UNIVERSIDADE DE SÃO PAULO – USP
ESCOLA DE ENGENHARIA DE SÃO CARLOS – EESC
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Thiago Souza Menezes

**Detecção de Ilhamento de Geradores Distribuídos
Utilizando Transformada S e Redes Neurais Artificiais
com Máquina de Aprendizado Extremo**

São Carlos – SP
2019

Thiago Souza Menezes

**Detecção de Ilhamento de Geradores Distribuídos
Utilizando Transformada S e Redes Neurais Artificiais
com Máquina de Aprendizado Extremo**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia de São Carlos, como parte dos requisitos para obtenção do título de Mestre em Ciências.

Área de Concentração: Sistemas Elétricos de Potência

Orientador: Prof. Tit. Denis Vinicius Coury

São Carlos – SP

2019

Trata-se da versão corrigida da dissertação. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da EESC/USP com os dados inseridos pelo(a) autor(a).

M541d	<p>Menezes, Thiago Souza</p> <p>Detecção de Ilhamento de Geradores Distribuídos Utilizando Transformada S e Redes Neurais Artificiais com Máquina de Aprendizado Extremo / Thiago Souza Menezes; orientador Denis Vinicius Coury. São Carlos, 2019.</p> <p>Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Sistemas Elétricos de Potência -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2019.</p> <p>1. Detecção de Ilhamento. 2. Geradores Distribuídos. 3. Máquina de Aprendizado Extremo. 4. Transformada S. 5. Redes Neurais Artificiais. I. Título.</p>
-------	--

FOLHA DE JULGAMENTO

Candidato: Bacharel **THIAGO SOUZA MENEZES**.

Título da dissertação: "Detecção de ilhamento de geradores distribuídos utilizando transformada S e redes neurais artificiais com máquinas de aprendizado extremo".

Data da defesa: 24/05/2019.

Comissão Julgadora:

Resultado:

Prof. Titular **Denis Vinicius Coury**
(Orientador)
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Dr. **Ricardo Caneloi dos Santos**
(Universidade Federal do ABC/UFABC)

APROVADO

Prof. Dr. **Madson Cortes de Almeida**
(Universidade Estadual de Campinas/UNICAMP)

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:
Prof. Associado **Ivan Nunes da Silva**

Presidente da Comissão de Pós-Graduação:
Prof. Titular **Murilo Araujo Romero**

AGRADECIMENTOS

Gostaria de agradecer primeiramente a minha família, aos meus pais, Valdivino e Maria Aparecida, bem como a minha irmã Ana Paula e ao meu cunhado Giuzimar, minha avó Odete e meu avô Isaac, por todo o apoio que me deram durante esta jornada e, além disso, por sempre acreditarem em mim e nos meus sonhos.

Ao Prof. Dr. Fabrício Augusto Matheus Moura, por ter me apresentado a minha linha de pesquisa durante a graduação e ter me incentivado a fazer o mestrado.

Aos professores Dr. Eduardo Nobuhiro Asada e Dr. José Carlos de Melo Viera Júnior, pelos comentários, correções e contribuições durante o exame de qualificação.

Aos professores Dr. Madson Cortes de Almeida e Dr. Ricardo Caneloi dos Santos, pelas suas contribuições e comentários durante a banca de defesa.

Ao meu orientador, Prof. Tit. Denis Vinicius Coury, primeiramente por ter me aceito como seu orientando de mestrado, pela orientação e todos os conselhos e conhecimentos transmitidos durante estes 2 anos que estivemos trabalhando juntos.

Ao Prof. Dr. Ricardo Augusto Souza Fernandes por suas correções e contribuições para o trabalho.

Aos amigos que fiz em São Carlos, em especial aos colegas do laboratório, primeiramente pela amizade, por todo o tempo que passamos juntos e por todos os momentos de descontração que tornaram a convivência e estadia em São Carlos mais alegre e prazerosa.

Ao Laboratório de Sistemas de Energia Elétrica, ao Departamento de Engenharia Elétrica e Computação, à Escola de Engenharia de São Carlos e à Universidade de São Paulo, pela infraestrutura para a realização deste trabalho.

Por fim, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo suporte financeiro.

*“... We should always know that we can do anything
Go do, you'll know how to ...”
(Go Do, Jón Þór Birgisson - Jónsi)*

RESUMO

MENEZES, T. S.. **Detecção de Ilhamento de Geradores Distribuídos Utilizando Transformada S e Redes Neurais Artificiais com Máquina de Aprendizado Extremo**. 67 p. Dissertação de Mestrado – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2019.

A conexão de Geradores Distribuídos (GDs) no sistema de distribuição vem se intensificando nos últimos anos. Neste cenário, o aumento de GDs pode trazer alguns benefícios, como a redundância da geração e redução das perdas elétricas. Por outro lado, o problema do ilhamento também vem se destacando. Atualmente, existem técnicas já consolidadas para a detecção do ilhamento, sendo que as técnicas passivas estão entre as mais utilizadas. Entretanto, as técnicas passivas são bastante dependentes do desbalanço de potência entre a geração e as cargas no momento de ocorrência do ilhamento para atuarem corretamente. Caso o desbalanço de potência seja pequeno, as técnicas passivas tendem a não identificar o ilhamento, gerando as chamadas Zonas de Não Detecção (ZNDs). Para mitigar este problema, a pesquisa por técnicas passivas inteligentes baseadas em aprendizagem de máquina vem se tornando cada vez mais comum. Neste trabalho foi modelada uma proteção anti-ilhamento baseada em Redes Neurais Artificiais (RNAs). A classificação do ilhamento é feita com base no espectro de frequência das tensões nos terminais do GD com o uso da Transformada de Stockwell, ou apenas Transformada S (TS). Outro ponto importante da metodologia foi a implementação de uma etapa de detecção de eventos, também baseada nas energias do espectro de frequência das tensões, para evitar a constante execução do classificador. Assim, a RNA apenas irá classificar o evento após receber um sinal de *trigger* da etapa de detecção de evento. Para o treinamento da RNA foram testados dois algoritmos diferentes, o clássico *Backpropagation* (BP) e a Máquina de Aprendizado Extremo, do inglês *Extreme Learning Machine* (ELM). Ressalta-se o melhor desempenho obtido com as redes treinadas pelo ELM, que apresentaram uma capacidade de generalização muito maior, logo, resultando em taxas de acerto mais elevadas. De modo geral, depois de comparada com métodos passivos convencionais para a detecção de ilhamento, a proteção proposta se mostrou mais precisa e com um tempo de detecção muito menor, sendo inferior a 2 ciclos. Por fim, ainda foi realizada a análise das ZNDs para a proteção proposta e as técnicas convencionais, por ser uma característica muito importante para a proteção anti-ilhamento, mas que não é comumente abordada para técnicas passivas inteligentes. Nesta análise, o método para a detecção de ilhamento proposto novamente se sobressaiu às técnicas convencionais, apresentando uma ZND muito menor.

