



**FUNDAÇÃO
UNIVERSIDADE
FEDERAL DE
MATO GROSSO DO SUL**

**FACULDADE DE ENGENHARIAS,
ARQUITETURA E URBANISMO E
GEOGRAFIA**

Engenharia Elétrica

Correção da Saturação de Transformadores de Corrente para Proteção Utilizando Redes Neurais Artificiais

Marcelo Soares da Silva

Campo Grande MS
07 de agosto de 2020



**FUNDAÇÃO
UNIVERSIDADE
FEDERAL DE
MATO GROSSO DO SUL**

**FACULDADE DE ENGENHARIAS,
ARQUITETURA E URBANISMO E
GEOGRAFIA**

Engenharia Elétrica

Correção da Saturação de Transformadores de Corrente para Proteção Utilizando Redes Neurais Artificiais

Marcelo Soares da Silva

Orientador: Prof. Dr. Marcio Luiz Magri Kimpara


Trabalho de Conclusão de Curso
apresentado à Universidade Federal de
Mato Grosso do Sul na Faculdade de
Engenharias, Arquitetura e Urbanismo e
Geografia, como requisito parcial para
obtenção do título de Engenheiro(a)
Eletricista.

Campo Grande MS
07 de agosto de 2020


Correção da Saturação de Transformadores de Corrente para Proteção Utilizando Redes Neurais Artificiais

Monografia apresentada à Universidade Federal de Mato Grosso do Sul na Faculdade de
Engenharias, Arquitetura e Urbanismo e Geografia, para obtenção da Graduação em
Engenharia Elétrica.


Banca Examinadora:



Prof. Dr. Marcio Luiz Magri Kimpara



Prof. Dra. Luciana Cambraia Leite




Prof. Dr. Flávio Guilherme de Melo Lima

Campo Grande MS
07 de agosto de 2020

DECLARAÇÃO DE AUTORIA E RESPONSABILIDADE

Marcelo Soares da Silva, residente e domiciliado na cidade de Campo Grande, Estado do Mato Grosso do Sul, portador do RG de nº 2105090 e CPF nº 0.27.888.501-23, declaro que o “Trabalho de Conclusão de Curso” apresentado, com o título “Correção da Saturação de Transformadores de Corrente para Proteção Utilizando Redes Neurais Artificiais” é de minha autoria e assumo a total responsabilidade pelo seu conteúdo e pela originalidade do texto. Declaro que identifiquei e referenciei todas as fontes e informações gerais que foram utilizadas para construção do presente texto. Declaro também que este artigo não foi publicado, em parte, na íntegra ou conteúdo similar em outros meios de comunicação, tendo sido enviado com exclusividade para a Universidade Federal de Mato Grosso do Sul (UFMS).

Campo Grande, 07 de agosto de 2020.



Marcelo Soares da Silva

Dedicatória

*Dedico este trabalho aos meus pais,
Maria e Manoel que desde sempre abriram
mão de muitas coisas para prover condições de
estudo aos filhos.*

AGRADECIMENTOS

Agradeço essa formação primeiramente a Deus e meus familiares próximos que sempre me apoiaram. Presto também, sinceros agradecimentos ao professor Marcio Kimpara pela maneira que me orientou, sempre com dedicação, paciência e comprometimento.

.

RESUMO

Um sistema de proteção deve atuar de forma a garantir a integridade dos equipamentos que compõem a instalação elétrica, entretanto, algumas situações podem causar o mau funcionamento desse sistema, gerando sérios prejuízos à rede elétrica. Diante disso, este trabalho fez o estudo da condição de saturação dos transformadores de corrente, cujo efeito é responsável por mascarar a leitura da corrente secundária que o relé faz para processar a sua lógica de acionamento. O objetivo do trabalho consiste em propor um método de correção para a leitura de corrente utilizando técnicas de inteligência artificial.

O algoritmo proposto baseia-se na arquitetura de rede denominada perceptron de múltiplas camadas (MLP). Primeiramente, algumas situações de curto circuito foram apresentadas à rede neural para treino e validação, em seguida, implementou-se a mesma em ambiente simulink para comprovar a característica de generalização. Os resultados demonstraram que a rede foi capaz de estimar satisfatoriamente a corrente não distorcida, tanto para situações treinadas quanto para novas condições. Com a rede proposta foi possível manter a integridade da leitura dos valores eficazes de corrente que o relé realiza.

Palavras-Chave: Proteção sistemas elétricos de potência, transformadores de corrente, saturação, redes neurais.

ABSTRACT

A protection system must act in order to guarantee the integrity of the equipment that compounds the electrical installation. Some situations can cause this system to malfunction, causing serious damage to the network. Therefore, this work explored the saturation condition of the current transformers, which are responsible for changing the reading of the secondary current that the relay makes to process its activation logic. And then, propose a correction method using artificial intelligence techniques.

The proposed algorithm is based on a network architecture called multilayer perceptron (MLP). Some short circuit situations were presented to the neural network for training and validation, then it was implemented in a simulink environment to prove the generalization characteristic. The results showed that the network were able to satisfactorily estimate the undistorted current, both for trained situations and for new conditions. With the proposed network it was possible to maintain the integrity of the reading of the effective current values that the relay performs.

Keywords: Protection of electrical power systems, current transformers, saturation, neural networks.

SUMÁRIO

1. INTRODUÇÃO	9
1.1. Justificativa (motivação) para o desenvolvimento do trabalho.....	13
1.2. Objetivos	13
1.2.1. Objetivo Geral	13
1.2.2. Objetivos Específicos	14
1.3. Organização do Trabalho (Resumo dos capítulos).....	14
2. REVISÃO TEÓRICA E MODELAGEM DO SISTEMA ESTUDADO	15
2.1. Revisão Teórica dos Equipamentos.....	15
2.1.1. IED's – Dispositivos Eletrônicos Inteligentes.....	15
2.1.2. Transformadores de corrente	16
2.2. Modelagem do Sistema estudado	19
3. REDES NEURAIS ARTIFICIAS	25
3.1. O Neurônio Artificial.....	26
3.2. Tipos de Função de Ativação.....	28
3.3. Principais Arquiteturas de Redes Neurais.....	30
3.3.1. Redes Feedforward de Camada Única	30
3.3.2. Redes Feedforward de múltiplas camadas.....	31
3.3.3. Redes Recorrentes	32
3.4. O Processo de Aprendizagem	33
3.4.1. Aprendizagem do Perceptron de Múltiplas Camadas – Retropropagação	33
3.5. Método de correção da corrente saturada por meio de uma MLP	34
4. RESULTADOS E DISCUSSÕES	38
4.1. Falta Monofásica.....	38
4.2. Falta Bifásica	40
4.3. Falta Trifásica	41
4.4. Diferentes condições de entrada para o algoritmo	43
4.5. Conclusão do capítulo de resultados.....	46
5. CONCLUSÕES GERAIS	47
6. Referências	48
7. Apêndice A-Modelos de Simulação.....	50

1. INTRODUÇÃO


O sistema elétrico de potência (SEP) tem a função de realizar a conexão entre a geração de energia e a carga. Portanto, os estudos de planejamento devem ser efetivos para assegurar que essa conexão seja realizada com o mínimo de interrupções possível. Devido a grande importância de se manter o sistema elétrico estável e confiável, os dispositivos de proteção adquirem papel crucial no funcionamento do mesmo.

