

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROJETO DE GRADUAÇÃO**

CRISTINA MARCHIORI MIRANDA

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA
LOCALIZAÇÃO DE FALTAS EM REDES DE MÉDIA
TENSÃO AUTOMATIZADAS E COM GERAÇÃO
DISTRIBUÍDA**

VITÓRIA
2020

CRISTINA MARCHIORI MIRANDA

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS PARA
LOCALIZAÇÃO DE FALTAS EM REDES DE MÉDIA TENSÃO
AUTOMATIZADAS E COM GERAÇÃO DISTRIBUÍDA**

Parte manuscrita do Projeto de Graduação da aluna **Cristina Marchiori Miranda**, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheira Eletricista.

Orientador: Prof. Dr. Oureste Elias Batista

VITÓRIA
2020

CRISTINA MARCHIORI MIRANDA

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA
LOCALIZAÇÃO DE FALTAS EM REDES DE MÉDIA TENSÃO
AUTOMATIZADAS E COM GERAÇÃO DISTRIBUÍDA**

Parte manuscrita do Projeto de Graduação da aluna **Cristina Marchiori Miranda**, apresentado ao Departamento de Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Engenheira Eletricista.

Aprovada em 18 de dezembro de 2020.

COMISSÃO EXAMINADORA:

Prof. Dr. Oureste Elias Batista
Universidade Federal do Espírito Santo
Orientador

Profa. Dra. Tiara Rodrigues Smarssaro de Freitas
Universidade Federal do Espírito Santo
Examinadora

Ma. Mariana Altoé Mendes
Universidade Federal do Espírito Santo
Examinadora

À minha mãe pelo suporte e confiança em praticamente todos os momentos da vida e aos meus amigos por estarem sempre ao meu lado, não me deixando desistir.

RESUMO

Durante as últimas décadas, devido a questões de ordem ambiental, econômica e política, tem-se aumentado o interesse na utilização de fontes limpas e renováveis de energia. Nesse contexto, a geração distribuída fotovoltaica se destaca pelo seu potencial de geração. No entanto, os sistemas de distribuição com alta penetração de geração distribuída fotovoltaica podem ter seu funcionamento diretamente afetado, já que os alimentadores deixam de apresentar fluxo de potência unidirecional por possuírem diversas fontes de geração. Um aspecto que é impactado é a proteção desses sistemas e, por isso, é importante pensar estratégias para mitigar possíveis problemas. Um processo muito relevante na proteção de sistemas elétricos de potência é a localização de faltas. Este trabalho visa estimar a localização de faltas em redes de distribuição de energia elétrica que possuem alta penetração de geração distribuída fotovoltaica utilizando redes neurais artificiais (RNAs). O alimentador utilizado é o IEEE *13-Node Distribution Test Feeder* no ambiente *Simulink*[®] do *software MATLAB*[®]. Foram aplicadas faltas monofásicas e trifásicas em diversos pontos do alimentador e, para cada uma delas, feitas todas as combinações de disponibilidade dos geradores fotovoltaicos. Isto inclui os casos em que nenhum deles está disponível, até o caso em que todos estão disponíveis, gerando 512 combinações. A inferência da distância das faltas foi realizada por meio de RNAs utilizando dados provenientes de medidores inteligentes posicionados ao longo do alimentador. O desempenho das redes neurais foi analisado por meio dos parâmetros de erro médio quadrático (MSE) e da regressão linear (R), sendo o melhor desempenho um MSE de $1,1408 \cdot 10^5$ e uma R de 99,994%. Também foram realizados testes de desempenho das RNAs a partir do pré-processamento dos dados de entrada por meio da análise de componentes principais. Foram utilizadas 4, 8 e 12 componentes principais, elas obtiveram bons resultados, mas as redes treinadas com todos os dados as superaram. Foi utilizada uma rede neural artificial para classificação do trecho em que ocorreu a falta e seu total de acertos foi de 93,33%.

Palavras-chave: Localização de faltas. Geração distribuída. Redes neurais artificiais. Análise de componentes principais.

ABSTRACT

During the last decades, due to environmental, economic and political issues, interest in the use of clean and renewable energy sources has increased. In this context, distributed photovoltaic generation stands out for its generation potential. However, distribution systems with high penetration of distributed photovoltaic generation may have their operation directly affected, since the feeders no longer present unidirectional power flow because they have several generation sources. A very relevant process that is impacted by distributed generation is the protection of electric power systems, specially fault location. This work aims to estimate the location of faults in electricity distribution networks that have a high penetration of distributed photovoltaic generation using artificial neural networks. The feeder used is the IEEE 13-Node Distribution Test Feeder in the Simulink[®] environment of the MATLAB[®] *software*. Single-phase and three-phase faults were applied to different points of the feeder and, for each one, all combinations of availability of photovoltaic generators were made. This includes the cases where none of them are available, until the case where all are available, generating 512 combinations. The fault distance inference was performed using artificial neural networks using data from smart meters positioned along the feeder. The performance of the Neural Networks was analyzed using the parameters mean square error (MSE) and linear regression (R), with the best performance being an MSE of $1,1408.10^5$ and an R of 99.994%. Performance tests of artificial neural networks were also performed from the pre-processing of the input data using the principal component analysis: using 4, 8 and 12 main components they obtained good results, but the networks trained with all the data overcame. An artificial neural network was used to classify the section in which a fault occurred, and its total number of correct answers was 93.33%.

Keywords: Fault location. Distributed generation. Artificial neural networks. Principal component analysis.

LISTA DE FIGURAS

Figura 1 – Sistema trifásico desequilibrado e suas componentes simétricas: (a) sistema desequilibrado; (b) sequência positiva; (c) sequência negativa; (d) sequência zero	23
Figura 2 – Modelo matemático do neurônio artificial	25
Figura 3 – Modelo de rede neural	26
Figura 4 – Modelo simplificado do alimentador	31
Figura 5 – Modelo do alimentador no <i>Simulink</i> [®]	32
Figura 6 – Modelo do alimentador completo para simulação	33
Figura 7 – Modelo simplificado do sistema fotovoltaico	34
Figura 8 – Interface da ferramenta para treinamento da rede neural	38

LISTA DE GRÁFICOS

Gráfico 1 – Histograma mostrando os erros dos conjuntos de treinamento, validação e teste da rede com todas as variáveis e 20 neurônios na camada oculta	42
Gráfico 2 – Regressão linear da rede com todas as variáveis e 20 neurônios na camada oculta: (a) Treinamento, (b) Validação, (c) Teste e (d) Todas	43

LISTA DE TABELAS

Tabela 1 – Desempenho das RNAs com todos os dados na entrada para diferentes quantidades de neurônios.....	40
Tabela 2 – Desempenho das RNAs com 4 componentes principais para diferentes quantidades de neurônios.....	40
Tabela 3 – Desempenho das RNAs com 8 componentes principais para diferentes quantidades de neurônios.....	41
Tabela 4 – Desempenho das RNAs com 12 componentes principais para diferentes quantidades de neurônios.....	41
Tabela 5 – Desempenho das RNAs com diferentes dados de entrada, utilizando 20 neurônios	41
Tabela 6 – Taxa de acerto do classificador de trechos	43

LISTA DE QUADROS

Quadro 1 – Comprimentos dos trechos do alimentador	32
Quadro 2 – Variância retida em função da quantidade de componentes principais.....	38

LISTA DE ABREVIATURAS E SIGLAS

GD	Geração Distribuída
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
PCA	<i>Principal Components Analysis</i>
RNAs	Redes Neurais Artificiais
SEPs	Sistemas Eléctricos de Potência
UFES	Universidade Federal do Espírito Santo

LISTA DE SÍMBOLOS

V_{a0}	Componente de tensão de sequência zero (V)
V_{a1}	Componente de tensão de sequência positiva (V)
V_{a2}	Componente de tensão de sequência negativa (V)
V_a	Fasor de tensão do sistema equilibrado da fase a (V)
V_b	Fasor de tensão do sistema equilibrado da fase b (V)
V_c	Fasor de tensão do sistema equilibrado da fase c (V)
a	Operador de rotação em 120°
m	Número de entradas da rede neural
j	Índice da entrada da rede neural
k	Camada da rede neural
x_j	Entrada j da rede neural
w_k	Peso do neurônio kj da rede neural
b_k	<i>Bias</i> da camada k da rede neural
y_k	Saída k da rede neural
φ	Função de ativação
V_{fv}	Tensão terminal do gerador fotovoltaico (V)
P_{fv}	Potência ativa do gerador fotovoltaico (W)
I_{ca}	Corrente de saída do inversor (A)
V_{ca}	Tensão de saída do inversor (A)
α	Ângulo da corrente de saída do inversor ($^\circ$)
fp	Fator de potência do sistema

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Apresentação do Tema	13
1.2	Justificativas	14
1.3	Objetivos Geral e Específicos	16
1.3.1	Objetivo Geral.....	16
1.3.2	Objetivos Específicos.....	16
1.4	Organização do Trabalho	16
2	REFERENCIAL TEÓRICO	18
2.1	Geração Distribuída	18
2.1.1	Geração Fotovoltaica	19
2.2	Proteção de Sistemas Elétricos de Distribuição	20
2.2.1	Tipos de Falhas	22
2.2.2	Componentes Simétricas.....	22
2.3	Redes Neurais Artificiais	24
2.4	Análise de Componentes Principais	28
3	MÉTODOS E ETAPAS DE DESENVOLVIMENTO	30
3.1	Alimentador	30
3.2	Sistema Fotovoltaico	34
3.3	Faltas	35
3.4	Simulações	36
3.5	Experimentos com RNAs	37
4	RESULTADOS E DISCUSSÕES	40
5	CONCLUSÃO	44
	REFERÊNCIAS BIBLIOGRÁFICAS	46

1 INTRODUÇÃO

1.1 Apresentação do Tema

A emergência de uma crise sistêmica ambiental traz à tona a necessidade de mudança da percepção de mundo calcada no crescimento ilimitado e no uso indiscriminado de recursos naturais. É preciso colocar como central o compromisso intergeracional de conservação e recuperação na natureza, já que esta possibilita a vida (NUNES-VILLELA et al., 2017).

Por essas e outras razões de ordem econômica e política, tem-se aumentado o interesse pela utilização de fontes limpas e renováveis de energia. Para Lucon e Goldemberg (2009), o tripé da organização sustentável do sistema energético é constituído pela descentralização da produção de energia, pela maior participação de fontes renováveis e pela eficiência energética.

Nesse contexto, a geração distribuída (GD), que quase sempre está associada a fontes renováveis de energia, surge como ferramenta para possibilitar essa organização sustentável do sistema energético. A GD possibilita a redução das emissões de gases estufa e o alívio sobre sistemas elétricos de potência que se encontram sobrecarregados (MENDES, 2018).