Palavras-chave: Detecção de Ilhamento. Geradores Distribuídos. Máquina de Aprendizado Extremo. Transformada S. Redes Neurais Artificiais.

ABSTRACT

MENEZES, T. S.. **Islanding Detection for Distributed Generators using S-transform and Artificial Neural Networks with Extreme Learning Machine**. 67 p. Master Dissertation – São Carlos School of Engineering, University of São Paulo, São Carlos, 2019.

The connection of distributed generators (DG) in the distribution system has been intensified in the recent years. In this scenario, the increase of DG can bring some benefits, such as generation redundancy and reduction of power losses. On the other hand, the problem of islanding is also been highlighted. Currently, there are already consolidated techniques for islanding detection, and passive techniques are among the most used ones. However, the passive techniques are very dependent of the power unbalance between the generation and the loads at the moment of the islanding in order to actuate properly. If the power mismatch is small, the passive techniques tend to not identify the islanding, generating the so called Non-Detection Zones (NDZ). To mitigate this issue, the research of intelligent passive techniques based in machine learning is becoming more common. In this study, an anti-islanding protection based on Artificial Neural Networks (ANN) was modelled. The islanding classification is done based on the frequency spectrum of the DG's terminal voltages using the Stockwell Transform, or just S-Transform (ST). Another important point of the methodology was the implementation of an event detection stage, also based on the energies of the voltages frequency spectrum, to avoid the constant execution of the classifier. Therefore, the ANN will only classify the event after receiving a trigger signal from the event detection stage. To train the ANN, two different algorithms were tested: the classic Backpropagation and the Extreme Learning Machine (ELM). It is noteworthy the better performance obtained with the neural networks trained by the ELM, which had a greater capacity of generalization, hence resulting in higher success rates. In general, after being compared with conventional passive techniques for islanding detection, the proposed protection was more accurate and with a much smaller detection time, being less than 2 cycles. Finally, the analysis of the NDZ for the proposed protection and the conventional techniques was carried out, as it is a very important feature for anti-islanding protection, but is not commonly addressed for intelligent passive techniques. In this analysis, the islanding detection method proposed again overcame the conventional techniques, presenting a much smaller NDZ.

Keywords: Artificial Neural Networks. Distributed Generators. Extreme Learning Machine. Islanding Detection. S-Transform.

LISTA DE ILUSTRAÇÕES

Figura 1 – Crescimento da potência instalada da geração distribuída no Brasil entre 2015 e 2018.	1
Figura 2 – Métodos para a detecção do ilhamento e suas divisões.	6
Figura 3 – Modelo do neurônio artificial.	14
Figura 4 – Rede Perceptron de múltiplas camadas.	15
Figura 5 – Rede neural com apenas uma camada escondida.	17
Figura 6 – Fluxograma da proteção anti-ilhamento proposta.	21
Figura 7 – Diagrama unifilar do transformador de potencial modelado no ATP.	22
Figura 8 – Espectro de frequência da tensão na fase A com cinco janelas de um ciclo cada com deslocamento de meio ciclo para um caso de falta trifásica de 20 Ω no sistema ocorrendo no meio da segunda janela.	25
Figura 9 – Espectro de frequência da tensão na fase A com cinco janelas de um ciclo cada com deslocamento de meio ciclo para um caso de ilhamento com $\Delta P = 0,409$ p.u. e $\Delta Q = -0,132$ p.u. de desbalanço de potência ocorrendo no meio da segunda janela.	25
Figura 10 – Valor da componente fundamental da tensão na fase A em cinco janelas consecutivas para os casos de (a) falta trifásica de 20 Ω e (b) ilhamento com $\Delta P = 0,409$ p.u. e $\Delta Q = -0,132$ p.u. de desbalanço de potência.	26
Figura 11 – Níveis de frequência do espectro obtido pela TS e suas simplificações.	27
Figura 12 – Valores de energia do espectro de frequência da tensão na fase A para o caso de falta trifásica de 20 Ω para a (a) 1ª janela, (b) 2ª janela, (c) 3ª janela, (d) 4ª janela e (e) 5ª janela apresentadas anteriormente.	28
Figura 13 – Valores de energia do espectro de frequência da tensão na fase A para o caso de ilhamento com $\Delta P = 0,409$ p.u. e $\Delta Q = -0,132$ p.u. de desbalanço de potência para a (a) 1ª janela, (b) 2ª janela, (c) 3ª janela, (d) 4ª janela e (e) 5ª janela apresentadas anteriormente.	29
Figura 14 – Detecção de uma falta trifásica-terra na barra 4 com resistência de falta igual à 20 Ω , com a (a) forma de onda da tensão no secundário do Transformador de Potencial (TP), (b) energia do espectro de frequência filtrada pela Média Móvel (MM) e (c) a sua taxa de variação com o limiar adaptativo.	31

Figura 15 – Detecção de um ilhamento com $\Delta P = 0,409$ p.u. e $\Delta Q = -0,132$ p.u. de desbalanço de potência, com a (a) forma de onda da tensão no secundário do TP, (b) energia do espectro de frequência filtrada pela MM e (c) a sua taxa de variação com o limiar adaptativo.	31
Figura 16 – Fluxograma da etapa <i>online</i> da proteção anti-ilhamento proposta.	35
Figura 17 – Sistema elétrico utilizado no estudo.	38
Figura 18 – Representação monofásica do modelo do transformador saturável no <i>software</i> ATP.	39
Figura 19 – Malha do regulador de excitação para o controle de tensão e potência reativa do gerador síncrono.	40
Figura 20 – Malha do regulador de velocidade para o controle de frequência e potência ativa do gerador síncrono.	42
Figura 21 – Exemplo de matriz de confusão.	44
Figura 22 – Região de desbalanço de potência utilizada para o treinamento (região escura) em comparação com a região utilizada na análise das ZNDs (região clara).	48
Figura 23 – Zona de não detecção da função de proteção 81U/O.	48
Figura 24 – Zona de não detecção da função de proteção 81R.	48
Figura 25 – Zona de não detecção da função de proteção 27/59.	49
Figura 26 – Zona de não detecção da proteção proposta treinada com o BP.	49
Figura 27 – Zona de não detecção da proteção proposta treinada com o ELM.	49
Figura 28 – Aquisição e cálculo da tensão trifásica de saída do gerador distribuído.	61
Figura 29 – Aquisição e cálculo da frequência na saída do gerador distribuído.	62
Figura 30 – Cálculo da taxa de variação da frequência na saída do gerador distribuído.	62
Figura 31 – Diagrama de blocos da função de proteção 81U/O.	63
Figura 32 – Diagrama de blocos da função de proteção 81R.	64
Figura 33 – Diagrama de blocos da função de proteção 27/59.	64