Devido a heterogeneidade do SEP, faz-se necessário a alocação de diversos dispositivos de proteção capazes de atender às generalidades do sistema. De forma estratégica, esses dispositivos não podem atuar de maneira independente, portanto, ao identificar uma falha, esses equipamentos devem ser capazes de isolá-la, desconectando-a do circuito sem que as outras partes do sistema sejam afetadas.

Na operação dos sistemas elétricos é bastante comum a ocorrência de curtos-circuitos. Portanto, a proteção deve atuar devidamente para evitar maiores danos aos equipamentos energizados. Além disso, há outras falhas que ocasionam interrupção no fornecimento de energia aos consumidores: as sobrecargas e os fenômenos de sub e sobretensão [1].

Um curto circuito faz circular pelos elementos do sistema, uma corrente bastante elevada que pode levar a danos irreparáveis em seus elementos e instalações. Por esse motivo, o sistema de proteção, composto por um conjunto de equipamentos que monitoram a corrente elétrica no sistema de potência, é de suma importância para detectar e desconectar a parte do sistema submetido a algum tipo de anormalidade. Um esquema geral da estrutura de um sistema de proteção é apresentado na Figura 1.1.

Fig. 1.1 Estrutura básica de um esquema de proteção de alimentadores. Fonte: Autor.



Basicamente, o sistema é composto por disjuntores, transformadores de corrente, transformadores de potencial e as IED's (Intelligent Electronic Device). Uma característica de um transformador de corrente (TC) que desempenha a função de proteção, é que este não deve saturar. A saturação deste equipamento causa uma certa distorção da sua corrente secundária, que pode comprometer a leitura de seu valor eficaz por um relé.

De maneira prática, a saturação do TC faz com que a corrente do seu secundário adquira uma forma não senoidal. Isso acarreta a diminuição do valor eficaz da corrente induzida. Nas Figuras 1.2 e 1.3 estão sendo mostrados os efeitos da diminuição da corrente de secundário devido a saturação do TC. Evidentemente, essa diferença entre as correntes pode causar problemas no sistema de medição dos relés, consequentemente, esse fato pode representar um problema para a correta atuação do sistema de proteção.

Fig. 1.2 Efeitos da saturação do TC na relação entre as correntes primária e secundária. Fonte: [2].





Fig. 1.3 Efeitos da saturação do TC na relação entre as correntes primária e secundária valores eficazes. Fonte: [2].




Para evitar a saturação dos TCs, o núcleo destes transformadores deveria possuir dimensões impraticáveis. Diante disso, algumas metodologias para corrigir a forma de onda da corrente saturada dos TCs foram propostas na literatura. A referência [3], propõe um método que substitui os TC's de proteção por transformadores de medição desenvolvendo a função de proteção. Isso, visando reduzir o tamanho e o custo de forma a viabilizar a construção de disjuntores com TC's integrado. Explorando a característica de saturação mais acentuada para TCs de medição, a corrente de magnetização foi estimada através do cálculo do fluxo no núcleo do transformador e da curva de magnetização, e então foi adicionada a corrente medida no secundário. Portanto, o trabalho propõe um algoritmo de detecção da saturação que consegue apurar bem o sinal, de forma a garantir a sensibilidade dos relés. Além disso, a seção do núcleo do TC é reduzida, provendo um menor custo para instalação e aquisição. Entretanto, a performance deste tipo de algoritmo baseado no modelo do transformador, pode ser prejudicada caso os parâmetros do TC sofram alteração. Há ainda, na referência [4], um método que corrige a distorção, primeiramente identificando o fluxo mútuo no início da saturação, a partir dos parâmetros utilizados para a curva de magnetização do equipamento.

O fluxo é calculado com base nesses valores iniciais, para todo o período de falta e então é feita uma estimativa para a corrente de magnetização. E por fim, adiciona-se esse valor estimado à corrente medida no secundário, provendo uma estimativa para a corrente que seria observada caso o TC não estivesse sob saturação [4]. Novamente, estes métodos dependem de cálculos baseados em um modelo matemático.

Neste trabalho será proposto um método de correção da distorção da corrente causada pela saturação, por meio de uma rede neural MLP (*multilayer perceptron*). Essa rede ficará alocada entre a saída do secundário do TC e a entrada da leitura do relé, conforme Figura 1.4. Assim, a distorção na forma de onda será corrigida e enviada para o dispositivo, garantindo a leitura ideal dos níveis de corrente que passam no sistema.

A Rede Neural (RNA) é uma ferramenta amplamente utilizada em situações envolvendo reconhecimento de padrões, interpolações, filtragem de sinais, previsões de séries temporais, entre outras. No caso do estudo em tela, a utilização de uma RNA se justifica por ser apta a suportar dados com erros e encontrar associações não lineares entre os parâmetros do modelo. A vantagem da rede é que pode ser treinada com correntes reais de um determinado TC, sendo, portanto, incorporadas características construtivas realistas ao modelo predição, algo difícil de ser realizado com modelos matemáticos.

Figura 1.4 Alocação do dispositivo de correção da distorção da corrente secundária do TC e sua inserção no sistema. Fonte: Autor.



1.1. JUSTIFICATIVA PARA O DESENVOLVIMENTO DO TRABALHO

Em sistemas elétricos de potência, os transformadores de corrente (TC) são utilizados para fornecer correntes suficientemente reduzidas e isoladas do circuito primário de forma a possibilitar o seu uso por equipamentos de medição, controle e proteção. Em condições normais é esperado que o TC reproduza com precisão a corrente secundária no lado secundário em termos de magnitude (reduzida) e forma de onda, entretanto, correntes de falta (que podem ser muito maiores do que a corrente nominal, e ainda não-simétricas) geralmente causam distorções da corrente secundária devido aos efeitos da saturação do TC.

A saturação do transformador de corrente (TC) leva a imprecisões na medição de corrente e, portanto, pode causar mau funcionamento de relés de proteção e dispositivos de controle que utilizam correntes como sinais de entrada. Afim de garantir uma adequada medição pelo relé, este trabalho propõe um algoritmo de correção da forma de onda da corrente secundária de um transformador de corrente saturado. Será desenvolvida uma rede neural de múltiplas camadas, que recebe a corrente distorcida do TC e retorna uma forma de onda a qual um transformador não saturado deveria fornecer.

Utilizou-se para essa função a rede MLP devido a sua característica de aprendizado e generalização, de forma que o resultado obtido é válido tanto para situações anteriormente treinadas, quanto para situações novas apresentadas à rede.