A geração fotovoltaica, como fonte renovável, possui um enorme potencial de compor uma fatia maior da produção energética. No entanto, a adição de painéis fotovoltaicos ao longo dos alimentadores pode impactar diretamente no funcionamento da rede. Uma razão para isto é que, em algumas situações, o fluxo de potência passa a ser bidirecional, pois os centros consumidores podem estar sendo alimentados pela rede ou contribuindo na alimentação da rede. Desse modo, a expansão da geração distribuída fotovoltaica modificou bastante as redes de distribuição, transformando alimentadores com apenas uma fonte e característica radial em alimentadores com múltiplas fontes de geração (DEHGHANI; KHODNIA; DEHGHAN, 2017).

Com a modificação de diversos parâmetros da rede, como valores de tensão, corrente e frequência, pode haver uma operação inadequada dos dispositivos de proteção, já que o ajuste deles é realizado a partir desses parâmetros. Por tal motivo, é necessário repensar estratégias de

proteção de sistemas elétricos para que considerem a operação com alta inserção de GD fotovoltaica.

Um processo muito importante dentre os que são de responsabilidade da proteção de sistemas elétricos é a localização de faltas. Ele consiste na determinação do local exato, ou mais próximo possível, da causa do distúrbio na rede (ARAUJO, 2015). Isso é realizado por meio do processamento de informações dos parâmetros da rede no momento do distúrbio, fornecidos por equipamentos de medição inteligentes nela instalados.

A detecção exata da localização de um curto-circuito é muito complexa em redes de distribuição, em comparação a redes de transmissão, devido a aspectos como variação da carga, alta impedância de curto-circuito e ao fato de as redes de distribuição frequentemente possuírem cargas desbalanceadas e assimétricas (DEHGHANI; NEZAMI, 2013). E esse processo se torna ainda mais complexo quando a rede possui uma elevada penetração de GD. Métodos algorítmicos utilizados para localização de faltas costumam ter seu erro elevado quando expostos a essa situação (JOSE et. al, 2013). Portanto, torna-se importante o estudo de técnicas de localização de faltas considerando um sistema que possua alta inserção de GD, que é a intenção deste trabalho.

1.2 Justificativas

Inicialmente, o foco dos pesquisadores em localização de faltas foi em linhas de transmissão, devido seu alto impacto nos sistemas de potência e também, pelo fato de serem bem extensas, há a necessidade de um longo tempo de locomoção das equipes para a investigação da falta (DASHTAR; DASHTI; SHAKER, 2018). Além disso, a localização de faltas se torna mais complexa em sistemas de distribuição devido à alta ramificação, desbalanceamento de cargas e até falhas no registro e ajustes de equipamentos que atuam na proteção.

Nas concessionárias de energia, não é rara a utilização de técnicas empíricas para identificação das falhas. As mais comuns são a inspeção visual e o chaveamento por tentativa e erro. Se a região for pequena, é possível localizar a falha examinando o local a pé, enquanto em áreas maiores é comum a utilização de automóveis ou helicóptero (GURURAJAPATHY;

MOKHLIS; ILLIAS, 2017). É evidente, no entanto, que se trata de um processo moroso e que métodos automatizados de realizar essa tarefa são bastante importantes.

Dashtar, Dashti e Shaker (2018) indicam que há basicamente três classes de métodos de localização de faltas: os baseados em impedância e componentes de frequência principal, em alta frequência e ondas móveis e em conhecimento e cognição. O primeiro busca calcular a impedância até o ponto de falta a partir da medição de corrente e tensão em seu terminal. Entretanto, a alta ramificação das linhas de distribuição e a impossibilidade de obter essas medições para qualquer ponto sujeito a falta fazem com que sua aplicabilidade seja difícil. Já a segunda classe de métodos se baseia na reflexão e transmissão das ondas geradas no ponto de falta. Esses métodos possuem uma ótima precisão, mas são mais complexos e caros que o primeiro pois necessitam de equipamentos auxiliares. A terceira classe de método aplica técnicas como inteligência artificial, análise estatística e métodos híbridos. Quando bem aplicadas, estratégias fundamentadas em aprendizado podem mostrar flexibilidade e bom desempenho em diferentes condições, apesar das particularidades dos sistemas.

Em função da complexidade dos problemas na localização de faltas, a discussão destes e os resultados de diversos estudos na literatura científica podem ser vistos como um indicativo que as soluções tradicionais estão cada vez mais próximas de sua obsolescência. A dificuldade de um tratamento analítico e numérico tem impulsionado a aplicação de sistemas computacionais inteligentes, tais como as redes neurais artificiais (RNAs) (BATISTA, 2016).

As técnicas de RNAs têm sido utilizadas nas áreas de previsão de carga, diagnóstico e localização de faltas, despacho econômico, avaliação de segurança e estabilidade transitória. Suas principais vantagens são a capacidade de lidar com variações estocásticas do ponto de operação programado com aumento de dados, classificação e processamento online e rápido, modelagem não-linear implícita e filtragem de dados do sistema (RAYBOLT, 2011).

Como as tecnologias de redes inteligentes adicionarão uma grande quantidade de dados em tempo real, como informações de corrente e tensão obtidas através de sensores instalados nos equipamentos, existe um enorme potencial para o desenvolvimento de mais técnicas baseadas em RNAs para localização de faltas. Esse processo, no entanto, requer que algumas dificuldades sejam consideradas. Uma delas é a alta demanda de tempo para treinamento das redes, outra é

a aquisição e estruturação de dados para serem utilizados (GURURAJAPATHY; MOKHLIS; ILLIAS, 2017). Dados limitados ou imprecisos podem afetar o desempenho do algoritmo (PEREZ, VÁSQUEZ, VILORIS; 2019). Por este motivo, para auxiliar na operação das RNAs, pode ser interessante realizar um pré-processamento dos dados para que sejam escolhidos os mais relevantes e para que haja uma diminuição desse tempo para treinamento das redes.

1.3 Objetivos Geral e Específicos

1.3.1 Objetivo Geral

Estimar a localização de faltas em redes de distribuição de energia elétrica que possuem alta inserção de geração distribuída fotovoltaica utilizando RNAs.

1.3.2 Objetivos Específicos

- a) Utilizar um modelo de alimentador para realização das simulações de faltas monofásicas e trifásicas e da variação da disponibilidade da geração fotovoltaica;
- b) Obter uma base de dados do comportamento do alimentador sob diversos tipos de curto-circuito em diferentes locais;
- c) Aplicar técnicas de pré-processamento de dados para melhoria dos resultados das RNAs.

1.4 Organização do Trabalho

A seção 1 contextualiza o tema do trabalho, apresentando suas justificativas e objetivos durante seu desenvolvimento.

A seção 2 traz o referencial teórico em que se baseia o trabalho. Ela contextualiza o tema da geração distribuída, mais especificamente a fotovoltaica e aborda sobre a importância da proteção de sistemas elétricos na distribuição, além de comentar as principais causas de falhas nesses sistemas. A seção também trata das RNAs, suas funcionalidades e topologias e a técnica PCA, que será utilizada para pré-processamento dos dados.

A seção 3 apresenta os métodos e as etapas de desenvolvimento do trabalho. Ela mostra as características do alimentador escolhido, a modelagem do sistema fotovoltaico e do bloco de faltas e como se deu a simulação do sistema. Além disso, a seção evidencia como se realizou a escolha das RNAs, seus parâmetros e seus dados de entrada, inclusive o número de componentes principais a serem utilizadas.

A seção 4 demonstra os resultados obtidos a partir das RNAs, juntamente com as métricas utilizadas para avaliar se elas foram eficientes na inferência da localização das faltas.

A seção 5 apresenta realiza um balanço sobre o trabalho desenvolvido e seus resultados.

2 REFERENCIAL TEÓRICO

2.1 Geração Distribuída

Os sistemas elétricos de potência (SEPs) são compostos por equipamentos que atuam de forma coordenada para fornecimento de energia elétrica com atenção a parâmetros como qualidade, segurança e custo. Suas atividades incluem geração, transmissão e distribuição de energia.

Os SEPs desenvolveram-se mundialmente em um modelo baseado em plantas geradoras de grande porte interligadas aos centros de consumo por meio de longas redes de transmissão e distribuição, caracterizando uma topologia com um fluxo unidirecional de energia (VARGAS, 2018). Esse modelo, no entanto, baseia-se, principalmente, em fontes de energia poluentes e/ou não-renováveis, o que provoca problemas no nível socioambiental, mas também no econômico, já que existe um limite em sua disponibilidade e, em curto prazo, um aumento do custo de exploração.

Por conta disto e em consonância com o desenvolvimento tecnológico, houve um aumento no interesse pelo uso de fontes renováveis de energia, principalmente as mais próximas dos consumidores. Inicialmente, a GD era utilizada em áreas de difícil acesso para linhas de transmissão e distribuição. No entanto, o interesse pela geração descentralizada acabou por aumentar o escopo de sua aplicabilidade (MOTOYA-BUENO; MUÑOZ-HERNANDÉZ; CONTRERAS, 2016).

A Agência Nacional de Energia Elétrica (ANEEL), em seu Caderno Temático de Micro e Minigeração Distribuída, define GD da seguinte forma:

A geração distribuída é caracterizada pela instalação de geradores de pequeno porte, normalmente a partir de fontes renováveis ou mesmo utilizando combustíveis fósseis, localizados próximos aos centros de consumo de energia elétrica (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2016, p. 7)

Esses pequenos geradores ao longo da rede de distribuição proporcionam benefícios, mas também desvantagens. Os benefícios incluem a diminuição de investimento na expansão dos sistemas de distribuição e transmissão, redução do impacto ambiental, melhoria do nível de tensão na rede nos momentos de alta demanda e a diversificação da matriz energética. Já as

desvantagens se dão pelo aumento da complexidade de operação da rede e cobrança pela utilização do sistema elétrico, além do pagamento de impostos e a necessidade de mudanças nos procedimentos das distribuidoras para operação, controle e proteção de suas redes (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2016).

O aumento na complexidade de operação da rede se dá por conta de eventuais mudanças nos perfis de tensão, corrente e fluxo de potência. Essas modificações podem ocorrer devido ao surgimento de fluxo reverso de potência em sistemas que foram projetados para operar em fluxos unidirecionais, impactando, por exemplo, na operação dos equipamentos de proteção (BHISE; KANKALE; JADHAO, 2017).

2.1.1 Geração Fotovoltaica

A geração de energia elétrica por meio de painéis fotovoltaicos vem se expandindo nos últimos anos. No Brasil, esse processo não vem ocorrendo na mesma velocidade que em países europeus e nos Estados Unidos, no entanto, sua localização geográfica o coloca em certa vantagem (MENDES, 2018). O Brasil, devido ao seu posicionamento entre os trópicos, apresenta um ótimo nível e baixa variabilidade de irradiação solar, demonstrando enorme potencial para implementação de geração fotovoltaica (INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 2017).