LISTA DE ALGORITMOS

Algoritmo 1 – Algoritmo de treinamento BP.	16
Algoritmo 2 – Algoritmo de treinamento ELM.	19

LISTA DE TABELAS

Tabela 1 – Resumo geral das técnicas e análises presentes nos principais trabalhos correlatos na literatura em comparação com o método proposto.	10
Tabela 2 – Comparação entre a classificação usando BP e ELM em uma RNA.	19
Tabela 3 – Parâmetros elétricos do transformador de potencial.	22
Tabela 4 – Pontos da curva de saturação utilizada no transformador de potencial.	23
Tabela 5 – Índices de avaliação para cada algoritmo de seleção de atributos.	33
Tabela 6 – Índices de avaliação para cada quantidade de atributos selecionados pelo algoritmo <i>Minimal-Redundancy-Maximal-Relevance</i> (mRMR).	33
Tabela 7 – Parâmetros dos transformadores dos alimentadores.	39
Tabela 8 – Valores dos parâmetros do regulador de excitação.	41
Tabela 9 – Valores dos parâmetros do regulador de velocidade.	42
Tabela 10 – Configurações de cada cenário simulado para treinamento e teste da proteção.	43
Tabela 11 – Desempenho médio do método proposto após 500 treinamentos.	45
Tabela 12 – Piores resultados das RNAs treinadas por cada algoritmo.	45
Tabela 13 – Ajuste das funções de proteção convencionais modeladas.	46
Tabela 14 – Resultados obtidos pelas proteções convencionais e o método proposto.	47
Tabela 15 – Configurações de cada cenário simulado para a análise das zonas de não detecção.	47
Tabela 16 – Desempenho de cada proteção para a análise da zona de não detecção.	50
Tabela 17 – Dados dos trechos de linha do sistema e seu comprimento.	65
Tabela 18 – Potências das cargas em cada uma das barras do sistema.	66
Tabela 19 – Dados elétricos e mecânicos da máquina síncrona.	66

LISTA DE SIGLAS

ATP	<i>Alternative Transient Program</i>
BP	<i>Backpropagation</i>
CIGRÉ	<i>Conseil International des Grands Réseaux Électriques</i>
DT	<i>Árvore de Decisão, do inglês Decision Tree</i>
ELM	<i>Máquina de Aprendizado Extremo, do inglês Extreme Learning Machine</i>
EQM	<i>Erro Quadrático Médio</i>
FPB	<i>Filtro Passa Baixa</i>
GD	<i>Gerador Distribuído</i>
MM	<i>Média Móvel</i>
mRMR	<i>Minimal-Redundancy-Maximal-Relevance</i>
MVS	<i>Máquina de Vetor de Suporte</i>
PAC	<i>Ponto de Acoplamento Comum</i>
PLCC	<i>Power Line Carrier Communication</i>
PMC	<i>Perceptron de Múltiplas Camadas</i>
p.u.	<i>por unidade</i>
RMS	<i>Root Mean Square</i>
RNA	<i>Rede Neural Artificial</i>
SCADA	<i>Supervisory Control and Data Acquisition</i>
SD	<i>Sistema de Distribuição</i>
SEP	<i>Sistema Elétrico de Potência</i>
SIN	<i>Sistema Interligado Nacional</i>

<i>SVM</i>	<i>Máquina de Vetor de Suporte, do inglês Support Vector Machine</i>
<i>TFN</i>	<i>Taxa de Falso Negativo</i>
<i>TFP</i>	<i>Taxa de Falso Positivo</i>
<i>TFTC</i>	<i>Transformada de Fourier de Tempo Curto</i>
<i>TP</i>	<i>Transformador de Potencial</i>
<i>TS</i>	<i>Transformada de Stockwell</i>
<i>TVMM</i>	<i>Taxa de Variação da Média Móvel</i>
<i>TW</i>	<i>Transformada Wavelet</i>
<i>ZND</i>	<i>Zona de Não Detecção</i>

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Justificativa	3
1.2	Objetivos	3
1.3	Organização do Documento	4
2	TÉCNICAS PARA A DETECÇÃO DE ILHAMENTO	5
2.1	Métodos Remotos	6
2.2	Métodos Locais	7
2.2.1	Técnicas Locais Ativas	7
2.2.2	Técnicas Locais Passivas	7
2.2.3	Técnicas Passivas Inteligentes	8
2.3	Considerações Finais	11
3	APRENDIZAGEM DE MÁQUINA	13
3.1	Redes Neurais Artificiais	14
3.1.1	Treinamento Convencional da RNA	16
3.1.2	Máquina de Aprendizado Extremo	17
3.1.3	Comparação entre BP e ELM	19
3.2	Considerações Finais	20
4	PROTEÇÃO ANTI-ILHAMENTO BASEADA EM APRENDIZAGEM DE MÁQUINA	21
4.1	Etapa <i>offline</i> - treinamento	22
4.1.1	Adequação do sinal	22
4.1.2	Transformada S	23
4.1.3	Energia do sinal	26
4.1.4	Detecção de eventos	30
4.1.5	Seleção de Atributos	32
4.1.6	Treinamento da RNA	33
4.2	Etapa <i>online</i> - operação	34
4.3	Considerações Finais	35
5	RESULTADOS E DISCUSSÕES DA METODOLOGIA PROPOSTA	37
5.1	Sistema em estudo	37

5.1.1	Transformadores	39
5.1.2	Gerador Síncrono	39
5.1.2.1	Regulador de tensão	40
5.1.2.2	Regulador de velocidade	41
5.2	Simulações Computacionais do Sistema Teste	43
5.3	Métricas de avaliação de desempenho	44
5.4	Resultados do método proposto	44
5.5	Comparação com métodos convencionais	46
5.6	Zona de não detecção	47
5.7	Considerações Finais	50
6	CONCLUSÕES	53
6.1	Publicações decorrentes desta pesquisa	54
6.2	Publicações em áreas correlatas a pesquisa	54
6.3	Trabalhos futuros	55
	REFERÊNCIAS	57
	APÊNDICE A FUNÇÕES DE PROTEÇÃO CONVENCIONAIS	61
A.1	Aquisição de dados	61
A.1.1	Tensão eficaz	61
A.1.2	Frequência e taxa de variação da frequência	62
A.2	Funções de proteção	63
A.2.1	Função 81U/O	63
A.2.2	Função 81R	63
A.2.3	Função 27/59	64
	ANEXO A SISTEMA DE TESTE DO CIGRÉ	65
A.1	Sistema Elétrico	65
A.2	Gerador Síncrono	66

INTRODUÇÃO

Nos últimos anos o Sistema Elétrico de Potência (SEP) brasileiro vem passando por diversas mudanças, como o aumento da interconexão no Sistema Interligado Nacional (SIN), ampliando assim a conexão de fontes alternativas para a geração de energia elétrica, incluindo fontes renováveis e de combustíveis fósseis. Este crescimento da geração distribuída pode ser visualizado na Figura 1, com a potência instalada acumulada dos Geradores Distribuídos (GDs) nos anos anteriores (em azul) e o aumento no período (em laranja).