1.2. OBJETIVOS

1.2.1. *Objetivo Geral*

Desenvolver uma rede neural artificial capaz de estimar o valor da corrente secundária de um transformador de corrente com base em treinamentos realizados a partir de situações de curto-circuito simuladas.

1.2.2. Objetivos Específicos

Primeiramente busca-se realizar a simulação de um sistema trifásico com a presença de um TC de proteção. Com a utilização da ferramenta do MatLab, simulou-se todas as formas de onda necessárias à análise e desenvolvimento do problema.

Em seguida, são exploradas arquiteturas de redes neurais artificiais a fim obter os melhores resultados. Após a composição da rede que melhor se adapta à resolução do problema abordado, avaliar as correções nas formas de onda obtidas para diferentes situações.

1.3. ORGANIZAÇÃO DO TRABALHO

Além deste capítulo introdutório, o restante do trabalho foi organizado conforme descrito abaixo.

No Capítulo 2, é apresentada uma breve revisão teórica dos transformadores de corrente e relés, a modelagem do transformador de corrente, as situações de curto a serem estudadas e as formas de onda a serem corrigidas.

No Capítulo 3, são apresentadas as características das redes neurais de forma geral e a descrição do método proposto para correção da saturação do transformador de corrente.

No Capítulo 4, são apresentados resultados obtidos sobre a rede neural proposta.

No Capítulo 5, são apresentadas as conclusões finais e propostas de continuidade do trabalho.

2. REVISÃO TEÓRICA E MODELAGEM DO SISTEMA ESTUDADO

O sistema de potência foi modelado em ambiente *Simulink*. A seguir serão apresentadas algumas características dos principais dispositivos estudados e, por fim alguns aspectos da simulação. Além disso, antes de começar o capítulo sobre redes neurais, serão apresentadas as condições de falta simuladas, que serviram de insumo para treinamento da MLP.

2.1. REVISÃO TEÓRICA DOS EQUIPAMENTOS

2.1.1. IED's – Dispositivos Eletrônicos Inteligentes.

À medida que agregam mais recursos, os relés digitais (IED'S) têm sido cada vez mais utilizados nas subestações de energia. O uso desses dispositivos permite redução do custo de manutenção e implantação – diminuição do número de cabos e equipamentos necessários à sua utilização – bem como troca mais rápida de informações, simplificação de projeto e sincronização temporal de dispositivos [5].


A Figura 2.1 apresenta a estrutura básica de um relé em diagrama de blocos. Conforme descrito em [1], um relé de proteção possui as seguintes características:

- Unidade de conversão de sinal;
- Unidade de medida;
- Fonte de tensão auxiliar;
- Unidade de saída;

A unidade de conversão recebe os sinais dos equipamentos de medição e os adequa aos níveis de funcionamento dos relés. Após isso, envia os mesmos à unidade de medida que os compara aos valores previamente parametrizados para operação para, ao identificar valores maiores que estes, envia uma informação para a unidade de saída. Esta, por sua vez, é constituída por uma bobina que aciona uma chave auxiliar.

Por fim, os relés possuem uma fonte de tensão auxiliar que fornece energia às unidades de medida, de saída e de acionamento. Essa última consiste em uma bobina montada no corpo do elemento responsável por desconectar o sistema.

Fig. 2.1 Diagrama de blocos de um relé de proteção. Fonte: Adaptado de [1].




2.1.2. Transformadores de corrente

Os transformadores de corrente, quando desempenhando função de proteção, são utilizados para suprir os relés. Isso porque são capazes de transformar as correntes elevadas que circulam pelo seu primário, em sinais com amplitude menor através do fenômeno de indução eletromagnética.

Esses equipamentos possuem um circuito primário, ligado em série com o sistema protegido, geralmente com poucas espiras. E, magneticamente acoplado a este há o circuito secundário que fornece a corrente transformada de acordo com a relação de espiras entre os dois enrolamentos. Na maioria dos casos, essa corrente é padronizada em 5 A [6].

Como uma simplificação, o circuito elétrico equivalente por fase de um transformador de corrente é mostrado a seguir na Figura 2.2, retirada de [6].

Fig. 2.2 Circuito elétrico monofásico equivalente para um transformador de corrente. Fonte [3].



Ao observar a Figura 2.2 é possível compreender o funcionamento desse equipamento: uma carga solicita da rede uma corrente I_p que circula pelo enrolamento primário, o qual pode-se desconsiderar a impedância $R1$ e $X1$ para TCs de proteção [6]. Enquanto que a corrente induzida I_s provoca uma queda de tensão nas impedâncias interna $R2+jX2$ e de carga R_c+jX_c , exigindo uma corrente magnetizante maior. O que provoca alterações na exatidão do transformador, visto que, segundo a lei dos nós tem-se:

$$I_p = I_s + I_m \quad (1)$$

Entretanto, quando o núcleo entra em saturação o erro associado à medida é bastante considerável, pois a parte ferromagnética do equipamento exige uma corrente de magnetização elevada [6].

Como o enrolamento primário do TC é ligado em série com o sistema de potência, a corrente nominal primária deve ser compatível com a carga do mesmo. De forma a aumentar a dinâmica de utilização desse equipamento, é possível realizar diferentes tipos de ligação para obter relações de transformações diversas.

Conforme mencionado anteriormente, as correntes secundárias dos transformadores de corrente geralmente são padronizadas em 5 A. Isso porque é um nível aceitável de corrente para os dispositivos que são ligados no secundário.

Um TC é especificado de acordo com a carga a qual será ligada no seu enrolamento secundário. Essa carga é o valor da impedância de todos os dispositivos ligados a seu circuito


secundário, incluindo também os condutores de interligação. Essa carga corresponde à impedância a qual será fornecida a potência que garante a exatidão do transformador.

Um outro aspecto ligado ao correto funcionamento do TC é o fator de sobrecorrente. Segundo a NBR 6856 [7], para serviço de proteção (principal foco desse trabalho), o fator de sobrecorrente é de 20. Após isso, há erro de medição associada à saturação do transformador de corrente.

A saturação desse equipamento é causada por um aumento do fluxo magnético no núcleo. O fluxo é gerado pela corrente primária e é usado para induzir a corrente secundária. Quando o material ferromagnético do núcleo é incapaz de conduzir o fluxo que está sendo gerado pela corrente primária, há o fenômeno da saturação.

Isso caracteriza um padrão de comportamento entre as correntes dos enrolamentos dividido em duas regiões. Uma de comportamento linear, em que a corrente secundária é proporcional à corrente primária pela relação entre as espiras. E a outra região denominada saturada ($I \geq f_s \cdot I_p$), a qual a corrente primária aumenta consideravelmente o seu valor enquanto que a corrente no secundário não apresenta variação de amplitude, conforme visto na Figura 2.3, onde $f_s I_{sn}$ representa a corrente nominal do secundário vezes o fator de sobrecorrente e $f_s I_{pn}$ representa a corrente nominal primária vezes o fator de sobrecorrente.