Comparando com combustíveis fósseis, a geração fotovoltaica tem baixo impacto ambiental, possibilitando a redução de emissão de 69.100 milhões de toneladas de CO₂, entre 69.000 e 99.000 toneladas de NO_x, óxidos de nitrogênio, e entre 126 e 184 toneladas de SO₂ até 2030. Ela também é uma fonte abundante, silenciosa e que, por geralmente ser instalada nos telhados, não ocupa um espaço útil nas residências (SAMPAIO; GONZALÉZ, 2017). Seus custos de manutenção também são reduzidos, já que não possuem partes móveis.

Apesar do baixo impacto ambiental na geração de energia, há emissão de gases do efeito estufa no processo de produção e transporte dos painéis. Além disso, parte dos materiais que o compõem são provenientes da mineração, ou seja, recursos que não são renováveis e cuja exploração apresenta elevado impacto ambiental e social.

A GD pode ser dividida em microgeração, de potências menores ou iguais a 75 kW (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2015), e minigeração, de potência superior a 75 kW e inferior ou igual a 5 MW (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2017). Em 2019, o Brasil ultrapassou a marca de 1 GW de potência instalada em micro e minigeração distribuída, sendo que a fotovoltaica representava 870 MW em um total de 82,6 mil unidades geradoras (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2019).

2.2 Proteção de Sistemas Elétricos de Distribuição

Os SEPs, apesar de serem projetados para atuar em regime permanente e de forma contínua, estão expostos a condições que podem perturbar seu funcionamento. Quando isso ocorre, há a modificação de suas grandezas elétricas, a saber, tensão, corrente e frequência, fazendo com que atue fora de seu regime de operação normal. Esta é uma condição de falha do sistema, ou, como é mais comumente chamada, falta (KINDERMANN, 2010).

Falta elétrica é definida pela ABNT NBR 5460:1992 como uma “ocorrência acidental e súbita, ou defeito, em um elemento de um sistema elétrico, que pode resultar em falha do próprio elemento e/ou de outros elementos associados” (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 1992, p. 20). Para garantir que haja confiabilidade e continuidade no fornecimento de energia, enquanto isola rapidamente a região afetada, é necessário um sistema de proteção seletivo e eficaz.

No caso de sistemas de distribuição, há alguns aspectos que devem ser atendidos na proteção. Um deles envolve a proteção dos equipamentos contra danos que possam ser causados por curtos-circuitos ou sobrecarga; outro envolve isolar a menor parte possível do circuito em uma condição de falha, e pelo menor tempo (ELETROBRÁS, 1982). É importante que as regiões isoladas sejam reestabelecidas o mais cedo possível para que os consumidores não sejam prejudicados. Por outro lado, uma descontinuidade no fornecimento de energia elétrica pode implicar em multas para a distribuidora (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2018).

Para atuação na proteção, são utilizados religadores automáticos, relés, disjuntores e fusíveis. Esses equipamentos são posicionados de modo a criarem zonas de proteção, fazendo com que

o equipamento mais próximo da falha tenha uma atuação mais rápida, possibilitando a interrupção do fornecimento ao menor número de consumidores (VARGAS, 2018).

Atualmente, diversos desses equipamentos atuantes na rede são digitais e possuem comunicação com o Centro de Operação da concessionária de energia elétrica, podendo tanto enviar informações das condições em que a rede se encontra, quanto receber comandos em tempo real. A integração desses equipamentos “inteligentes” ao sistema elétrico forma um conjunto que vem sendo denominado redes elétricas inteligentes ou, no inglês, *smart grids*. Essas redes inteligentes combinam as novas tecnologias de informação, comunicação, medição e automação e promovem o desenvolvimento de técnicas avançadas de monitoramento, controle, operação e manutenção da rede (ARAUJO, 2015).

As redes inteligentes têm sido vistas como a principal solução para a modernização da infraestrutura do setor elétrico pela possibilidade de prover medição avançada, automação de sistemas e processos, trocas de informações bidirecionalmente em tempo real, aumento da eficiência e segurança energética, redução de perdas e custos, participação ativa dos consumidores, e maior viabilização da inclusão de fontes alternativas a matriz energética por meio da geração e microgeração distribuída, entre outros aspectos (ARAUJO, 2015, p. 38).

Como uma das funcionalidades das redes inteligentes é a medição inteligente, ela pode fornecer históricos de dados, parâmetros operacionais e diagnósticos do sistema. Todas essas informações podem auxiliar na identificação e localização de distúrbios, além da tomada de decisão acerca da solução desses problemas (ARAUJO, 2015).

A localização de faltas é uma das aplicações mais importantes dessas redes inteligentes, já que essa é uma das premissas para a operação econômica e confiável dos SEPs. Sua execução visa restabelecer o fornecimento de energia elétrica em tempo compatível com as exigências do conjunto de consumidores afetados pela interrupção ou a identificação de defeitos latentes que podem vir a comprometer a integridade do sistema e a segurança da população (BATISTA, 2016).

2.2.1 Tipos de Falhas

Há diversas situações que podem causar falhas em SEPs, algumas delas são: problemas de isolamento, mecânicos, elétricos, de natureza térmica, de manutenção e outros. Essas falhas podem ser permanentes ou temporárias (CAMINHA, 2004).

As temporárias comumente ocorrem por conta de toque breve entre cabos, entre cabos e árvores ou animais, tensões induzidas por descargas atmosféricas indiretas ou perda de isolamento. Essas falhas temporárias podem ter seus efeitos mitigados por meio da atuação do religamento automático da rede (CAMINHA, 2004).

Já as permanentes podem ser causadas por rompimentos de cabos, quedas de árvores sobre a rede, queda de postes, descargas atmosféricas diretas, vandalismos e queimadas. Como elas costumam realizar um dano físico à rede, demandam o envio de uma equipe de manutenção ao local (CAMINHA, 2004).

Existem diversos tipos de curtos-circuitos: monofásico à terra, bifásico à terra, bifásico e trifásico. O de maior ocorrência é o monofásico à terra, representando 63% dos casos. Nesse tipo de curto-circuito, a maior parte ocorre apenas temporariamente, representando 96% dos casos (KINDERMANN, 2010). Já os curtos-circuitos trifásicos, apesar de serem bem menos frequentes, com uma taxa de cerca de 5%, são bastante perigosos, obtendo correntes altíssimas (LIM; DORR, 2000).


2.2.2 Componentes Simétricas

Como a maior parte dos curtos-circuitos que atingem a rede elétrica são assimétricos, ocorrendo, principalmente, entre fase e terra, o modelo de circuito monofásico equivalente para representar o sistema trifásico não é adequado, já que as tensões e correntes se diferenciam em módulo e não estão igualmente defasadas em 120° . Um modelo mais adequado para resolução desse tipo de problema é a representação em componentes simétricas (VARGAS, 2018).

A base dessa representação é o Teorema de Fortescue, que preconiza que um circuito trifásico desequilibrado, na sequência de fases ABC, pode ser decomposto em três sistemas de fasores

equilibrados: componentes simétricas de sequência positiva, negativa e zero (FORTESCUE, 1918), como pode ser visto na Figura 1.

Figura 1 – Sistema trifásico desequilibrado e suas componentes simétricas: (a) sistema desequilibrado; (b) sequência positiva; (c) sequência negativa; (d) sequência zero



Fonte: Vargas (2018).

Nota: Adaptada pela autora.

A sequência positiva é composta por um conjunto de três fasores balanceados, de mesmo módulo, defasados em 120° , com a mesma sequência de fases do sistema trifásico original. A sequência negativa também possui três fasores balanceados, de mesmo módulo e defasados em 120° , no entanto, possui uma sequência de fases contrária à do sistema original. Já a sequência zero possui três fasores idênticos: de mesmo módulo e ângulo (CAMINHA, 2004).

A obtenção das componentes simétricas é realizada a partir da aplicação de uma matriz de transformação. Ela pode ser feita a qualquer conjunto de fasores trifásicos, sejam eles de tensão ou de corrente. A equação (1) mostra essa transformação, as variáveis V_{a0} , V_{a1} e V_{a2} são os fasores das componentes de sequência 0, positiva e negativa, respectivamente, enquanto V_a , V_b e V_c são os fasores do sistema desequilibrado. A variável a é um operador que realiza uma rotação de 120° .

$$\begin{bmatrix} V_{a0} \\ V_{a1} \\ V_{a2} \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 1 & a & a^2 \\ 1 & a^2 & a \end{bmatrix} \cdot \begin{bmatrix} V_a \\ V_b \\ V_c \end{bmatrix} \quad (1)$$

2.3 Redes Neurais Artificiais


As RNAs são modelos computacionais adaptativos inspirados nas características de processamento de informação de neurônios reais e suas interconexões (HAYKIN, 1999). Suas principais características incluem: capacidade de aprendizagem, habilidade de generalização, organização de dados, capacidade de adaptação, facilidade de prototipagem, armazenamento distribuído e tolerância a falhas (SILVA; SPATTI; FLAUZINO, 2010).

O processo de treinamento das RNAs consiste no ajuste dos pesos sinápticos, o que permite que a rede se adapte ao processo e possibilita a extração da relação das variáveis analisadas. Desse modo, as RNAs são capazes de generalizar o conhecimento adquirido e organizar amostras que possuam similaridade (CINTRA, 2018).

As RNAs podem ser utilizadas para diversas funcionalidades, algumas delas são: aproximação de funções, controle de processos, classificação de padrões, agrupamento de dados, previsão, otimização e memórias associativas (SILVA; SPATTI; FLAUZINO, 2010). Neste trabalho, será empregada a aproximação de funções. Para tal, as RNAs são treinadas com o objetivo de mapear a relação entre as variáveis de entrada e saída, de forma a generalizar suas respostas.

A unidade de processamento das RNAs é o neurônio artificial, cujo primeiro modelo matemático foi realizado por McCulloch e Pitts (1943). Os neurônios se ligam entre si por meio de conexões que estão associadas a um peso sináptico. Para treinar a rede, os pesos sinápticos são ajustados de forma iterativa de modo que sua saída se aproxime dos valores esperados. O modelo geral de neurônio é mostrado na Figura 2. Sua operação se dá a partir da apresentação dos sinais nas entradas x , cada um dos sinais é multiplicado por um peso w e então somados a um *bias* b . Esse resultado é submetido a uma função de ativação φ , gerando a saída da rede. As funções de ativação podem ser do tipo degrau, degrau bipolar, rampa simétrica, logística, tangente hiperbólica, sigmoide, gaussiana ou linear (SILVA; SPATTI; FLAUZINO, 2010). Os procedimentos descritos são resumidos nas equações (2) e (3).