Figura 1 – Crescimento da potência instalada da geração distribuída no Brasil entre 2015 e 2018.

Fonte: ANEEL (2019).

A presença dos GDs no Sistema de Distribuição (SD) pode levar a uma redução nas perdas elétricas do sistema e melhoria no perfil de tensão dos alimentadores próximos ao Ponto de Acoplamento Comum (PAC) do GD. Além disso, a alocação de geradores ao longo da distribuição diversifica as fontes para a geração de energia, reduzindo a necessidade de grandes linhas para a transmissão de energia, já que a geração se encontra próxima às cargas.

Entretanto, a geração distribuída pode trazer algumas desvantagens ao sistema elétrico, como a elevação de tensão na condição de carga leve e problemas de proteção, devido a bidirecionalidade no fluxo de potência. Outro problema relacionado a geração distribuída é o ilhamento, que é uma situação em que uma porção do SD se encontra eletricamente isolada do restante do SEP, mas permanece energizada por um GD conectado a ela. O ilhamento pode ocorrer devido a atuação da proteção em uma condição de falta ou mesmo devido a uma manobra para manutenção de algum equipamento pela distribuidora.

O ilhamento pode ser classificado em dois tipos, intencional e não intencional. No ilhamento intencional o GD permanecerá alimentando o sistema ilhado intencionalmente, assegurando que este continuará energizado. Já no ilhamento não intencional, após a detecção da ocorrência do ilhamento, o GD é desconectado para evitar possíveis problemas, tais como risco à equipe de manutenção da distribuidora, aterramento inadequado, perda da coordenação da proteção de sobrecorrente e religamento fora de sincronismo.

Deste modo, o estudo de técnicas para a detecção do ilhamento se torna ainda mais importante, seja para a atuação da proteção anti-ilhamento ou ainda para que o sistema de gerenciamento seja capaz de atuar para manter a estabilidade do sistema, no caso de um ilhamento intencional. Para qualquer que seja o objetivo da detecção, de acordo com a norma 1547 do IEEE o tempo de detecção do ilhamento deve ser inferior a 2 segundos (IEEE... , 2018).

Convencionalmente, as técnicas de detecção de ilhamento utilizam tensão e frequência como parâmetros para detectar a ocorrência do mesmo. Porém, o tipo das cargas presentes no sistema e o desbalanço energético entre geração e consumo podem afetar o desempenho da detecção, criando situações em que a proteção não consiga detectar o ilhamento, conhecidas como Zonas de Não Detecção (ZNDs). Portanto, para aumentar a confiabilidade da proteção, as ZNDs devem ser minimizadas. Para isso, busca-se o desenvolvimento de novas técnicas para a detecção do ilhamento, ou mesmo o aprimoramento das já existentes.

Outro fator que pode influenciar a detecção do ilhamento é o tipo da unidade geradora, podendo ser rotativa ou estática. A geração estática está relacionada aos GDs que utilizam conexões com interface por meio de técnicas da eletrônica de potência, como o uso de inversores. Atualmente, no SIN este tipo de geração tem uma baixa representatividade. Já as máquinas rotativas incluem os geradores síncronos e de indução, sendo a maioria das unidades geradoras instaladas no sistema elétrico brasileiro. Entretanto, por serem utilizadas na geração hidráulica e termoelétrica, as máquinas síncronas são mais empregadas quando comparadas com as de indução (Ministério de Minas e Energia, 2018).

Neste contexto, será apresentada no decorrer deste trabalho uma técnica de detecção do ilhamento voltada para geradores síncronos. O método baseia-se na extração de características e reconhecimento de padrões nos sinais de tensão amostrados nos terminais do gerador síncrono. Para isso, o sinal de tensão será pré-processado com o uso da Transformada de Stockwell (TS) para a extração de características do espectro de frequência, sendo a sua escolha baseada em

pontos positivos abordados pela literatura, como a melhor representação do espectro e menor sensibilidade a ruídos (MOUKADEM; ABDESLAM; DIETERLEN, 2014). Já o reconhecimento dos padrões presentes no sinal pré-processado será realizado por técnicas de aprendizagem de máquina, em específico uma Rede Neural Artificial (RNA), sendo usado um novo algoritmo de treinamento chamado Máquina de Aprendizado Extremo, do inglês *Extreme Learning Machine* (ELM) (HUANG; ZHU; SIEW, 2006) e um algoritmo clássico de treinamento, denominado *Backpropagation* (BP).

1.1 Justificativa

Em geral a proteção dos geradores síncronos é feita com o uso de técnicas locais de detecção passiva, que consistem na leitura de parâmetros do sistema elétrico, como a tensão e frequência. Caso a grandeza medida exceda um limiar definido para a sua operação, a proteção acusará a ocorrência do ilhamento. As técnicas passivas apresentam como desvantagem o surgimento de grandes ZNDs. Estas zonas podem ser minimizadas com o ajuste do limiar da proteção, porém isto pode ser uma tarefa árdua. Caso o valor do limiar esteja muito baixo, a proteção irá atuar de forma indevida, mas caso este esteja muito elevado a proteção pode não vir a atuar.

Logo, há uma necessidade em se utilizar uma técnica capaz de distinguir adequadamente uma situação de ilhamento de uma condição normal de operação do sistema. Para efetuar tal distinção, deve-se utilizar uma técnica capaz de reconhecer e classificar os padrões presentes no sinal. A RNA é uma das técnicas indicadas para a classificação destes diferentes fenômenos.

Para garantir o desempenho destas técnicas de aprendizagem de máquina, o banco de dados para o treinamento deverá englobar uma grande quantidade de fenômenos, os quais se deseja classificar. Assim sendo, será necessário a utilização de um *software* para a simulação do sistema elétrico a ser estudado e, conseqüentemente, obter os dados referentes a cada um dos fenômenos. Para este estudo será utilizado o *software Alternative Transient Program* (ATP) com o uso da interface do *ATPDraw* para modelar um sistema elétrico teste e obter todos os dados de entrada necessários para o treinamento do classificador.

Um fator que pode influenciar no desempenho das RNAs é o algoritmo de treinamento. Para este estudo foi utilizado um novo algoritmo de treinamento, o ELM, para a RNA de modo a suprir as deficiências dos algoritmos convencionais, como o elevado esforço computacional demandado e a convergência para mínimos locais.