Fig. 2.3 Relação entre correntes de transformadores de corrente (medição e proteção) para as duas regiões de operação – não saturada e saturada. Fonte: Autor.



2.2. MODELAGEM DO SISTEMA ESTUDADO

A modelagem do transformador de corrente foi feita utilizando a ferramenta SIMULINK do software MATLAB. A característica de saturação do núcleo foi retirada de um modelo da própria desenvolvedora, disponível na literatura. O circuito simplificado do TC está apresentado na Figura 2.4.

A carga R_1 no secundário, também chamada de impedância de Burden, representa os equipamentos ligados a essa parte do equipamento. Conforme [6], a NBR 6856 padroniza as cargas secundárias de acordo com a Tabela 2.1.

Fig. 2.4 Modelo simplificado de um transformador de corrente. Fonte: Autor.




Tabela 2.1 Cargas nominais para TCs a 60 Hz e 5 A.

Classe	Impedância Ω
C2,5	0,1
C5,0	0,2
C12,5	1,0
C50	2,0
C100	4,0
C200	8,0

Fonte: [3].

O bloco “*Saturable Transformer*” foi parametrizado para o equipamento pertencer à classe C25, ou B100. Na Tabela 2.2, estão apresentados os valores que relacionam o fluxo e a corrente do ramo magnetizante, esses valores determinam a característica de saturação do TC estudado.

Tabela 2.2 Característica de magnetização do TC estudado. Valores em pu.

<i>Corrente (I_m)</i> <i>(p.u.)</i>	<i>Fluxo (ϕ)</i> <i>(p.u.)</i>
0	0
0.01	10
1	10.5

Fonte: Autor.

O TC escolhido possui relação nominal de 150-5 A, ou 30:1. A tensão nominal do sistema é de 138 kV e a potência de carga 20 MVA inicialmente.

Após a modelagem e implementação do sistema trifásico da Figura 2.5, com os parâmetros acima, simulou-se algumas situações de curto circuito, para avaliar a saturação do TC. São elas listadas abaixo:

- Falta monofásica: Sendo o menos agressivo ao sistema, entretanto o mais corriqueiro. Sua incidência é alta se considerar os outros tipos de falta;
- Falta bifásica: Não muito frequente, possui agressividade mais acentuada que a situação anterior;
- Falta trifásica: Apesar de ser raro o seu acontecimento, o potencial destrutivo desse tipo de falta é bastante alto.


Esses curto circuitos podem ser do tipo permanentes ou temporários, sendo esse primeiro do tipo irreversível espontaneamente, dessa forma necessita de conserto na rede elétrica para o restabelecimento do sistema. Após a desconexão efetuada pelo disjuntor, faz-se necessário deslocar uma equipe de manutenção até o ponto do defeito para conserto [8].

Já o curto do tipo temporário ocorre sem que haja defeito na rede. Após a atuação das proteções, o funcionamento normal dos equipamentos é garantido. Esses, por sua vez podem acontecer por diversas causas, entre elas: sobretensão na rede, umidade, chuva, galhos de arvores, pássaros e etc.

É importante destacar também que as simulações de falta consideradas neste trabalho apresentam a componente CC. Normalmente, se as correntes de falta são puramente sinusoidais, os TCs podem medir até 20 vezes as correntes nominais com erro aceitável, no entanto se a corrente de


falta medida contiver uma componente CC com decaimento exponencial o TC pode ficar saturado, mesmo que a corrente de falta não seja tão elevada. Como dito anteriormente, a saturação do TC provoca medições distorcidas e imprecisão na operação dos relés.

Fig. 2.5 Sistema trifásico 138 kV 20MVA com representação do TC na fase A. Fonte: Autor.



A Figura 2.6 apresenta o diagrama unifilar do sistema estudado. No lado fonte, tem-se o fornecimento de 138 kV e 25 MVA, entretanto, não representa uma unidade geradora, pois é incomum usinas gerarem nessa tensão elevada. Portanto, o sistema desenhado representa uma subestação, que conecta uma linha de transmissão a uma outra subestação de distribuição, a qual a partir dela (o que foi omitido, pois não era interessante para o estudo em questão) a tensão será rebaixada para níveis adequados à distribuição.


Fig. 2.6 Representação do sistema estudado. Fonte: Autor



A Figura 2.7 apresenta comparação das formas de onda das correntes primária e secundária para a primeira situação de falta.

Fig. 2.7 Relação entre a corrente primária e secundária do TC para a situação de falta monofásica.


Fonte: Autor



Para a situação de curto bifásico, a Figura 2.8 apresenta a relação entre as correntes e uma saturação um pouco mais acentuada. Que pode ser explicada porque essa situação de falta é um pouco mais agressiva do que a anterior.

Fig. 2.8 Relação entre a corrente primária e secundária do TC para a situação de falta bifásica.


Fonte: Autor



A falta trifásica, no geral, é a que atinge os sistemas com maior intensidade, apesar de a frequência de acontecimentos de tal evento ser bastante baixa. A Figura 2.9 abaixo representa a relação entre as correntes do TC obtidas quando submetido o sistema a essa falta.

Fig. 2.9 Relação entre a corrente primária e secundária do TC para a situação de falta trifásica.

Fonte: Autor



3. REDES NEURAIS ARTIFICIAIS

O cérebro é um computador complexo, não linear e paralelo. Sua estrutura é constituída por neurônios que são capazes de realizar alguns processamentos: reconhecimento de padrões, percepção e controle motor [9].

É através da experiência que o cérebro é capaz de desenvolver suas regras e aprendizados. Dessa forma, este órgão inteligente é capaz de se impor e se adaptar ao ambiente o qual está inserido. Independentemente da situação a qual isso ocorre.

Pela sua grande capacidade de interpretar informações imprecisas, de forma extremamente rápida, o cérebro humano tem motivado pesquisas que buscam reproduzir as suas características computacionais [10]. E, portanto, vem à tona a ideia de Rede Neural.

As RNA's representam modelos matemáticos de neurônios biológicos. Sua estrutura é paralelamente distribuída e, segundo [9], possui a habilidade de armazenar comportamento experimental e torna-lo disponível para uso. De maneira geral, [9] relaciona o comportamento das redes neurais ao do cérebro em dois aspectos:

“1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;

2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.”

As redes neurais possuem a capacidade de resolver problemas complexos. A sua habilidade de aprender e generalizar é uma ferramenta poderosa para diversas situações de processamento de informações. Entretanto, essa ferramenta deve trabalhar junto com uma abordagem consistente de engenharia de sistemas [9].