Figura 2 – Modelo matemático do neurônio artificial



Fonte: Haykin (2001).

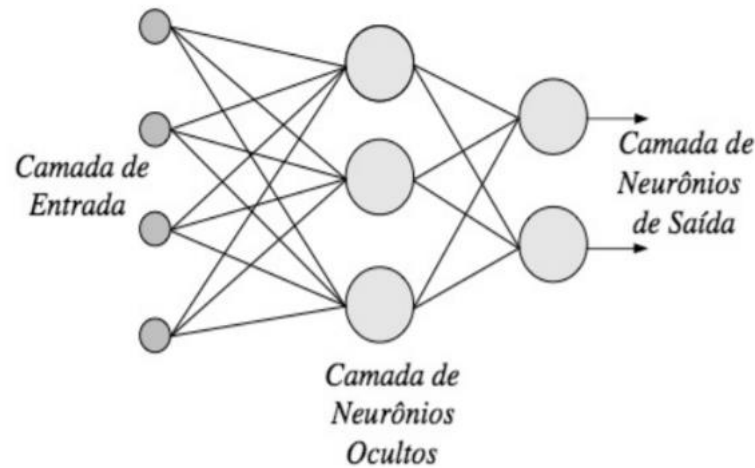
$$v_k = \sum_{j=1}^m w_{kj} \cdot x_j + b_k \quad (2)$$

$$y_k = \varphi(v_k) \quad (3)$$

As RNAs podem ser compostas de um ou mais neurônios e possuir uma ou mais camadas. Sua arquitetura define como os neurônios estarão arranjados e, portanto, o fluxo sináptico. Já a topologia se refere às distintas composições estruturais que ela poderá apresentar em uma arquitetura. A arquitetura de uma rede neural é escolhida a partir da necessidade de aplicação e está relacionada com o algoritmo de aprendizagem utilizado para treinar a rede. As características que definem a estrutura de uma rede neural são: camadas intermediárias, quantidade de neurônios, função de transferência e algoritmo de aprendizado (HAYKIN, 2001). Quando o sinal percorre a rede em apenas uma direção, da entrada para a saída, essa rede é denominada rede de alimentação direta (do inglês *feedforward*) e possui neurônios agrupados em camadas (CINTRA, 2018).

Um modelo de RNA pode ser visto na Figura 3. Esse modelo possui três camadas distintas: a de entrada, a oculta e a de saída.

Figura 3 – Modelo de rede neural



Fonte: Cintra (2018).

A camada de entrada é responsável por receber os sinais de entrada e repassá-los para a oculta, ela não realiza nenhuma operação sobre esses dados. A camada oculta processa os dados provenientes da camada de entrada e a camada de saída apresenta os resultados finais da rede (SILVA; SPATTI; FLAUZINO, 2010).

O *perceptron* é o primeiro modelo de aprendizado supervisionado. Ele foi desenvolvido por Rosenblatt (1958). Seu algoritmo de treinamento calcula os erros entre a saída da rede e a saída desejada e os utiliza para ajustar os pesos. O *perceptron* pode possuir uma ou mais camadas ocultas, sendo que os de uma camada são capazes apenas de resolver funções lineares, enquanto os de múltiplas camadas são capazes de aproximar quaisquer funções contínuas (BISHOP, 1995).

Existem também as redes com realimentação, ou recorrentes (do inglês *recurrent*). Nessas redes, a saída de alguns neurônios pode alimentar neurônios da mesma camada ou de camadas anteriores. Isso faz com que o sinal se desloque em duas direções, possibilitando que a rede possua memória dinâmica e consiga representar dados em sistema dinâmicos (CINTRA, 2018).

O aprendizado da rede *perceptron* é realizado por meio do algoritmo supervisionado de retropropagação (do inglês *backpropagation*). Esse algoritmo foi desenvolvido por Rumelhart, Hinton e Williams (1986) e modifica os valores dos pesos para representar os padrões do conjunto de dados de treinamento com o objetivo de minimizar o erro médio quadrático.

Para o desenvolvimento de aplicações que utilizam redes neurais, alguns passos devem ser tomados. Os primeiros são a coleta de dados e a separação em conjuntos. Os dados escolhidos devem cobrir o domínio do problema e incluir exceções e condições limites. Eles devem ser separados em dados de treinamento e dados de teste, um conjunto para ser utilizado no treinamento da rede e o outro para verificar seu desempenho. Esses dados também podem ser pré-processados para que sejam mais apropriados para utilização na rede (CINTRA, 2018).

Em seguida, deve ser definida a configuração da rede: o paradigma apropriado à aplicação, a topologia a ser utilizada (número de camadas e neurônios em cada uma delas), os parâmetros do algoritmo de treinamento e as funções de ativação (CINTRA, 2018).

Então, é realizado o treinamento da rede. Alguns aspectos devem ser considerados nessa etapa, tais quais a inicialização da rede, o modo e o tempo de treinamento. Após o treinamento, é realizado o teste com os dados que não foram utilizados, determinando assim seu desempenho. E, por último, a rede pode ser incluída no sistema do ambiente operacional da aplicação (CINTRA, 2018).

No contexto das aplicações em SEPs, especificamente nos problemas de localização de faltas, as RNAs possuem algumas vantagens e desvantagens. Como vantagens estão a simplicidade de implementação e a capacidade de detecção de correlações não lineares entre variáveis dependentes e independentes. As desvantagens incluem a dependência da quantidade e qualidade dos dados que serão treinados, para que se produza um algoritmo de bom desempenho, a lenta convergência do processo de treinamento e a definição empírica de vários dos parâmetros importantes das RNAs, como quantidade de camadas ocultas, quantidade de neurônios e taxa de aprendizado (GURURAJAPATHY; MOKHLIS; ILLIAS, 2017).

2.4 Análise de Componentes Principais

A análise de componentes principais (PCA, do inglês *principal components analysis*) é uma técnica não-supervisionada que busca a redução dimensional e a não-correlação linear entre variáveis, preservando a maior parte da informação contida em seus dados (CHIANG; RUSSEL; BRAATZ, 2000). Ela é provavelmente a técnica estatística multivariada mais popular e mais antiga, sendo utilizada em quase todas as disciplinas científicas (HERVÉ; J., 2011).

O algoritmo busca encontrar as direções no espaço m-dimensional sobre as quais a variância (distância entre os valores de seus dados e o valor esperado) é maximizada. Desta forma, espera-se reter o máximo de informação dos dados com uso de um número menor de coordenadas científicas (HERVÉ; J., 2011).

Para que isto seja feito, a PCA calcula novas variáveis denominadas componentes principais, que são encontradas a partir de combinações lineares entre as variáveis originais. A primeira componente principal é a que possui maior variância. Esta componente é, portanto, a que extrairá a maior quantidade de informações dos dados. Já a segunda componente é encontrada de forma que seja ortogonal à primeira e com a maior variância possível. As componentes seguintes são reveladas de forma análoga e a quantidade máxima de componentes é o número de variáveis originais.

Para cálculo da PCA, primeiramente os dados são organizados em uma matriz, em que cada coluna representa uma variável que será observada. Em seguida, é subtraída a média dos dados e eles são normalizados quanto à variância. Então, é calculada a matriz de correlação e encontrados seus autovalores e autovetores. Os autovalores definem o grau de importância de cada componente que foi criada no espaço da PCA e os autovetores compõem uma matriz de rotação que descreve os dados transformados (CHIANG; RUSSEL; BRAATZ, 2000).

De acordo com Chiang, Braatz e Russel (2001), há alguns fatores que motivam a utilização da PCA em análise de falhas de sistemas. Um deles é que a representação da informação em dimensões mais compactas generaliza melhor os dados independentes do conjunto de treinamento. Outro fator é que a estrutura que se abstrai na análise torna possível a identificação

das variáveis mais afetadas pela falha. E, por último, a PCA permite a separação dos dados em dois subespaços: um que descreve as tendências sistemáticas do processo e outro que é composto basicamente de ruído.

3 MÉTODOS E ETAPAS DE DESENVOLVIMENTO

Seguindo os aspectos colocados por Prodanov e Freitas (2013), o trabalho em questão pode ser caracterizado como uma pesquisa aplicada, já que investiga soluções para um problema particular, e também experimental, pois busca estudar uma situação sob controle com a utilização de ferramentas específicas para esse fim, nesse caso, *softwares*. Quanto aos seus objetivos, pode ser definida como uma pesquisa explicativa. Ela também é quantitativa, já que utiliza de recursos e técnicas estatísticas para sua avaliação.


Para a estimação da localização das faltas, foram utilizados dados obtidos de simulações por meio da *toolbox SimPowerSystems™* e o ambiente gráfico *Simulink®* presentes no *software MATLAB®*. Os dados são processados por meio da *Neural Net Fitting tool* e da *Neural Net Pattern Recognition tool* do *MATLAB®*. Também são realizados pré-processamento dos dados utilizando o método das componentes simétricas e a análise de componentes principais.

3.1 Alimentador

Para desenvolvimento do projeto, foi escolhido o alimentador IEEE *13-Node Distribution Test Feeder*. Publicado pelo Subcomitê de Análise do Sistema de Distribuição do *Institute of Electrical and Electronics Engineers* (IEEE), é um circuito pequeno e comumente utilizado para testes de características em sistemas de distribuição. Trata-se de um sistema relativamente carregado e que possui um regulador de tensão na saída da subestação, capacitores *shunt* para compensação reativa e carga desbalanceada. Boa parte de seus ramais são trifásicos, possuindo apenas três bifásicos e dois monofásicos (IEEE, 1992). Seu modelo simplificado é mostrado na Figura 4.

A tensão de saída da subestação é de 115 kV, mas há um transformador já no nó 650 que a abaixa para 4,16 kV. A potência total consumida pelo alimentador é de 3.466 kW e 2.102 kvar, sendo que os capacitores promovem uma compensação reativa de 700 kvar. Como o transformador da subestação é de 5 MVA, o carregamento do circuito é de cerca de 75% de sua capacidade, o que demonstra sua característica de relativamente carregado.