1.2 Objetivos

O objetivo deste trabalho é desenvolver uma proteção anti-ilhamento para geradores síncronos distribuídos visando melhorar a detecção do ilhamento e reduzir as ZNDs. Esta

proteção tem como base a extração de características com a TS e a classificação dos eventos com uma Rede Neural Artificial. Para isso, os objetivos a seguir devem ser alcançados:

- **Compreensão do problema:**
 - Buscar na literatura técnicas convencionais de detecção do ilhamento e o uso de técnicas inteligentes, bem como formas de avaliar a proteção anti-ilhamento de modo adequado.
- **Modelagem do sistema elétrico:**
 - Modelar e simular o sistema elétrico a ser estudado através de um *software* de simulação de sistemas elétricos;
 - Extrair os dados da simulação e salvá-los para serem utilizados durante a modelagem da proteção.
- **Projeto da proteção anti-ilhamento:**
 - Projetar a proteção anti-ilhamento baseada no uso da TS e nas RNAs.
- **Avaliação da proteção projetada:**
 - Desenvolver métricas para avaliar a proteção anti-ilhamento modelada com o intuito de analisar o seu desempenho.

1.3 Organização do Documento

Este documento foi organizado da seguinte forma:

- **Capítulo 2:** apresenta a problemática envolvendo a não detecção do ilhamento e as principais técnicas para a sua detecção. Ao final do capítulo é feita uma revisão sobre o uso de técnicas inteligentes para a detecção do ilhamento.
- **Capítulo 3:** aborda as principais características das RNAs e os seus algoritmos de treinamento. As diferenças entre o algoritmo clássico de treinamento das RNAs e o ELM também serão abordadas.
- **Capítulo 4:** elucida os parâmetros, configurações e funcionamento da proteção anti-ilhamento proposta.
- **Capítulo 5:** expõe os resultados obtidos com a aplicação da metodologia proposta, incluindo a análise das ZNDs.
- **Capítulo 6:** ressalta as discussões finais, contribuições e propostas para a continuidade do trabalho.

TÉCNICAS PARA A DETECÇÃO DE ILHAMENTO

O ilhamento pode ser fruto de diversos fenômenos no sistema, como a atuação da proteção devido a um curto-circuito, ou mesmo o desligamento por parte da distribuidora para efetuar manutenção em certa parte do sistema. Independente da origem do ilhamento, alguns problemas podem surgir, tais como ([WALLING; MILLER, 2002](#)):

- Risco à equipe de manutenção da distribuidora pela alimentação do sistema pelos GDs ser mantida após as fontes primárias terem sido retiradas;
- Risco à população no caso de cabos partidos permanecerem energizados mesmo após a proteção ter atuado de modo a desenergizar o sistema;
- A tensão e frequência do sistema ilhado podem não permanecer dentro dos limites de operação estabelecidos pelas normas reguladoras, podendo vir a danificar tanto as cargas presentes no sistema ilhado quanto o próprio GD;
- Dependendo da configuração do transformador de interconexão, o sistema ilhado pode perder a referência de terra para a sua operação. Assim, para casos de falta fase-terra, pode ser difícil, ou impossível, a detecção pelos relés de sobrecorrente, já que a corrente de falta é muito pequena ou mesmo nula. Esta situação pode danificar os elementos do sistema, pois as fases sãs podem sofrer uma elevação de tensão da ordem de 1,7 vezes a nominal durante uma falta fase-terra franca; e
- Perda de sincronismo durante a operação de religamento pelo religador automático. Isso se dá ao fato de que, durante um evento de falta no sistema, a atuação da proteção pode formar uma ilha ao tentar isolar a falta. Porém, a falta permanecerá alimentada no sistema pelo GD, e quando o religador atuar para reenergizar o sistema, os dois sistemas estarão fora de sincronismo, o que pode causar o surgimento de correntes elevadas que podem vir a danificar os elementos do sistema.

Devido a todos os possíveis problemas supramencionados, o ilhamento deve ser detectado de forma rápida e confiável. De acordo com as recomendações da norma 1547 do IEEE, o ilhamento deve ser detectado em até 2 segundos (IEEE..., 2018). Vale ressaltar que este tempo pode ser menor caso haja religador automático no sistema de distribuição, pois a proteção anti-ilhamento deverá atuar antes que o religamento ocorra.

Os métodos mais comuns para a detecção do ilhamento são os métodos remotos e locais, sendo que os métodos locais podem ainda ser divididos em métodos baseados em técnicas ativas, passivas e híbridas (que possuem características das técnicas ativas e passivas). Porém, nos últimos anos, as técnicas passivas inteligentes vêm sendo estudadas com maior intensidade, gerando assim uma subdivisão nas técnicas passivas. O diagrama de divisões das técnicas de detecção do ilhamento está representado na Figura 2.

Figura 2 – Métodos para a detecção do ilhamento e suas divisões.

Fonte: Elaborada pelo autor.

2.1 Métodos Remotos

Por utilizarem um canal de comunicação entre a distribuidora de energia e o GD, os métodos remotos apresentam grande confiabilidade. Entretanto, possuem alto custo de implementação, devido à infraestrutura necessária, e no caso de falha na comunicação podem ocasionar a retirada dos GDs ao longo do sistema de forma indevida. Nesta situação, seria necessária a utilização de alguma técnica local de modo a impedir esta atuação indevida da proteção causada pela perda da comunicação. Alguns exemplos de técnicas remotas são:

- **Sistema com *Supervisory Control and Data Acquisition* (SCADA):** utilizam um sistema supervisor para monitorar o estado de cada uma das chaves e disjuntores do SEP, assim sendo capazes de detectar quando uma porção do sistema encontra-se ilhada. Neste caso, um sinal é enviado ao GD por meio do canal de comunicação para que o mesmo se desconecte do sistema; e
- **Sistema com *Power Line Carrier Communication* (PLCC):** um sinal é gerado no sistema de transmissão e é continuamente transmitido para os alimentadores do SD

por meio dos próprios cabos das linhas de distribuição. Os GDs possuem dispositivos receptores, e caso o sinal não seja recebido (no caso de haver um disjuntor aberto entre a subestação e o GD, por exemplo) o ilhamento é identificado e o GD é retirado do sistema.

2.2 Métodos Locais

As técnicas locais se baseiam na leitura de parâmetros do sistema elétrico nas proximidades do GD, normalmente no PAC. Estas técnicas podem ainda ser divididas em técnicas de detecção ativas, passivas, e híbridas. Porém, apenas as técnicas ativas e passivas serão descritas ao decorrer desta seção.