Algumas capacidades garantem às redes neurais a habilidade de resolver problemas complexos, são elas [9]:


- Aprendizagem;
- Generalização;
- Não-linearidade;
- Adaptabilidade;
- Tolerância a falhas;
- Resposta a evidências;

Essas características permitem às redes neurais uma boa capacidade de estimar resoluções boas para problemas complexos. E por esse motivo elas podem ser empregadas como um método alternativo para a resolução de problemas de engenharia. Conforme mencionado, o seu comportamento se baseia na organização do neurônio biológico. Esse aspecto e alguns outros pontos importantes no entendimento das RNA's serão abordados nos tópicos a seguir.

3.1. O NEURÔNIO ARTIFICIAL

O neurônio é o elemento básico de uma rede neural. Pode-se descrevê-lo como uma unidade de processamento de informação fundamental para o funcionamento de uma rede. A Figura 3.1 apresenta uma estrutura básica do neurônio artificial de uma RNA, retirada de [11].

Fig. 3.1 Estrutura básica de um neurônio artificial. Fonte: [11].



Observando a Figura 3.1, pode-se destacar três elementos básicos do modelo: o conjunto de elos de conexão e seus respectivos pesos sinápticos ($w_1, w_2, \dots, w_n$), um somador

que faz a operação de combinação linear entre as respectivas sinapses do neurônio e a função de ativação, utilizada para limitar a amplitude do sinal de saída a um valor permissível.

De forma geral, pode-se representar matematicamente um neurônio artificial através de um par de equações conforme segue:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.1)$$

$$y_k = \phi(u_k + b_k) \quad (2.2)$$

Onde $x_1, x_2, \dots, x_m$ representam as entradas, $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos, u_k é a saída do combinador linear, b_k é o vetor bias – que tem a função de limitar a entrada líquida do somador [9], $\phi(-)$ representa a função de ativação e y_k é a saída do neurônio.


Considerando a presença externa do parâmetro bias, pode-se modelar o neurônio através das equações (2.3) e (2.4).

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (2.3)$$

$$y_k = \phi(v_k) \quad (2.4)$$

E então, conforme descrito em [9], tem-se um modelo não-linear do neurônio artificial apresentado na Figura 3.2.

Fig. 3.2 Modelo não-linear do neurônio artificial. Fonte: Adaptado de [9].




3.2. TIPOS DE FUNÇÃO DE ATIVAÇÃO

As funções de ativação definem a saída de um neurônio, e majoritariamente são de três tipos: função limiar, função linear por partes e função sigmóide.

A função limiar, apresentada na Figura 3.3 possui a seguinte definição:

$$\varphi(v) = \begin{cases} 0, & v < 0 \\ 1, & v \geq 0 \end{cases} \quad (2.5)$$


Fig. 3.3 Função de ativação limiar: *função de heaviside*. Fonte Adaptado de [9].



A função linear por partes, com o comportamento apresentado na Figura 3.4, possui a seguinte definição:

$$\varphi(v) = \begin{cases} 1, & v \geq \frac{1}{2}, \\ v, & \frac{1}{2} > v > -\frac{1}{2}, \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (2.6)$$


Fig. 3.4 Função linear por partes. Fonte: Adaptado de [9].



E por fim a função mais utilizada na ativação de redes, a função sigmóide possui um gráfico com formato de “S”, conforme Figura 3.5. Essa função é definida como uma função estritamente crescente com um comportamento balanceado adequadamente entre regiões lineares e não lineares. Como exemplo, tem-se a função logística em (2.7) [9], na qual α representa o parâmetro de inclinação da função.

$$\varphi(v) = \frac{1}{1+e^{-\alpha v}} \quad (2.7)$$

Fig. 3.5 Função sigmóide. Fonte: Adaptado de [9].



Por se tratar de uma função não linear, a saída de sua camada tende a ser não linear, variando entre zero e um. Seu formato de “S” apresenta uma curva suave entre esses valores, isso significa que é uma função diferenciável no seu percurso. Diante disso, há alguns problemas quando os gradientes ficam muito pequenos, acarretando problemas no aprendizado da rede.

A função de ativação tangente hiperbólica é semelhante à função sigmóide, com a mesma forma ela varia entre -1 e 1. Por ser uma função não linear, também é possível fazer *backpropagation* nos erros.

Um problema no uso das funções de ativação é que elas precisam que os valores de entradas estejam parametrizados em uma escala adequada, através da normalização. A não observância desse aspecto pode levar a saturação da função, o que pode comprometer a taxa de aprendizado da rede.

3.3. PRINCIPAIS ARQUITETURAS DE REDES NEURAI


Após compreender a estrutura do neurônio, é possível associar que uma rede neural se trata de um conjunto desses elementos associados. A distribuição dos neurônios em uma rede, determina a característica geral do algoritmo de aprendizado a ser utilizado para treiná-la. Em geral, a RNA pode ser de três classes diferentes, conforme serão descritas a seguir.

3.3.1. *Redes Feedforward de Camada Única*

É a forma mais simples de rede neural. Nela, os neurônios estão organizados em uma única camada e a saída de cada um deles constitui uma saída da rede.

A rede é denominada *feedforward*, pois, o sentido de propagação dos sinais de entrada é somente unilateral e não vice e versa, ou seja, os neurônios de fonte fornecem os sinais de entrada para a camada de saída. Portanto, não há laço de realimentação.

Fig. 3.6 Rede alimentada adiante com uma camada. Fonte: [10]




3.3.2. *Redes Feedforward de múltiplas camadas*

Essa classe de rede neural se diferencia da anterior pela presença de uma ou mais camadas intermediárias, denominadas de ocultas. Por serem elementos, como dito, intermediários, a função dos neurônios ocultos é intervir entre a entrada e a saída da rede.

Por conta do aumento do número de iterações e de um número maior de conexões sinápticas, a rede adquire uma perspectiva global, o que garante a camada oculta, a capacidade de extrair estatísticas elevadas.

Algumas redes possuem múltiplas camadas ocultas. O exemplo mostrado na Figura 3.7, apresenta uma rede de duas camadas ocultas, totalizando quatro camadas resultantes. Esse tipo de arquitetura de rede é chamado de Perceptrons Multicamadas (ou MLP's – *Multilayer Perceptrons*).

Fig. 3.7 Rede feedforward de múltiplas camadas. Fonte: [12]




3.3.3. Redes Recorrentes

As redes recorrentes se distinguem das anteriormente apresentadas pelo fato de apresentar um laço de realimentação na camada de entrada. A presença desses elementos de realimentação impacta diretamente na capacidade de aprendizagem da rede e no seu desempenho. Esse laço pode resultar em um comportamento dinâmico não linear para entradas não lineares.

Um exemplo de arquitetura de rede recorrente é apresentado na Figura 3.8.

Fig. 3.8 Arquitetura de uma rede neural recorrente com atraso unitário. Fonte: [10].



3.4. O PROCESSO DE APRENDIZAGEM

A característica primordial de uma rede é a capacidade de aprender. Através de um processo de aprendizado, a RNA se adapta ao ambiente e melhora o seu desempenho. Este, por sua vez, é marcado por uma série de iterações e ajustes nos pesos sinápticos associados as camadas. O grau de instrução de uma rede neural é aumentado a cada iteração neuronal [9].

