é constituído por sinais de corrente de sequência zero de motores em condição de operação normal e com falta de uma das fases para a terra. Os resultados obtidos mostram que todas as arquiteturas de redes neurais convolucionais apresentaram bons resultados, o que indica que a arquitetura proposta é viável para a detecção das falhas investigadas. Entretanto, os classificadores construídos com otimizador *RMSPROP* apresentaram 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*. Uma possível justificativa para os resultados obtidos é o 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, 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 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 *CNN*, 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.

## AGRADECIMENTOS

Os autores agradecem a Cooperação CAPES/FAPES - PDPG, projeto TIC+TAC, pelo apoio financeiro (TO 133/2021, Processo N° 2021-CFT5C).

## REFERÊNCIAS

- Baldwin, T., Renovich, F., and Saunders, L.F. (2003). Directional ground-fault indicator for high-resistance grounded systems. *IEEE Transactions on Industry Applications*, 39(2), 325–332.
- Blackburn, J.L. and Domin, T.J. (2015). *Protective relaying: principles and applications*. CRC press.
- Bowen, J. (2011). *Grounding for Industrial Systems*. Institute of Electrical and Electronics Engineers (IEEE).
- Cai, X.W., Jin, T., Jia, H.B., and Qi, Y.L. (2014). The design of location system for single-phase grounded fault in distribution network based on zero-sequence current. In *Advanced Materials Research*, volume 986, 1677–1681. Trans Tech Publ.
- Cerentini, A. et al. (2018). Identificação do glaucoma em imagens do fundo do olho utilizando aprendizagem profunda. Universidade Federal de Santa Maria.
- Costa, P.F. (2014). 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*, 1.
- Hinton, G., Srivastava, N., and Swersky, K. (2012). Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. volume 14, 2.
- Kim, S.H., Geem, Z.W., and Han, G.T. (2020). Hyperparameter optimization method based on harmony search algorithm to improve performance of 1d cnn human respiration pattern recognition system. *Sensors*, 20(13), 3697.
- Kingma, D.P. and Ba, J. (2014). Adam: A method for stochastic optimization.
- LeCun, Y., Boser, B., and Denker, J. (1990). D. henderson, re howard, w. hubbard, and lj jackel. *Handwritten digit recognition with a back-propagation network*, 1, 396–404.
- Lubich, D. (1997). High resistance grounding and fault finding on three phase three wire (delta) power systems. In *1997 IEEE Annual Textile, Fiber and Film Industry Technical Conference*, 10–5. IEEE.
- Paul, D. (2020). Phase-ground fault current analysis and protection of a high-resistance grounded power system. *IEEE Transactions on Industry Applications*, 1.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms.
- Samanfar, A. and Mahamedi, B. (2010). Directional high-resistance earth fault detector based on zero-sequence components and wavelet transform. In *2010 IEEE International Conference on Power and Energy*, 151–155. IEEE.
- Sutskever, I., Martens, J., Dahl, G., and Hinton, G. (2013). On the importance of initialization and momentum in deep learning. In *International conference on machine learning*, 1139–1147. PMLR.
- Tao, Q., Liu, F., Li, Y., and Sidorov, D. (2019). Air pollution forecasting using a deep learning model based on 1d convnets and bidirectional gru. *IEEE access*, 7, 76690–76698.
- Taqi, A.M., Awad, A., Al-Azzo, F., and Milanova, M. (2018). The impact of multi-optimizers and data augmentation on tensorflow convolutional neural network performance. In *2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*, 140–145. IEEE.
- Valdes, M., Papallo, T., and Premerlani, B. (2006). Ground fault location in low-voltage high-resistance grounded systems via the single-processor concept for circuit protection. In *Conference Record of 2006 Annual Pulp and Paper Industry Technical Conference*, 1–8. IEEE.
- Widodo, A., Yang, B.S., Gu, D.S., and Choi, B.K. (2009). Intelligent fault diagnosis system of induction motor based on transient current signal. *Mechatronics*, 19(5), 680–689.
- Zamboni, L. (2013). *Detecção e localização de faltas em sistemas elétricos de distribuição usando abordagem inteligente baseada em análise espectral de sinais*. Ph.D. thesis, Universidade de São Paulo.