2.2.1 Técnicas Locais Ativas

Os métodos locais baseados em técnicas ativas, inserem uma pequena perturbação no sistema e com a sua análise verificam possíveis alterações no SEP. A principal ideia é que esta perturbação resultará em pequenas oscilações no sistema quando conectado à rede de distribuição, mas durante o ilhamento as oscilações resultantes serão significativas, possibilitando assim a detecção do ilhamento a partir da resposta do sistema às perturbações inseridas. A maioria das técnicas ativas de detecção foram desenvolvidas para GDs que utilizam inversores de frequência. Porém, algumas técnicas, como a medição da impedância e erro da potência reativa injetada, foram propostos para geradores síncronos (LAGHARI *et al.*, 2014)

Apesar destes métodos apresentarem uma elevada taxa de acerto na detecção do ilhamento e possuírem um baixo custo, a inserção de oscilações e distúrbios no sistema podem gerar problemas de qualidade da energia elétrica. Outra desvantagem está relacionada ao tempo de detecção, que é normalmente elevado devido ao tempo de resposta da perturbação no sistema. A grande vantagem das técnicas ativas é que elas apresentam ZNDs muito pequenas, podendo detectar o ilhamento até em casos de total equilíbrio entre a geração e o consumo (MAHAT; CHEN; BAK-JENSEN, 2008).

2.2.2 Técnicas Locais Passivas

Os métodos baseados em técnicas passivas são os mais utilizados por serem de fácil implementação e apresentarem um custo reduzido, principalmente os métodos baseados em frequência (XU; MAUCH; MARTEL, 2004). O seu funcionamento consiste na leitura de parâmetros do sistema, como tensão e frequência, para tomar a decisão, que na maioria dos casos possui baixo tempo de atuação. Entretanto, caso durante o ilhamento os parâmetros do sistema não sofram alterações significativas, como ocorre em situações que a potência produzida pelo GD é semelhante a potência consumida pelas cargas, o ilhamento pode não ser detectado, apresentando assim grandes ZNDs (LAGHARI *et al.*, 2014).

Na ocorrência do ilhamento, é comum o surgimento de um desbalanço de potência ativa e/ou reativa entre o consumo das cargas e a geração do GD. Com o desbalanço de potência reativa durante o ilhamento, pode ocorrer elevações ou afundamentos na magnitude da tensão, dependendo do caso de excesso ou déficit de potência. Com isso, o ilhamento pode ser detectado a partir do monitoramento da tensão e a comparação com limites inferiores e superiores para a magnitude da tensão do sistema.

Analisando o desbalanço de potência ativa durante o ilhamento é normal que ocorra distúrbio na frequência. Assim, as técnicas baseadas na frequências são as mais utilizadas para a detecção do ilhamento. No caso do relé de sub ou sobre frequência, se o valor da frequência medido exceder um dos limiares estabelecidos, o relé irá atuar para desconectar o GD. Entretanto, em casos em que a frequência varia mais lentamente, o relé de taxa de variação da frequência apresenta melhores resultados, com menores tempos de detecção (XU; MAUCH; MARTEL, 2004).

Outras técnicas passivas para a detecção do ilhamento incluem a taxa de variação da potência ativa e reativa de saída (AGHDAM *et al.*, 2011), distorção harmônica, desbalanço de tensão (JANG; KIM, 2004) e variação da impedância vista pelo GD (GHANEM *et al.*, 2017).

Contudo, por apresentarem baixo custo e tempo de atuação e ainda não prejudicarem a qualidade da energia, os métodos locais baseados em técnicas passivas são muito empregados no sistema elétrico.

2.2.3 Técnicas Passivas Inteligentes

A maior desvantagem para o uso de técnicas passivas está relacionada à sua dependência no desbalanço de potência (ativa e/ou reativa) para detectar o ilhamento corretamente. Em situações onde a potência produzida pelo GD é muito similar à consumida pelas cargas, as técnicas passivas convencionais tendem a não conseguir efetuar a detecção do ilhamento. Para se obter melhores resultados durante tais situações, técnicas passivas inteligentes vem sendo estudadas.

Lidula e Rajapakse (2009) propuseram a análise de transitórios nos sinais de corrente para a identificação do ilhamento em um sistema com dois geradores síncronos. Devido à presença de componentes de alta frequência durante o evento, foi utilizada uma taxa amostral de 20 kHz. Os sinais foram pré-processados com o uso da Transformada Wavelet (TW) (até o sexto nível de decomposição) e a classificação foi realizada com 3 diferentes classificadores (Árvore de Decisão, do inglês *Decision Tree* (DT), Rede Neural Probabilística e Máquina de Vetor de Suporte, do inglês *Support Vector Machine* (SVM)). Utilizando a energia dos coeficientes da TW o método mostrou potencial para a identificação do ilhamento, porém a taxa de acerto obtida ainda estava bastante inferior à encontrada utilizando as técnicas passivas convencionais.

Dando continuidade à pesquisa, Lidula e Rajapakse (2010) efetuaram algumas alterações

no método proposto anteriormente para a detecção do ilhamento, agora em um sistema com um gerador síncrono e um de indução. A taxa amostral foi reduzida para 10 kHz, considerando a taxa de acerto encontrada, esforço computacional e custo de equipamento para uma aplicação em tempo real. Com o uso da energia dos coeficientes da TW (até o quarto nível de decomposição) da tensão e corrente, a classificação utilizando uma DT, com cinco nós de profundidade, obteve uma taxa de acerto acima de 98%. Neste trabalho foi efetuada a seleção de atributos, que consiste em selecionar as entradas mais relevantes para a classificação do ilhamento, de modo a simplificar o modelo e reduzir o tempo de treinamento e execução.

Já [Fayyad e Osman \(2010\)](#) efetuaram um estudo similar para a detecção do ilhamento em um sistema com dois geradores síncronos, com o uso da TW para a extração de características do sinal e o classificador utilizado foi uma RNA. Com uma taxa de amostragem de 10 kHz e com a decomposição da TW até o sétimo nível da tensão no PAC, obteve-se uma taxa de acerto média superior a 97%.

Em 2012, o estudo realizado por [Lidula e Rajapakse \(2012\)](#) voltou-se para a detecção de ilhamento em um sistema com a presença de GDs com inversor de frequência. Mantendo a metodologia apresentada no estudo realizado anteriormente ([LIDULA; RAJAPAKSE, 2010](#)), mantendo a taxa de amostragem de 10 kHz, obteve-se uma taxa de acerto semelhante. Realizando uma comparação com métodos passivos de detecção de ilhamento, incluindo relés de frequência e tensão, verificou-se que o método proposto apresenta uma confiabilidade maior e com um tempo de atuação menor.

Entretanto, apesar de os trabalhos mencionados até o momento terem obtido resultados satisfatórios, todos apresentam um ponto negativo em comum, a elevada taxa de amostragem. Por utilizarem taxas amostrais de 10 kHz ([LIDULA; RAJAPAKSE, 2010](#); [FAYYAD; OSMAN, 2010](#); [LIDULA; RAJAPAKSE, 2012](#)) e 20 kHz ([LIDULA; RAJAPAKSE, 2009](#)), uma implementação do método seria bastante onerosa. Logo, a aplicação destas técnicas pode se tornar inviável, não em razão da sua precisão, mas por motivos econômicos.