Pode-se dizer que o aprendizado se consolidou quando a rede atinge uma solução generalizado para o problema submetido. A maioria dos modelos possui uma regra de treinamento e a rede aprende por exemplos de casos reais anteriormente submetidos a ela.

Nesta seção será dada prioridade ao processo de aprendizado de uma MLP – Perceptron de múltiplas camadas.

3.4.1. *Aprendizagem do Perceptron de Múltiplas Camadas – Retropropagação*

De forma iterativa, esse algoritmo tem a função de minimizar a função de custo igual à diferença média quadrática entre a saída alvo e a saída da rede neural. Na fase de treinamento há dois passos: um de propagação e um de retropropagação [9].

Neste primeiro passo, um padrão conhecido é apresentado a rede e as funções de ativação são computadas, camadas após camadas até os valores chegarem nas camadas de saída. O passo de retropropagação atualiza as conexões da rede utilizando os erros computados na camada de saída, seguindo o fluxo desta até a camada de entrada. Este processo requer uma função de ativação que varia suavemente, como é o caso da sigmoideal [9].

Este tipo de solução foi proposto para corrigir o problema da forma de onda saturada dos transformadores de corrente, mencionada nos capítulos iniciais desse trabalho. Através da arquitetura da MLP, os sinais amostrados foram utilizados como dados de treino e teste para o aprendizado da rede. O processo será descrito a seguir.

3.5. MÉTODO DE CORREÇÃO DA CORRENTE SATURADA POR MEIO DE UMA MLP

A partir das situações de falta apresentadas no capítulo 2, foram gerados os dados do conjunto de treinamento da rede MLP, para correção da distorção da corrente secundária do TC devido a saturação. Os vetores referentes às correntes primárias do TC, com ganho ideal, foram utilizados como dados alvos da rede. E, a partir das entradas, que foram as correntes secundárias, ela deve ser capaz de atingir seu alvo durante o treinamento. As correntes do secundário foram utilizadas como entrada porque, na prática, são estes os dados que estariam disponíveis.

Após o treino e validação, o esperado é que a rede neural apresente uma correção satisfatória, quando submetida a diferentes situações. Para a camada de entrada, definiu-se 15 neurônios, sendo que o primeiro recebe o sinal atual da amostra e os demais, cada um com atraso unitário em relação ao outro, recebe os 15 pontos anteriores da amostra.

Geralmente, as entradas da rede neural devem ser normalizadas, para atenderem as características das suas funções de ativação. Entretanto, nessa rede desenvolvida, não há a necessidade de normalização dos valores de entrada porque a mesma trabalha apenas com uma variável.

A saída, com apenas uma camada deve apresentar uma série temporal da corrente corrigida. Na Figura 3.9, tem-se a representação da arquitetura de rede usada. Na Figura

3.10(a) e 3.10(b) pode-se ver, conforme a implementação em ambiente *Simulink* os atrasos mencionados.

Fig. 3.9 Perceptron de múltiplas camadas utilizado para corrigir a forma de onda distorcida de um TC saturado. Fonte: Autor.






Fig. 3.10 Implementação em ambiente *Simulink* da MLP utilizada. Fonte: Autor.



(a)



(b)

Conforme visto na Figura 3.9, a arquitetura da rede utilizada é composta por:

- 15 neurônios na camada de entrada;
- Duas camadas intermediárias de 20 e 10 neurônios, respectivamente, e função de ativação sigmóide;
- E uma camada de saída com um neurônio e função de ativação linear.

O conjunto de treinamento foram as condições de falta apresentadas no capítulo 2, bem como a operação normal do TC. Para teste foram submetidas algumas situações que a rede não havia tido contato, sendo elas diferentes faltas para diferentes condições de carga.

A Figura 3.11 apresenta as características de treino da rede com um tempo de treino de 35 segundos, foram 546 épocas até a rede atingir o critério de parada. O método de treinamento adotado foi o *Levenberg-Marquardt*. Na figura 3.12 tem-se a performance da rede treinada, que será avaliada no capítulo de resultados.

Figura 3.11 Características de treino da rede neural MLP. Fonte: Autor.





Figura 3.12 Performance da MLP após 35 segundos de treino. Fonte: Autor.



Vale mencionar que a arquitetura utilizada foi ajustada com base na tentativa e erro, isto é, iniciou-se o treinamento com um número baixo de neurônios e baseado na performance da rede (neste caso o erro quadrático médio), adicionou-se mais neurônios/camadas até que o erro fosse aceitável. Este procedimento foi realizado observando-se os cuidados com sobreajuste para que a rede apresente boa capacidade de generalização para outras situações de curto-circuito e/ou diferentes níveis de saturação.

4. RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados das simulações utilizando a rede neural demonstrada no capítulo anterior. Primeiramente, os resultados obtidos pela rede quando submetida aos seus dados de treino e em seguida para algumas condições consideradas novas para a RNA para verificar a capacidade de generalização. Por fim, a partir da modelagem do sistema de um relé de sobrecorrente, será demonstrada a ideia de um dos impactos que a saturação do TC pode gerar nos dispositivos de proteção.


Antes de apresentar as formas de onda relevantes, a saída da rede neural passou por um filtro Butterworth, com o objetivo de eliminar as suas componentes de alta frequência. Sua frequência de corte foi fixada em $6 \times 60 = 360$ Hz.

4.1. FALTA MONOFÁSICA

Neste primeiro cenário avaliou-se o comportamento do TC e da rede neural proposta diante de uma falta monofásica. Neste instante, assumiu-se que a carga no sistema de potência era de 25 MVA, e a resistência de burden foi mantida em 1Ω .


A Figura 4.1 apresenta a comparação entre as três correntes de interesse, a corrente primária ideal, considerando o RTC (amarelo), a corrente secundária distorcida (azul) e a corrente corrigida pela rede neural (laranja). Nota-se que há um certo erro entre a corrente alvo (secundária ideal) e a corrente de saída da RNA. Entretanto, ao comparar-se com a corrente distorcida pela saturação, pode-se concluir a eficácia da correção da rede.

Fig. 4.1 Comparação entre as correntes – I_s ideal, I_s e corrente de saída da rede para a situação de falta monofásica. Fonte: Autor.



Na Figura 4.2, estão apresentadas as mesmas correntes, mas após o canal de entrada do relé que é composto pelo bloco *Fourier analysis* que apresenta os valores eficazes que serão lidos pelo relé.


Fig. 4.2 Comparação entre as correntes eficazes para a situação de falta monofásica. Fonte: Autor.



Observando-se as curvas apresentadas e considerando essa situação apenas para comparação, se fosse definido um I_{pickup} para o relé de 60 A, ao enviar o sinal de corrente distorcida o dispositivo não seria capaz de enviar o *trip* para o disjuntor. Entretanto, com a corrente da rede, a situação é melhorada e o IED envia o sinal de *trip*, conforme visto na Figura 4.3.