Figura 4 – Modelo simplificado do alimentador

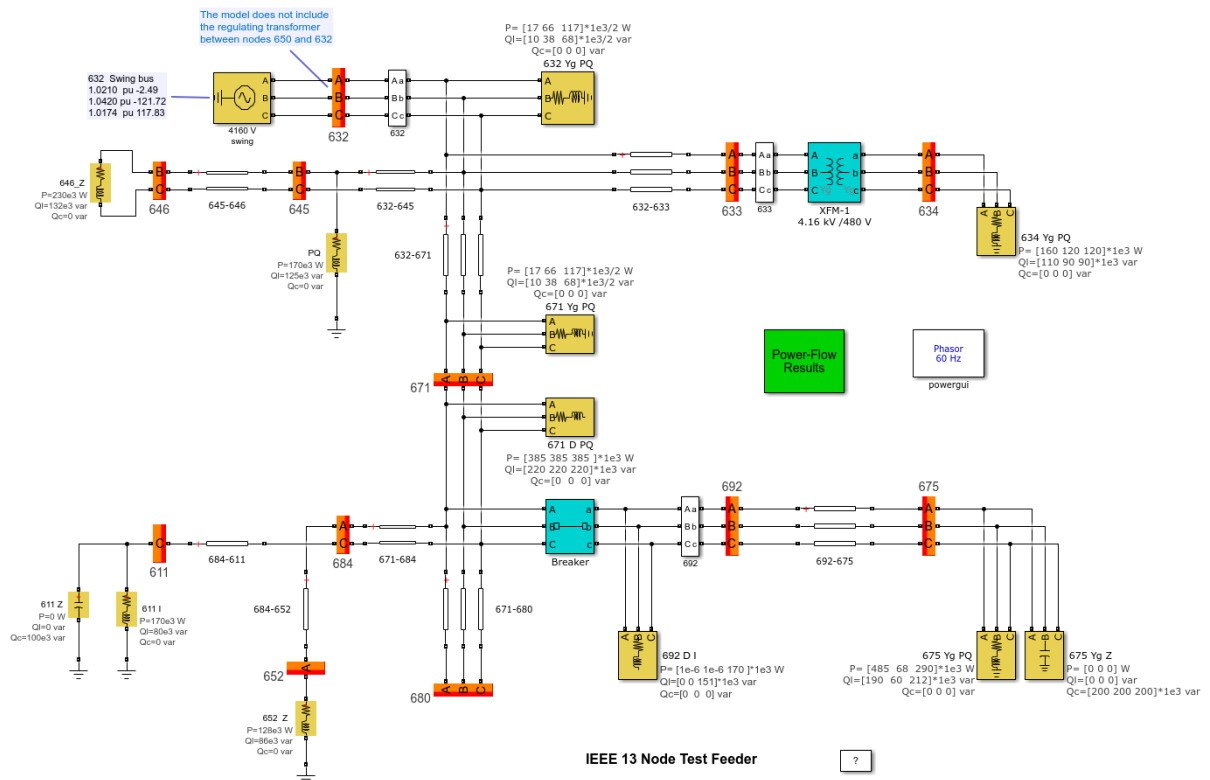


Fonte: Institute of Electrical and Electronics Engineers (1992).

O *Simulink*[®] possui um modelo do alimentador de 13 nós do IEEE que pode ser utilizado para as simulações. Esse modelo já foi inclusive validado por Mendes (2018), realizando simulações do fluxo de potência e comparando com os valores esperados fornecidos por relatórios oficiais do IEEE. O modelo do *Simulink*[®] pode ser visto na Figura 5.

A esse modelo foram realizadas algumas adaptações, como em Vargas (2018). São elas: inserção do transformador regulador entre os nós 650 e 632 que estão presentes no modelo do IEEE mas não no do *Simulink*[®]; balanceamento das cargas, mantendo seu carregamento original mas distribuindo igualmente entre as fases; e retirada do disjuntor da barra 692, considerando-o fechado todo tempo.

Foram feitas outras modificações. Para que o alimentador possua alta penetração de geração distribuída, foram inseridos blocos do sistema fotovoltaico junto a cada uma das cargas do alimentador, que são os blocos azuis na Figura 6. Também foram incluídos blocos para execução das faltas (representados pelos blocos vermelhos na Figura 6) e, para que fosse possível variar sua localização ao longo das linhas, cada um dos blocos de linha foi duplicado, mas de modo que seu comprimento total fosse o mesmo da linha original. Ou seja, um dos blocos representaria, por exemplo, 90% do comprimento da linha, enquanto o outro, 10%, estando a falta alocada entre eles.

Figura 5 – Modelo do alimentador no *Simulink*[®]

Fonte: *Mathworks* (2020).

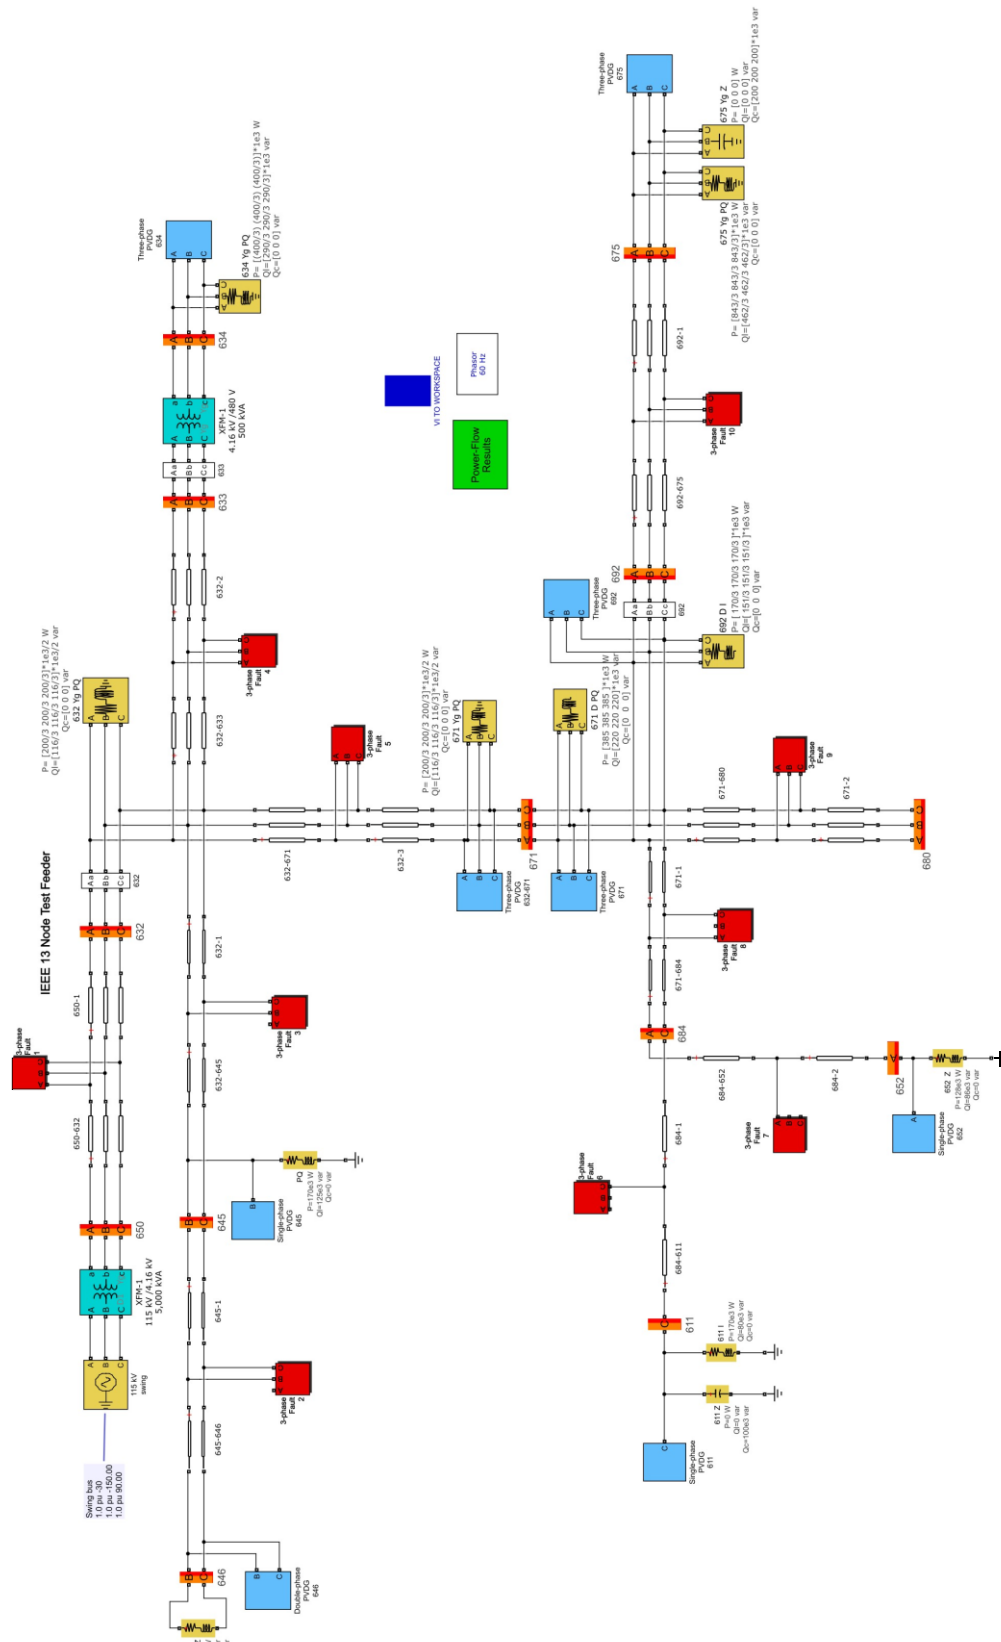
O comprimento total de cada trecho do alimentador é mostrado no Quadro 1. O modelo completo para simulação utilizado pode ser visto na Figura 6.

Quadro 1 – Comprimentos dos trechos do alimentador

Trecho	Comprimento (km)
650 - 632	0,6096
645 - 646	0,0914
632 - 645	0,1524
632 - 633	0,1524
632 - 671	0,6096
684 - 611	0,0914
684 - 652	0,2438
671 - 684	0,0914
671 - 680	0,3048
692 - 675	0,1524

Fonte: Produzido pela própria autora.

Figura 6 – Modelo do alimentador completo para simulação




Fonte: Produzida pela própria autora.

3.2 Sistema Fotovoltaico

Como o projeto visa localização de faltas em um sistema com alta penetração de geração distribuída fotovoltaica, também foi necessário um modelo para simulação do sistema fotovoltaico. O *Simulink*[®] possui um sistema fotovoltaico completo, o *power PV array 3500 W*, no entanto, modelos completos podem tornar as simulações mais lentas. Por este motivo, Mendes (2018) desenvolveu um modelo simplificado, um sistema global que aproxima de maneira satisfatória a operação de um sistema fotovoltaico em regime permanente. Sua representação pode ser vista na Figura 7. Sendo que V_{fv} é a tensão terminal do gerador fotovoltaico, P_{fv} a potência ativa total produzida por ele, I_{ca} a corrente de saída depois de passar pelo inversor e V_{ca} a tensão de saída. α é o ângulo da corrente de saída e fp o fator de potência. A potência máxima do sistema fotovoltaico é ajustada para o mesmo valor da carga que ele alimenta.