Com o intuito de investigar qual a melhor técnica para a extração de características, [Ray, Kishor e Mohanty \(2012\)](#) efetuaram um estudo comparativo entre a TW e a TS. Tendo como objetivo a extração de característica para a detecção do ilhamento e eventos de perturbação da qualidade da energia elétrica em um sistema com diferente tipos de fontes geradoras, os autores constataram, a partir de uma análise qualitativa e quantitativa, que a melhor resposta foi obtida com o uso da TS.

Utilizando a TW para extrair características da componente de sequência negativa da tensão (V_2), [Mishra et al. \(2016b\)](#) efetuaram um estudo comparativo para encontrar o melhor classificador para a detecção do ilhamento em um sistema com dois GDs. Após comparar os resultados da classificação obtida utilizando SVM, RNA, algoritmo de clusterização baseado em evolução diferencial, ELM e DT, encontrou-se que o melhor resultado, mesmo em condições com a presença de ruído nos sinais de entrada, foi obtido com o ELM. Os autores destacaram

ainda a importância de se considerar outros parâmetros além da taxa de acerto para devidamente se avaliar um método de classificação.

No mesmo ano, [Mishra et al. \(2016a\)](#) analisaram a detecção do ilhamento utilizando ELM a partir da extração de características da componente de sequência negativa da tensão (V_2) e corrente (I_2) com a TS. O resultado encontrado foi comparado com outras técnicas de classificação, e o método proposto apresentou-se promissor, com desempenho superior à RNA com treinamento clássico e ao SVM, mesmo na presença de ruído no sinal de entrada. Entretanto, devido ao processamento adicional para calcular as componentes simétricas dos sinais, os métodos apresentados em ([MISHRA et al., 2016b](#)) e ([MISHRA et al., 2016a](#)) apresentam um esforço computacional maior.

Com base nos trabalhos supracitados, foi montada uma metodologia para a detecção de ilhamento com base em pontos positivos encontrados, suprimindo algumas deficiências e ao mesmo incluindo novas análises. Um resumo geral dos trabalhos correlatos com a metodologia proposta é apresentado na Tabela 1.

Tabela 1 – Resumo geral das técnicas e análises presentes nos principais trabalhos correlatos na literatura em comparação com o método proposto.

	Lidula e Rajapakse (2009)	Lidula e Rajapakse (2010)	Fayyad e Osman (2010)	Lidula e Rajapakse (2012)	Ray, Kishor e Mohanty (2012)	Mishra et al. (2016b)	Mishra et al. (2016a)	Método proposto
Sinal	I	V e I	V	V e I	V	V_2	V_2 e I_2	V
TW	✓	✓	✓	✓	✓	✓		
TS					✓		✓	✓
DT	✓	✓		✓		✓		
RNA	✓		✓			✓	✓	✓
ELM						✓	✓	✓
SVM	✓					✓	✓	
Cluster						✓		
Taxa amostral	20 kHz	10 kHz	10 kHz	10 kHz	*	2,4 kHz	2,4 kHz	3,84 kHz
Dados de treinamento	206 casos	758 casos	120 casos	2901 casos	*	335 casos	170 casos	1600 casos
Dados de teste	69 casos	129 casos	60 casos	420 casos	*	665 casos	330 casos	5776 casos
Seleção de atributos		✓						✓
81U/O				✓				✓
81R	✓			✓				✓
27/59				✓				✓
Análise das ZNDs			†					✓

Fonte: Elaborada pelo autor.

* Valores não disponíveis no trabalho.

† Apesar de mencionar a redução, a ZND da proteção anti-ilhamento proposta não foi apresentada.

Com os dados da Tabela 1 é possível perceber as diferenças presentes entre os trabalhos correlatos e o método proposto. Destaca-se a distribuição dos dados de treinamento e teste, sendo utilizados poucos casos principalmente para os testes da proteção. Entretanto, os dados de teste utilizados neste trabalho são muito superiores aos demais, com mais de 5700 casos analisados. Além disso, a análise das ZNDs é um diferencial do presente trabalho, já que esta não é uma análise muito utilizada na literatura para as técnicas passivas inteligentes.

A metodologia proposta para a detecção de ilhamento utiliza a TS para pré-processamento do sinal de tensão e a classificação do evento é realizada por uma RNA treinada pelo algoritmo ELM. Outro ponto de destaque da metodologia é o uso de uma taxa amostral de apenas 64 amostras por ciclo (3840 Hz), que é uma taxa comumente encontrada em relés digitais. Adicionalmente, o desempenho da metodologia proposta é comparado com o de métodos passivos convencionais, incluindo a análise das ZNDs. Esta metodologia proposta será apresentada em maiores detalhes no Capítulo 4.

2.3 Considerações Finais

Pode-se concluir que a pesquisa de técnicas de detecção do ilhamento ainda pode passar por muitas mudanças e melhorias. Contudo, devido ao desenvolvimento das técnicas inteligentes para a detecção do ilhamento, pontos negativos, como as grandes ZNDs das proteções passivas, vem sendo minimizados.

Assim, este trabalho irá se concentrar no uso de algumas características positivas apresentadas na literatura para modelar uma proteção passiva inteligente para detectar o ilhamento em um sistema de distribuição com um gerador síncrono distribuído.

APRENDIZAGEM DE MÁQUINA

As técnicas de aprendizagem de máquina são caracterizadas por utilizarem recursos da inteligência artificial, biologia e matemática em geral, para construir um modelo capaz de aprender determinado padrão ou relação entre os dados, podendo estas relações serem previamente conhecidas ou não ([AWAD; KHANNA, 2015](#)).

Utilizando o conceito de aprendizado com base em experiências, os modelos se ajustam automaticamente a fim de encontrar a melhor resposta para determinado problema. O método de aprendizagem pode ser dividido em dois tipos: supervisionado e não supervisionado.

No treinamento supervisionado, o algoritmo de treinamento tem à disposição os dados de entradas e as repostas de saída desejadas, conseguindo assim encontrar o erro entre a resposta atual e desejada para ajustar os seus parâmetros internos. Os métodos de aprendizado supervisionado incluem, dentre outros, **AD!**, Sistemas Fuzzy, Máquina de Vetor de Suporte e Redes Neurais Artificiais.

Já no caso do treinamento não supervisionado, o algoritmo encontra de forma autônoma as relações entre os dados de entrada e os classifica de acordo com as semelhanças encontradas. Normalmente estes algoritmos associam o seu aprendizado a métricas que devem ser otimizadas. Dentre os algoritmos de aprendizado não supervisionado pode-se citar os Mapas Auto Organizáveis de Kohonen e o *K-means*.