Fig. 4.3 TRIP do relé para a situação de falta monofásica a partir da corrente corrigida pela rede.


Fonte: Autor.



4.2. FALTA BIFÁSICA

Ainda com a carga do sistema de potência em 25 MVA e resistência de burden igual a 1Ω , avaliou-se o comportamento do TC e da rede neural diante de uma falta bifásica.


A Figura 4.4 apresenta a sobreposição das correntes do TC. Em amarelo a corrente primária após o fator de transformação, em azul a corrente secundária distorcida e em laranja a corrente corrigida pela rede. Agora para a situação de falta bifásica, nota-se que mesmo com um certo erro a correção é satisfatória.

Fig. 4.4 Comparação entre as correntes – I_s ideal, I_s e corrente de saída da rede para a situação de falta bifásica. Fonte: Autor.

Nota-se que no começo a rede apresenta uma diferença bastante acentuada. Isso acontece, pois, nas primeiras 15 amostras ela não tem valores de entrada associada, devido aos atrasos unitários acrescentados na camada de entrada.


Analisando os valores RMS, pode-se reforçar a eficácia da correção obtida pelo algoritmo, porque a diferença para a corrente distorcida é bastante significativa. Na Figura 4.5 tem-se a comparação entre os três sinais de corrente.

Fig. 4.5 Comparação entre as correntes eficazes para a situação de falta bifásica. Fonte: Autor.



Da mesma forma que na análise da situação anterior, ao mudar a corrente de *pick-up* do relé para 100 A, pode-se perceber pela figura 4.5 que a corrente distorcida pela saturação é incapaz de provocar o TRIP para comandar o dispositivo de abertura do circuito. Entretanto, o comando resultante na Figura 4.6 é proveniente da corrente corrigida pela rede MLP.


Fig. 4.6 TRIP do relé para a situação de falta bifásica a partir da corrente corrigida pela rede. Fonte: Autor.



4.3. FALTA TRIFÁSICA


Seguindo o mesmo padrão de apresentação das situações anteriores, a Figura 4.7 apresenta a comparação entre as correntes primária, secundária e corrigida pela rede, para o TC saturado.

Fig. 4.7 Comparação entre as correntes – I_s ideal, I_s e corrente de saída da rede para a situação de falta trifásica. Fonte: Autor.



Apesar de a saturação do transformador acentuar mais a distorção de corrente para a falta monofásica, a rede consegue estimar bem a forma de onda esperada. Esse aspecto reforça a característica de generalização e adaptabilidade de uma rede neural. Na Figura 4.8, estão apresentados os valores eficazes e fica evidente que a distorção impacta de uma maneira muito grande na leitura do relé.


Fig. 4.8 Comparação entre as correntes eficazes para a situação de falta trifásica. Fonte: Autor.



De maneira equivalente, apenas para exemplificação, ao ajustar a corrente de *pick up* do relé para 100 A, o mesmo não identifica falta no sistema a partir da corrente secundária do TC. Entretanto, com a corrente da rede, a distorção é corrigida garantindo a leitura do dispositivo, Figura 4.9.

Fig. 4.9 TRIP do relé para a situação de falta trifásica a partir da corrente corrigida pela rede. Fonte:

Autor.



Ao submeter a rede a situações as quais a mesma já teve contato, os resultados de correção são satisfatórios. No próximo tópico a ideia é avaliar a tendência de generalização da mesma, para condições diferentes das de treino.

4.4. DIFERENTES CONDIÇÕES DE ENTRADA PARA O ALGORITMO

A primeira análise será a de uma condição de falta a qual a rede não foi submetida em treino: curto bifásico-terra. Apesar de não ser uma situação comum, é importante observar o comportamento da correção proposta também para essa situação. Portanto, tem-se nas Figuras 4.10, 4.11 e 4.12 a comparação entre as correntes do TC, os valores eficazes e o trip do relé para um ajuste (apenas para exemplificação) de 100 A, respectivamente.

Fig. 4.10 Comparação entre as correntes – I_s ideal, I_s e corrente de saída da rede para a situação, estranha a rede, de falta bifásica-terra. Fonte: Autor.




Fig. 4.11 Comparação entre as correntes eficazes para a situação, estranha a rede, de falta bifásica-terra. Fonte: Autor.






Figura 4.1

Fig. 4.12 TRIP do relé para a situação, estranha a rede, de falta bifásica-terra a partir da corrente corrigida pela rede. Fonte: Autor.




Ainda com o intuito de validar a generalização da rede neural para o problema abordado, será apresentado a seguir duas condições de falta já vistas, mas para uma carga diferente. Na Figura 4.13 tem-se as formas de onda para um curto monofásico com uma carga reduzida, agora de 22 MVA.

Fig. 4.13 Comparação entre as correntes – I_s ideal, I_s e corrente de saída da rede para a situação, estranha a rede, de carga menor (22 MVA) e curto monofásico. Fonte: Autor.




Na Figura 4.14, reduziu-se ainda mais a condição de carga – agora para 20 MVA - e aplicou-se um curto trifásico para submeter à rede. De maneira a reforçar a sua característica de generalização, a mesma apresentou uma correção satisfatória para a corrente corrigida.

Fig. 4.14 Comparação entre as correntes – I_s ideal, I_s e corrente de saída da rede para a situação, estranha a rede, de carga menor (20 MVA) e curto trifásico. Fonte: Autor.



Por fim, submeteu-se à rede neural, a situação de operação normal do TC. Para visualização do resultado, a Figura 4.15 apresenta a comparação entre as formas de onda. Nota-se que a rede consegue estimar bem a corrente primária, exceto pelos primeiros 15 pontos a qual a mesma não tem parâmetro suficiente para estimação.

Figura 4.15 Comparação entre as correntes I_s ideal, I_s e a corrente de saída da rede para a situação de operação normal do TC. Fonte: Autor.



4.5. CONCLUSÃO DO CAPÍTULO DE RESULTADOS

Diante dos resultados apresentados, nota-se uma boa característica de generalização da rede neural desenvolvida. Dessa forma, o objetivo de propor um algoritmo de correção da distorção da corrente secundária de um transformador de corrente por consequência de sua saturação foi atingido.

Portanto, mostrou-se que a leitura errônea de um relé ligado a um TC saturado, também pode ser corrigida com essa técnica, que vem sendo bastante utilizada atualmente. O código utilizado para amostragem e treino, bem como o sistema modelado para o *trip* do relé de sobrecorrente, podem ser vistos nos apêndices deste trabalho.

5. CONCLUSÕES GERAIS

Compreender um sistema de proteção é muito importante na área de sistemas de potência. Os dispositivos de proteção são responsáveis por isolar um circuito que está submetido a alguma anormalidade, que pode ser prejudicial aos equipamentos energizados, de maneira a manter a integridade das instalações elétricas.