Figura 7 – Modelo simplificado do sistema fotovoltaico



Fonte: Mendes (2018).

Quando comparado ao sistema fotovoltaico completo do *Simulink*[®], o erro médio para variação da tensão no ponto de acoplamento não ultrapassou 0,52% enquanto a potência reativa de saída apresentou erros maiores, de até 6,28%, o que se explica pelo desprezo das perdas internas. Desse modo, o modelo foi considerado eficiente (MENDES, 2018).

O modelo simplificado mostra-se vantajoso quando comparados os tempos de simulação. Ele se mostrou entre 95 e 200 vezes mais rápido que o *power PV array 3500 W*. É, portanto, mais indicado para simulações computacionais com alta penetração de geração distribuída fotovoltaica, que é a intenção deste projeto (MENDES, 2018).

Esse modelo, no entanto, deve ser utilizado para operações em regime permanente. Quando há distúrbios na rede, é importante que seu comportamento seja modificado. Para redes de baixa penetração de geração distribuída, é recomendado que os micro e minigeradores se desconectem da rede de distribuição. Entretanto, em sistemas em que a geração distribuída tem alta penetração, isso pode causar problemas de estabilidade. Nesse sentido, o modelo completo que foi utilizado é o proposto por Vargas (2018), que tem seu comportamento modificado a partir da tensão no ponto de acoplamento. O módulo e a corrente injetados podem ser vistos nas equações (4) e (5).

$$|I_{ca}| = \begin{cases} 0, & \text{se } V_{ca} < 0,10 \text{ pu.} \\ 2pu, & \text{se } 0,10 \text{ pu} \leq V_{ca} < 0,50 \text{ pu.} \\ \frac{2P_{fv}}{fp V_{ca-pico}}, & \text{se } 0,50 \text{ pu} \leq V_{ca} < 1,10 \text{ pu.} \\ 0, & \text{se } V_{ca} > 1,10 \text{ pu.} \end{cases} \quad (4)$$

$$\angle\alpha = \begin{cases} \angle V_{ca} + \arccos(0,9), & \text{se } 0,10 \text{ pu} \leq V_{ca} < 0,50 \text{ pu.} \\ \angle V_{ca} - \frac{\arccos(0,9)(|V_{ca}| - 0,8)}{0,3}, & \text{se } 0,50 \text{ pu} \leq V_{ca} < 0,80 \text{ pu.} \\ \angle V_{ca}, & \text{se } 0,80 \text{ pu} \leq V_{ca} < 1,00 \text{ pu.} \\ \angle V_{ca} - \frac{\arccos(0,9)(|V_{ca}| - 1)}{0,1}, & \text{se } 1,00 \text{ pu} \leq V_{ca} < 1,10 \text{ pu.} \end{cases} \quad (5)$$

3.3 Faltas

Para execução das faltas no alimentador, considerou-se, inicialmente, a possibilidade da utilização do bloco *Three-Phase Fault* da biblioteca *Simscape Power Systems* do *Simulink*[®]. Esse bloco permite a interrupção do circuito para todas as combinações de faltas fase-fase e fase-terra. É possível também alterar os valores das resistências de falta e controlar o momento da falta externamente.

Entretanto, há uma desvantagem em sua utilização: ele não permite o controle externo do tipo de falta a ser aplicada. Logo, é necessário realizar ciclos de simulações distintos para diferentes tipos de falta.

Por esse motivo, optou-se pela utilização de um bloco simplificado em que é possível alterar os valores de resistência de cada uma das fases pelo *script*. Desse modo, as modificações do tipo de falta a ser aplicada podem ser feitas por meio do código, sem que se tenha que alterar as configurações do modelo do *Simulink*[®].

Foram aplicadas faltas monofásicas e trifásicas com uma resistência de $0,001 \Omega$ por fase.

3.4 Simulações

O objetivo das simulações foi obter uma base de dados das tensões e correntes recolhidas pelos três medidores do alimentador para que posteriormente eles pudessem ser processados e a localização da falta ser estimada pelas RNAs. O ambiente de simulação foi o *Simulink*[®] do *software MATLAB*[®] e foi utilizado o modo fasorial com uma frequência de 60 Hz.

Para escolher o tempo de simulação do *Simulink*[®], foram realizados testes com diferentes configurações das faltas e dos geradores fotovoltaicos para vários tempos de execução, a saber: 0,01 s, 0,05 s, 1 s e 1,2 s, sendo o último o valor utilizado por Vargas (2018). Os valores de tensão e corrente obtidos para os três últimos casos foram os mesmos, portanto, concluiu-se que poderia ser utilizado o tempo de 0,05 s. Desse modo, a execução seria mais rápida sem prejudicar a convergência do fluxo de potência.

Foram aplicadas faltas monofásicas (AT, BT e CT) e trifásicas (ABC) em todos os trechos do alimentador e, para cada uma delas, foram feitas todas as combinações de disponibilidade dos geradores fotovoltaicos. Isto inclui o caso em que nenhum deles está disponível até o que todos estão disponíveis, gerando 512 combinações. As faltas foram realizadas em diversos pontos em cada trecho, obtendo um passo de aproximadamente 50 m de distância. Os dados dos medidores foram obtidos durante as faltas e o total de amostras de cada uma das variáveis foi de 99,009. O tempo total de simulação do alimentador foi de cerca de 256 horas, ou 10 dias e 16 horas.

Cada cenário de simulação recolheu os módulos e ângulos das correntes e tensões dos três medidores posicionados ao longo do alimentador, o que totaliza 36 variáveis. As tensões e correntes foram convertidas para suas correspondentes componentes simétricas e foram

armazenados dados de sequências positiva, negativa e zero de apenas uma das fases para cada um dos medidores.

3.5 Experimentos com RNAs

Para estimar a localização das faltas, os dados recolhidos da simulação foram utilizados para treinamento das RNAs. O treinamento foi também realizado no *MATLAB*[®] utilizando sua *Neural Net Fitting tool*, cuja interface é mostrada na Figura 8.

Essa ferramenta possibilita a inserção de dados, a criação e treinamento de uma rede neural e a avaliação de sua performance utilizando as métricas de erro médio quadrado e regressão linear. O erro médio quadrático é a média quadrada da diferença entre as saídas e as entradas da rede, de forma que se seu valor for nulo, significa que não há erros. Já a regressão mede a correlação entre as entradas e as saídas da rede, de forma que o valor 1 significa que elas têm uma relação próxima, enquanto 0, uma relação aleatória.

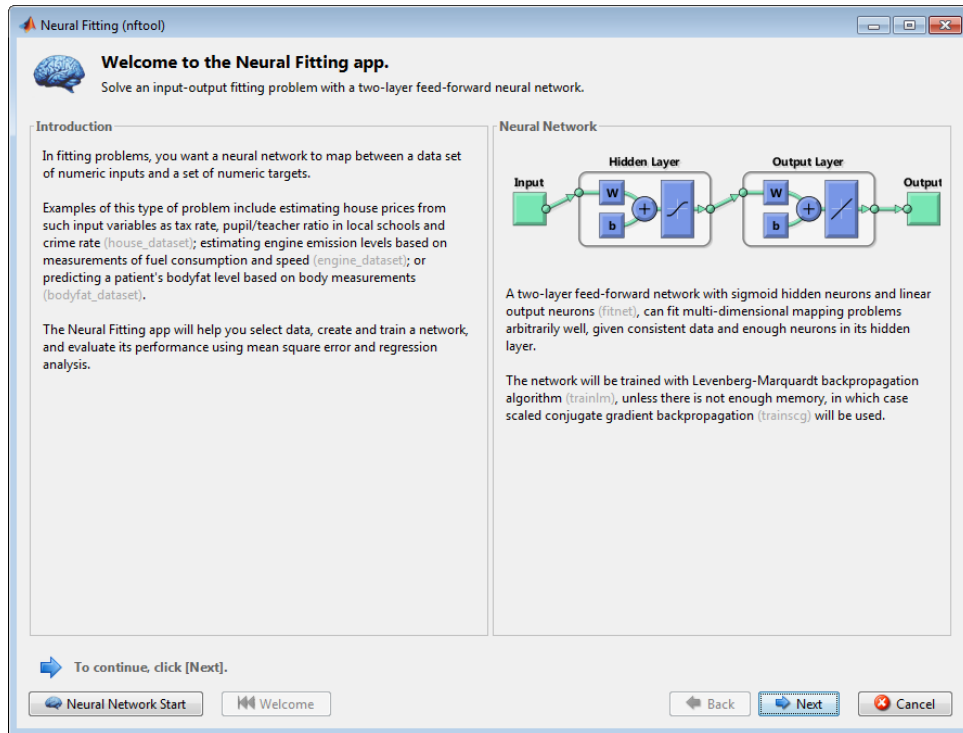
Na inserção de dados, foram colocados dois conjuntos: os dados de entrada a serem apresentados às RNAs e os resultados que devem ser observados em sua saída. Os dados de entrada são os valores de tensão e corrente (ou os provenientes de seu pré-processamento) e os resultados são as distâncias das faltas em relação a cada um dos três medidores da rede.

Posteriormente, escolheu-se os tamanhos dos conjuntos para treinamento, validação e teste da rede neural, que foram respectivamente de 70%, 15% e 15%, o que equivale a um total de 68.307, 14.851 e 14.851 amostras. A seleção das amostras é feita de forma aleatória e nenhuma amostra de cada subconjunto está contida em outro. As quantidades de neurônios na camada oculta foram 10, 15 e 20. O algoritmo de treinamento utilizado foi o Levenberg-Marquardt, que diminui o tempo de convergência e o esforço computacional da retropropagação (SILVA; SPATTI; FLAUZINO, 2010). A função de ativação da camada intermediária das RNAs é a sigmoide e a dos neurônios de saída é a linear.

Foram feitos diversos conjuntos de dados de entrada. O primeiro continha todos os dados recolhidos na simulação, ou seja, as 99.009 amostras de 36 variáveis. As demais redes foram treinadas com um número menor de variáveis. Foi aplicada a PCA nos dados e obtidas as

componentes principais. As variâncias retidas para diversas quantidades de componentes principais podem ser vistas no Quadro 2.

Figura 8 – Interface da ferramenta para treinamento da rede neural



Fonte: Produzida pela própria autora.

Quadro 2 – Variância retida em função da quantidade de componentes principais

Componentes principais	Variância acumulada (%)
1	62,66
2	83,66
3	90,11
4	93,66
5	96,34
8	98,62
12	99,58
18	99,90
36	100,00

Fonte: Produzido pela própria autora.