Um dos aspectos mais importantes para o funcionamento do sistema de proteção é a boa leitura dos sinais feita pelos dispositivos responsáveis pela sua lógica e filosofia. Entretanto, conforme foi apresentado, um transformador de corrente quando saturado, pode mascarar a leitura de um relé por meio da distorção de sua corrente secundária.

Como uma maneira de corrigir essa distorção causada pela saturação do TC, foi proposto um algoritmo baseado na arquitetura de rede neural denominada Perceptron de Múltiplas. Para isso, modelou-se um sistema trifásico e submeteu-se a RNA com três situações de curto circuito e uma operação normal para treino e validação.

Após isso, mostrou-se que esse tipo de arquitetura pode apresentar resultados satisfatórios para correção do problema apresentado, pois, mesmo quando a rede foi exposta a situações diferentes das utilizadas para treino, a mesma apresentou a sua característica de generalização, consolidando-se assim o seu aprendizado. Entretanto, a sua desvantagem é que para associar a rede neural com transformadores de corrente com características diversas, são necessários novos treinos.

Como trabalhos futuros propõe-se explorar a saturação do TC quando do mau dimensionamento da sua resistência de *Burden*, ou seja, em alguns casos, os cabos que ligam os relés ao secundário possuem comprimento muito grande, chegando a extrapolar a impedância nominal de carga do transformador.

Além disso, propõe-se explorar outras arquiteturas de redes neurais afim de fazer uma análise comparativa, uma sugestão seria utilizar uma rede neural recorrente e uma rede neural de base radial (RBF).

6. REFERÊNCIAS

- [1] João Mamede Filho, *Proteção de Sistemas Elétricos de Potência*, Rio de Janeiro: LTC, 2013.
- [2] F. B. Ajaei, M. Sanaye-Pasand, M. Davarpanah, A. Rezaei-Zare, R. Iravani, " Compensation of the Current-Transformer Saturation Effects for Digital Relays." In: IEEE TRANSACTIONS ON POWER DELIVERY - VOL. 26, NO. 4, OCTOBER 2011.
- [3] Y. C. KANG, S. H. U. J. KANG, " Compensating algorithm suitable for use with measurement-type current transformers for protection." In: GENERATION, TRANSMISSION AND DISTRIBUTION, IEE PROCEEDINGS, V. 152, N. 6, P. 880-890, NOV. 2005.
- [4] Y. C. KANG, J. K. S. H. KANG, A. T. P. JOHNS, R. K. AGGARWAL, " Development and hardware implementation of a compensating algorithm for the secondary current of current transformers" In: IEEE PROCEEDINGS - ELECTRIC POWER APPLICATIONS. V.143, N.1,P.41-49, JAN 1996.
- [5] S. L. Maia Lacerda, G. H. Riberio Carneiro, "Dispositivos eletrônicos inteligentes (ied's) e a norma iec 61850: união que está dando certo". Em: INSTITUTO FEDERAL DE EDUCAÇÃO CIÊNCIA E TECNOLOGIA DA PARAÍBA.
- [6] João Mamede Filho, *Manual de Equipamentos Elétricos*, 4. ed. - Rio de Janeiro: LTC, 2013.
- [7] ABNT. (2015, Fevereiro) ABNT Catálogo. [Online]. <https://www.abntcatalogo.com.br/norma.aspx?ID=329301>
- [8] Geraldo Kindermann, *Curto Circuito*, 2. ed. Porto Alegre: SAGRA LUZZATTO, 1977.
- [9] Haykin Simon, *Redes Neurais: Princípios e Prática*, 2. ed. Porto Alegre RS: BOOKMAN, 2001.

-
- [10] M. A. Rosely, " Correção da saturação de transformadores de corrente via redes neurais artificiais e seus efeitos na proteção de distância" em: COPPE/UFRJ, M.Sc, Engenharia elétrica, 2007.
- [11] J. A. Fabro, "Redes Neurais Artificiais", em: CURSO DE ESPECIALIZAÇÃO EM INTELIGÊNCIA COMPUTACIONAL, UTFPR, AGOSTO 2001.
- [12] "DEEP LEARNING BOOK BRASIL," Capítulo 9 - A Arquitetura de Redes Neurais. Data Science Academy.
- [13] J. F. DIAS BREDA, " Um modelo computacional para o relé digital de sobrecorrente empregado na proteção de sistemas elétricos de potência", Trabalho de conclusão de curso. Em: ESCOLA DE ENGENHARIA SÃO CARLOS USP, SÃO CARLOS SP, 2009

7. APÊNDICE A-MODELOS DE SIMULAÇÃO

Código utilizado para amostragem do sinal e treino da RNA:

```
close all
clc
Ts = 2e-4;
clear out1 in1 in2 in3 in4 in5 in6 in7 in8 in9 in10 in11 in12 in13 in14
in15

amostras = 15;
k = 1;

for a=amostras:1:size(Ip,1)
    out1(1,k) = Ip(a,1);

    in1(1,k) = Is(a,1);
    in2(1,k) = Is(a-1,1);
    in3(1,k) = Is(a-2,1);
    in4(1,k) = Is(a-3,1);
    in5(1,k) = Is(a-4,1);
    in6(1,k) = Is(a-5,1);
    in7(1,k) = Is(a-6,1);
    in8(1,k) = Is(a-7,1);
    in9(1,k) = Is(a-8,1);
    in10(1,k) = Is(a-9,1);
    in11(1,k) = Is(a-10,1);
    in12(1,k) = Is(a-11,1);
    in13(1,k) = Is(a-12,1);
    in14(1,k) = Is(a-13,1);
    in15(1,k) = Is(a-14,1);

    k=k+1;
end

entradas = [in1; in2; in3; in4; in5; in6; in7; in8; in9; in10; in11;
in12; in13; in14; in15];
saidas = out1;

%entradas1 = entradas;      % Trifásico-terra
%saidas1 = saidas;

%entradas2 = entradas;      % Monofásico-terra
%saidas2 = saidas;

%entradas3 = entradas;      % Bifásico
%saidas3 = saidas;
```

```
%entradas4 = entradas;      % Atuação normal
%saidas4 = saidas;

IN = [entradas1 entradas2 entradas3 entradas4];
OUT = [saidas1 saidas2 saidas3 saidas4];

% Cria a rede
netA1 = newff(IN,OUT,[20,10],{'tansig' 'tansig' 'purelin'},'trainlm');

% Treina a rede
netA1.trainParam.epochs = 3000;
netA1.trainParam.goal = 0.05;
netA1.trainParam.max_fail = 1000;
netA1.trainParam.min_grad = 0;
tic
[netA1,tr] = train(netA1,IN,OUT);
toc

return

gensim(netA1,Ts)
```

Fig. 2 Modelagem do relé de sobrecorrente em ambiente *Simulink*. Fonte: [12].