A aplicação da PCA forneceu um conjunto de variáveis que não possuem correlação linear. Isto possibilita a utilização de um número menor de variáveis, mas que possui a maior parte da informação contida naquele conjunto de dados.

Considerando os valores de variância retida mostrados no Quadro 2, optou-se por realizar o treinamento de RNAs com conjuntos de dados de entrada com 4, 8 e 12 componentes principais. Os três conjuntos de dados possuem mais de 93% de variância retida, o que pode indicar um bom desempenho das RNAs, apesar da considerável redução de variáveis de entrada.

Somente o cálculo das distâncias entre o ponto de falta e os medidores inteligentes alocados ao longo do alimentador não são suficientes para localizar faltas em alguns trechos. Isso ocorre pois há trechos que apresentam as mesmas distâncias para os três medidores que outro trecho próximo. Mesmo considerando que haja algum mérito em reduzir todas as opções de localização de falta para dois pontos em trechos diferentes, decidiu-se construir uma outra rede que contribua para esses casos sob dúvida. Ela classifica o trecho que cada uma das faltas ocorreu. Esta rede é construída a partir da *Neural Net Pattern Recognition tool* do *MATLAB*[®].

Foram testadas diversas configurações para essa rede: utilizando todos os dados ou apenas algumas componentes principais, variando o número de neurônios na camada intermediária e o tamanho dos conjuntos de treino, validação e teste. Por fim, a rede escolhida foi a com todos os dados de entrada, 30 neurônios na camada oculta e conjuntos de treino, validação e teste com 70%, 15% e 15% dos dados, respectivamente.

Os dados são treinados com o algoritmo de gradiente conjugado escalonado. Os neurônios da camada oculta têm função de ativação sigmoide e os de saída, *softmax*.

Os resultados obtidos a partir das RNAs são mostrados e discutidos na seção 4.

4 RESULTADOS E DISCUSSÕES

As primeiras redes, treinadas com todos os dados dos três medidores, têm os resultados obtidos a partir do treinamento de suas RNAs apresentados na Tabela 1. O desempenho das redes é consideravelmente bom, como indicado pelo MSE na ordem de 10^{-5} e pela R acima de 99,96%. Ele é crescente com o número de neurônios utilizados na camada oculta das RNAs. Os tempos de treinamento das RNAs para 10, 15 e 20 neurônios são de 11 min, 52 min e 1 h e 28 min.

Tabela 1 – Desempenho das RNAs com todos os dados na entrada para diferentes quantidades de neurônios

Número Neurônios	Treino		Validação		Teste	
	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)
10	6,4015	99,968	6,5426	99,967	6,4879	99,968
15	1,6299	99,992	1,677	99,992	1,6291	99,992
20	1,0501	99,995	1,071	99,995	1,1408	99,994

Fonte: Produzida pela própria autora.

Ao utilizar os dados com apenas algumas componentes principais, observa-se que o desempenho diminui, em comparação às RNAs treinadas com todos os dados. O desempenho, como esperado, é maior com o aumento da quantidade de componentes principais utilizadas. A Tabela 2, a Tabela 3 e a Tabela 4 mostram o desempenho das RNAs variando com o número de neurônios na camada oculta para 4, 8 e 12 componentes principais.

Tabela 2 – Desempenho das RNAs com 4 componentes principais para diferentes quantidades de neurônios

Número Neurônios	Treino		Validação		Teste	
	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)
10	274,5	98,623	277,9	98,609	281,7	98,581
15	182,9	99,085	187,9	99,056	189,5	99,053
20	161,7	99,191	159,4	99,204	157,7	99,210

Fonte: Produzida pela própria autora.

Apesar de os desempenhos das RNAs com 4 componentes principais serem menores do que os das com 8 e 12 componentes, é possível perceber que não há um incremento tão relevante. Isto pode ser explicado pela variância retida contida em cada um desses conjuntos de dados. As 4 primeiras componentes já possuem uma variância retida de 93,66%, enquanto as 8 primeiras, 98,62% e as 12, 99,58%. Ou seja, a parte majoritária da informação útil contida nos dados totais já está presente nas 4 primeiras componentes.

Tabela 3 – Desempenho das RNAs com 8 componentes principais para diferentes quantidades de neurônios

Número Neurônios	Treino		Validação		Teste	
	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)
10	72,68	99,637	74,76	99,628	73,61	99,632
15	52,22	99,740	53,41	99,734	50,68	99,746
20	34,82	99,826	34,54	99,828	35,05	99,825

Fonte: Produzida pela própria autora.

Tabela 4 – Desempenho das RNAs com 12 componentes principais para diferentes quantidades de neurônios

Número Neurônios	Treino		Validação		Teste	
	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)
10	30,10	99,850	31,00	99,845	30,46	99,848
15	12,76	99,941	12,52	99,943	12,64	99,941
20	8,17	99,958	8,41	99,961	8,08	99,963

Fonte: Produzida pela própria autora.

A Tabela 5 mostra um resumo dos melhores desempenhos para os diferentes dados de entrada. Todos eles ocorreram com a utilização de 20 neurônios da camada oculta. É possível observar que, apesar de o MSE ser aproximadamente 160 vezes menor comparando a utilização de todos os dados e das quatro componentes principais, a regressão é bem próxima e consideravelmente alta. Isto implica que a utilização da PCA pode ser bastante útil em sistemas com muitos dados de entrada, pois é possível reduzir a quantidade de dados e, conseqüentemente, o tempo de treinamento da rede. Para se ter uma ideia, as RNAs treinadas com todos os dados, com 4 CPs, com 8 CPs e com 12 CPs, para 20 neurônios da camada intermediária, apresentaram um tempo de treinamento de 1 h 28 min, 11 min, 17 min e 20 min, respectivamente.

Tabela 5 – Desempenho das RNAs com diferentes dados de entrada, utilizando 20 neurônios


Dados utilizados	Treino		Validação		Teste	
	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)	MSE(10^{-5})	R (%)
Todos	1,0501	99,995	1,071	99,995	1,1408	99,994
4 CPs	161,7	99,191	159,4	99,204	157,7	99,210
8 CPs	34,82	99,826	34,54	99,828	35,05	99,825
12 CPs	8,17	99,958	8,41	99,961	8,08	99,963

Fonte: Produzida pela própria autora.

A rede com melhor desempenho dentre as apresentadas foi a que utilizou todos os dados de entrada e 20 neurônios na camada oculta. O histograma ilustrando os erros dos conjuntos de treinamento, validação e teste dessa rede pode ser visto no Gráfico 1. Considerando que o eixo das abscissas é o erro para cada uma das amostras e o das ordenadas indica a quantidade de amostras, é possível observar no gráfico que a maior parte dos erros está bem próximo de zero, sendo que o erro máximo para essa rede é de 0,0277 km, ou 27,7 m. É interessante pensar no

efeito desse erro máximo no cotidiano das distribuidoras. A distância entre dois postes de iluminação é, geralmente, maior que esse valor, o que demonstra que, na prática, esse é um erro contornável a partir da inspeção visual dos agentes responsáveis pela manutenção.

Gráfico 1 – Histograma mostrando os erros dos conjuntos de treinamento, validação e teste da rede com todas as variáveis e 20 neurônios na camada oculta




Fonte: Produzido pela própria autora.

Já no Gráfico 2, é representada a regressão linear da rede para o treinamento, validação e teste, para a rede treinada com todas as variáveis e que possui 20 neurônios na camada oculta. Nela, nota-se que os dados estão bem próximos à curva, o que demonstra que o *fitting* foi bem executado.

Quanto à rede que determina o trecho em que ocorreu a falta, é possível visualizar sua taxa de acertos por trecho na Tabela 6. Em um geral, ela obteve bons resultados, no entanto, dois trechos merecem especial atenção: o 632 – 645 e o 671 – 684. O primeiro é um trecho realmente problemático pois pode ser confundido com o trecho 650 – 632 quando analisadas somente as distâncias até os medidores. Já o segundo não possui esse problema de confundir com outros

trechos, no entanto, como ele é relativamente curto, 91,4 m, e as amostras foram obtidas a cada 50 m, as RNAs podem ter maior dificuldade para extrair características que apontem para ele.

Gráfico 2 – Regressão linear da rede com todas as variáveis e 20 neurônios na camada oculta: (a) Treinamento, (b) Validação, (c) Teste e (d) Todas



Fonte: Produzido pela própria autora.

Tabela 6 – Taxa de acerto do classificador de trechos

Trecho	Percentual de acerto
650 – 632	100%
645 – 646	85,14%
632 – 645	71,45%
632 – 633	88,28%
632 – 671	95,11%
684 – 611	84,17%
684 – 652	93,18%
671 – 684	54,40%
671 – 680	94,87%
692 – 675	100%
Total	93,33%

Fonte: Produzida pela própria autora.

5 CONCLUSÃO

O presente trabalho perpassou uma temática atual e que vem se aprofundando cada vez mais ao longo dos últimos anos: o incremento da utilização de geração distribuída fotovoltaica. Ao mesmo tempo que este fenômeno está na pauta para um futuro em maior harmonia com o meio ambiente, ele também é um desafio para as estruturas e o funcionamento dos SEPs.

Dentro da proteção de sistemas elétricos, que tem sua dinâmica diretamente afetada por essa intensa inserção de GD, o aspecto escolhido como foco deste trabalho foi a localização de faltas e a utilização de dados de medidores automatizados, cada vez mais presentes nos SEPs, para este fim. Mais especificamente, a aplicação desses dados para treinamento de RNAs para localização de faltas.

Como já abordado ao longo do trabalho, a utilização de métodos de inteligência computacional para resolução de problemas que acometem os SEPs possui alguns desafios, dentre eles a necessidade de aquisição e estruturação de dados para serem utilizados e a alta demanda de tempo para treinamento das redes.

Ambos desafios foram enfrentados neste trabalho, em proporções diferentes. De fato, houve uma alta demanda de tempo para processamento computacional, no entanto, não foi o treinamento das redes o requisitou de forma mais intensa. A necessidade de aquisição e estruturação dos dados que tomou um longo tempo, já que havia muitos cenários a serem simulados no alimentador estudado. Como as RNAs utilizadas não possuíam muitas camadas e complexidades, foi possível alcançar resultados satisfatórios e em um tempo curto de simulação. O máximo de tempo que uma rede demorou em seu treinamento foi de, aproximadamente, 1 hora e meia. Enquanto isso, as simulações dos diversos cenários de faltas e disponibilidade dos geradores fotovoltaicos duraram mais de dez dias. Este tempo só não foi mais longo porque foram diminuídas as metas iniciais: a princípio, o plano era aplicar faltas a cada 1 metro ao longo de todo alimentador, mas devido à limitação de tempo, optou-se por utilizar 50 metros.

De modo geral, as RNAs desenvolvidas obtiveram bons resultados para inferência da localização das faltas, mesmo quando utilizado um número menor de dados de entrada, como ao aplicar a PCA.

A PCA demonstrou-se uma boa técnica para utilizar para um sistema com muitos dados de entrada. Ela permitiu que, apenas com uma quantidade de 1/9 do total de variáveis, as RNAs treinadas alcançassem um desempenho muito próximo das treinadas com o total de variáveis. A técnica pode ser mais útil em sistemas maiores, com mais variáveis de entrada, já que uma vantagem percebida é que o tempo de treinamento da rede passa a ser muito menor com a diminuição da quantidade de dados de entrada.

Como avanços para trabalhos futuros, seria interessante a experimentação de outras topologias de RNAs. Por exemplo, o aumento de camadas intermediárias muitas vezes consegue extrair características mais complexas dos dados, fornecendo resultados melhores. Também poderia ser realizada a variação da potência dos painéis fotovoltaicos e das cargas. Outro ponto que possa ser relevante é a utilização de outra linguagem de programação e/ou plataforma de simulação. Apesar de bastante intuitivo e com muitas ferramentas disponíveis, o *MATLAB*[®] limita bastante todas as configurações que por ventura se queira experimentar devido ao longo tempo de simulação.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDI, H.; WILLIAMS, L. J. Principal component analysis. **Wiley interdisciplinary reviews: computational statistics**, v. 2, n. 4, p. 433-459, 2010.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5460**: Sistemas elétricos de potência. Rio de Janeiro: ABNT, 1992.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Avaliar Aprimoramentos na Regulação de Continuidade do Fornecimento de Energia Elétrica**: Relatório de Análise de Impacto Regulatório. 2018. Brasília, DF: AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2018. Disponível em:
<https://www.aneel.gov.br/documents/656877/18485189/7+Modelo+de+AIR+-+SRD+-+Continuidade+do+Fornecimento.pdf/8a3f3cc3-f5f0-6e17-5dc7-5ef70d6a6eb9>
Acesso em: 22 dez. 2020.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Cadernos Temáticos Micro e Minigeração Distribuída**: Sistema de Compensação de Energia Elétrica. 2016. Brasília, DF: AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2016. Disponível em:
<http://www.aneel.gov.br/documents/656877/14913578/Caderno+tematico+Micro+e+Minigera%C3%A7%C3%A3o+Distribuida+-+2+edicao/716e8bb2-83b8-48e9-b4c8-a66d7f655161>.
Acesso em: 14 set. 2020.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Brasil ultrapassa marca de 1GW em geração distribuída**. 2019. Disponível em: https://www.aneel.gov.br/sala-de-imprensa-exibicao/-/asset_publisher/XGPXSqdMFHrE/content/brasil-ultrapassa-marca-de-1gw-em-geracao-distribuida/656877#:~:text=O%20Brasil%20ultrapassou%20a%20marca,2012%20e%20687%2F2015). Acesso em: 15 set. 2020.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução Normativa no 687, de 24 de novembro de 2015**. Brasília, DF: ANEEL, 2015. 25 p. Disponível em:
<http://www2.aneel.gov.br/cedoc/ren2015687.pdf>. Acesso em: 14 set. 2020.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução Normativa no 786, de 17 de outubro de 2017**. Brasília, DF: ANEEL, 2017. 2 p. Disponível em:
<http://www2.aneel.gov.br/cedoc/ren2017786.pdf>. Acesso em: 14 set. 2020.

ARAÚJO, M. A. **Metodologia para Localização de Falhas em Sistemas de Distribuição Modernos Pautada na Aplicação SVM-RFE**, 2015. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2015.

BATISTA, O. E. **Sistema Inteligente Baseado em Decomposição por Componentes Ortogonais e Inferência Fuzzy para Localização de Falhas de Alta Impedância em Sistemas de Distribuição de Energia Elétrica com Geração Distribuída**, 2016. Tese

(Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2016.

BISHOP, C. M.. **Neural networks for pattern recognition**. 1. ed. Nova Iorque: Oxford University Press, 1995.

BHISE, D. R.; KANKALE, R. S.; JADHAO, S. Impact of distributed generation on protection of power system. *In: INTERNATIONAL CONFERENCE ON INNOVATIVE MECHANISMS FOR INDUSTRY APPLICATIONS*, 2017, Bengaluru. **Proceedings** [...]. Bengaluru: IEEE, 2017. p. 399-405.

CAMINHA, A. C. **Introdução à Proteção dos Sistemas Elétricos**. 9. ed. São Paulo: Edgard Blucher, 2004.

CINTRA, R. **Introdução à Neurocomputação**. São José dos Campos: INPE, 2018. (Apostila). Disponível em: http://www.inpe.br/elac2018/arquivos/ELAC2018_MC3_apostila.pdf. Acesso em: 14 set. 2020.

CHIANG, L. H.; RUSSEL, E. L.; BRAATZ, R. D. Fault diagnosis in chemical processes using fisher discriminant analysis, discriminant partial least squares, and principal component analysis. **Chemometrics and Intelligent Laboratory Systems**. [S.l.]: Elsevier, 2000. v. 50, n. 2, p. 243–252.

CHIANG, L. H.; BRAATZ, R. D.; RUSSELL, E. L. **Fault detection and diagnosis in industrial systems**. [S.l.]: Springer Science & Business Media, 2001.

DASHTDAR, M.; DASHTI, R.; SHAKER, R. Distribution network fault section identification and fault location using artificial neural network. *In: INTERNATIONAL CONFERENCE ON ELECTRICAL AND ELECTRONIC ENGINEERING*, 5., 2018, Istanbul. **Proceedings** [...]. Istanbul: ICEEC, 2018. v. 5, p. 273-278.

DEHGHANI, F.; KHODNIA, F.; DEHGHAN, E. Fault location of unbalanced power distribution feeder with distributed generation using neural networks. **CIREOpen Access Proceedings Journal**, [S. l.], v. 2017, n. 1, p. 1134-1137, 2017.

DEHGHANI, F., NEZAMI, H. A new fault location technique on radial distribution systems using artificial neural network. *In: International Conference And Exhibition On Electricity Distribution*. **Proceedings** [...]. Estocolmo: CIREN, 2013, v. 22, n.p.

ELETROBRÁS. **Proteção de Sistemas Aéreos de Distribuição**. [S. l.]: Campus/Eletróbrás, 1982. 235 p. (Coleção Distribuição de Energia Elétrica, v. 2)

FORTESCUE, C. L. Method of symmetrical co-ordinates applied to the solution of polyphase networks. **Transactions of the American Institute of Electrical Engineers**, v. 37, p. 1027–1140, 1918.

GURURAJAPATHY, S. S.; MOKHLIS, H.; ILLIAS, H. A. Fault location and detection techniques in power distribution systems with distributed generation: A review. **Renewable and Sustainable Energy Reviews**, v. 74, p. 949-958, 2017.

HAYKIN, S. **Neural Networks: a comprehensive foundation**. New York: MacMillan College Publishing Co., 1999.

HAYKIN, S. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS. **IEEE 13 Node Test Feeder**. 1992. Disponível em: <http://sites.ieee.org/pes-testfeeders/resources/>. Acesso em 14 set. 2020.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Atlas Brasileiro de Energia Solar**. São José dos Campos: INPE, 2017.

JOSE, B. D. S., CAVALCANTE, P. A. H., TRINDADE, F. C., ALMEIDA, M. C. Analysis of distance based fault location methods for Smart Grids with distributed generation. *In: IEEE PES INNOVATIVE SMART GRID TECHNOLOGIES EUROPE*. 4., 2013, Copenhagen. **Proceedings[...]**. Copenhagen: IEEE, 2013. p. 1-5.

KINDERMANN, G. **Curto-Circuito**. 5. ed. Florianópolis: UFSC-EEL-LABPLAN, 2010.

LIM, P. K.; DORR, D. S. Understanding and resolving voltage sag related problems for sensitive industrial customers. *In: IEEE POWER ENGINEERING SOCIETY WINTER MEETING*. 2000, Cingapura. **Proceedings[...]**. Cingapura: IEEE, 2000. p. 2886-2890.

LUCON, O.; GOLDEMBERG, J. Crise financeira, energia e sustentabilidade no Brasil. **Estudos Avançados**, São Paulo, v. 23, n. 65, p. 121-130, 2009.

MATHWORKS. **IEEE 13 Node Test Feeder**. 2020. Disponível em: <https://www.mathworks.com/help/physmod/sps/examples/ieee-13-node-test-feeder.html>. Acesso em: 14 set. 2020.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in neurons activity. **Bulletin of Mathematical Biophysics**, v. 5, n. 115-133, p. 10, 1943.

MENDES, M. A. **Análise dos Impactos da Alta Inserção de Geração Distribuída Fotovoltaica na Proteção de Sobrecorrente Temporizada**. 2018. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Centro Tecnológico, Universidade Federal do Espírito Santo, Vitória, 2018.

MONTOYA-BUENO, S.; MUÑOZ-HERNÁNDEZ, J. I.; CONTRERAS, J. Uncertainty management of renewable distributed generation. **Journal of Cleaner Production**, v. 138, p. 103-118, 2016.

NUNES-VILLELA, J.; RAPOZO, F. O., DOMINGOS, M. D. L. C.; QUELHAS, O. L. G. Energia Em Tempo De Descarbonização: Uma Revisão Com Foco Em Consumidores

Fotovoltaicos. **Revista Brasileira de Ciências Ambientais** (Online), [S. l.], n. 45, p. 130-144, 2017.

PEREZ, R.; VÁSQUEZ, C.; VILORIA, A. An intelligent strategy for faults location in distribution networks with distributed generation. **Journal of Intelligent & Fuzzy Systems**, v. 36, n. 2, p. 1627-1637, 2019.

PRODANOV, C. C.; FREITAS, E. C. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**, 2. ed. Nova Hamburgo: Feevale, 2013.

RAYBOLT, A. C. S. **Localização de Falhas em Linhas de Transmissão em Circuito Duplo Utilizando Redes Neurais Artificiais**. 2011. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. **Parallel Distributed Processing**, v. 1, p. 318-362, 1985.

SAMPAIO, P. G., V.; GONZÁLEZ, M. O. A. Photovoltaic solar energy: Conceptual framework. **Renewable and Sustainable Energy Reviews**, v. 74, p. 590–601, 2017.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas: curso prático**. São Paulo: Artliber, 2010.

VARGAS, M. C. **Análise dos Impactos das Falhas na Proteção de Sobrecorrente em Redes de Distribuição com Elevada Penetração de Geração Distribuída Fotovoltaica**. 2018. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Centro Tecnológico, Universidade Federal do Espírito Santo, Vitória, 2018.