A escolha entre cada um dos tipos de treinamento depende do problema a ser aplicado e da disponibilidade dos dados de saída. Nesse trabalho serão analisadas apenas técnicas de treinamento supervisionado pelo fato das saídas desejadas para a classificação já serem conhecidas. Dentre as técnicas de aprendizagem supervisionadas serão abordadas apenas as RNAs.

3.1 Redes Neurais Artificiais

As RNAs são modelos computacionais baseados no sistema nervoso biológico, sendo capazes de adquirir e manter o conhecimento por meio de experiência. De forma análoga ao modelo biológico que apresenta os neurônios com suas ligações sinápticas, o modelo artificial apresenta unidades de processamento (neurônios artificiais) interligadas de modo a processar um sinal de entrada por meio da troca de informações feita pelas ligações sinápticas artificiais, sendo representadas por vetores/matrizes de pesos sinápticos.

A Figura 3 apresenta os principais componentes do modelo de um neurônio artificial com n sinais de entrada, sendo eles:

Figura 3 – Modelo do neurônio artificial.

Fonte: Elaborada pelo autor.

- **Sinais de entrada (x)**

São os sinais externos a serem analisados pelo neurônio, sendo normalmente normalizados com o intuito de otimizar o processamento computacional por parte do algoritmo de treinamento;

- **Pesos sinápticos (w)**

São valores utilizados para ponderar cada uma das variáveis de entrada, permitindo que as entradas apresentem diferentes importâncias para cada neurônio da rede;

- **Combinação linear (Σ)**

Tem como função combinar todos os sinais de entrada, devidamente ponderados pelos seus pesos sinápticos, para obter um valor de potencial de ativação do neurônio;

- **Limiar de ativação (θ)**

Especifica um nível a partir do qual o resultado da combinação linear gera um disparo em direção a saída do neurônio;

- **Potencial de ativação (u)**

É o resultado da diferença entre a saída da combinação linear das entradas e o limiar de ativação;

- **Função de ativação (g)**

Tem como objetivo limitar a saída do neurônio em um intervalo limitado, normalmente entre 0 e 1 ou -1 e 1;

- **Sinal de saída (y)**

É o valor final de saída do neurônio, podendo ainda servir como entrada para outros neurônios subsequentes.

Ainda com base na Figura 3, o sinal de saída do neurônio pode ser encontrado como expresso nas equações abaixo.

$$u = \left(\sum_{i=1}^n w_i \cdot x_i \right) - \theta \quad (3.1)$$

$$y = g(u) \quad (3.2)$$

Apesar da sua simplicidade, uma rede contendo apenas um neurônio é capaz de resolver problemas simples de classificação binária, desde que as classes sejam linearmente separáveis, como é o caso das redes Perceptron e Adaline. Por terem apenas um neurônio, o algoritmo responsável pelo treinamento da rede efetua uma relação direta entre o erro da saída com os pesos sinápticos e assim ajustar os parâmetros necessários para minimizar o erro.

Para problemas com maior complexidade há a necessidade de se combinar múltiplos neurônios em uma rede com uma ou mais camadas intermediárias, conhecidas como camadas escondidas. Sendo a rede Perceptron de Múltiplas Camadas (PMC) a representante mais conhecida das redes neurais de múltiplas camadas. A Figura 4 apresenta uma topologia genérica de uma rede PMC.

Figura 4 – Rede Perceptron de múltiplas camadas.

Fonte: Elaborada pelo autor.

Diferentemente do que ocorre com o treinamento das redes com apenas um neurônio, a rede PMC não consegue estabelecer uma relação direta entre o erro da camada de saída com os pesos das camadas intermediárias. Desta forma, o algoritmo de treinamento da rede PMC é mais complexo. Na subseção a seguir o treinamento da rede PMC será tratado com mais detalhes.

3.1.1 Treinamento Convencional da RNA

O grande desenvolvimento e aplicação das redes PMC se deu no final dos anos 1980, com a divulgação do algoritmo de treinamento BP. O processo de treinamento completo e a teoria envolvida é tratado em [Silva, Spatti e Flauzino \(2010\)](#). De forma resumida o algoritmo de treinamento opera de modo a encontrar o erro da saída e ajustar os pesos sinápticos e limiares de ativação de todas as camadas neurais até que o erro seja minimizado, efetuando o ajuste várias vezes de forma iterativa.

A execução do algoritmo exige a definição de alguns parâmetros, que são a taxa de aprendizagem e a precisão requerida. A taxa de aprendizagem especifica o quanto a rede neural irá aprender a partir de cada experiência, e a precisão requerida é o critério de parada utilizado como valor máximo para o Erro Quadrático Médio (EQM). Assim, quando o EQM for menor que a precisão requerida o algoritmo finaliza o processo de treinamento da rede. Entretanto, para o caso do algoritmo não conseguir convergir para um valor menor que o especificado, deve-se estipular um número máximo de iterações para garantir a parada do treinamento. Com isso, o treinamento é realizado como apresentado no Algoritmo 1.

Algoritmo 1: Algoritmo de treinamento BP.

Entrada: Dados de treinamento

Saída: W e θ

início

$X \leftarrow$ Amostras de entrada do treinamento

$T \leftarrow$ Saídas desejadas para cada amostra de treinamento

$\eta \leftarrow$ taxa de aprendizagem

$\varepsilon \leftarrow$ precisão desejada

inicializa os pesos sinápticos e limiares de ativação, W e θ , com valores aleatórios

enquanto $EQM > \varepsilon$ **faça**

para *Todas as k amostras do treinamento* **faça**

obtem a saída $Y(k)$

calcula o erro $\Rightarrow \Delta Y(k) = Y(k) - T(k)$

ajusta os valores de W e θ

fim

calcula o EQM

fim

fim

retorna W e θ *ajustados*

Apesar de conseguir bons resultados em geral, o BP apresenta alguns pontos negativos, como os apresentados na sequência:

- **Taxa de aprendizagem:** Se seu valor for pequeno o algoritmo pode levar muito tempo para convergir. Já para valores elevados, o algoritmo pode perder a estabilidade e não convergir;
- **Mínimo local:** Há a possibilidade de o algoritmo convergir para um ponto de mínimo local do erro muito distante do valor de mínimo global;
- **Overfitting:** Com o BP a rede pode ser sobre ajustada, levando à perda da generalização; e
- **Tempo de treinamento:** Devido ao processo iterativo de treinamento, o BP pode levar um tempo elevado para convergir, resultando em grande esforço computacional.

3.1.2 Máquina de Aprendizado Extremo

O algoritmo de treinamento ELM foi publicado em um trabalho de [Huang, Zhu e Siew \(2006\)](#). O objetivo de seu desenvolvimento foi resolver os problemas relacionados ao BP mencionados anteriormente, resultando em redes com boa generalização e tempo de treinamento da ordem de 1000 vezes mais rápido em alguns testes realizados no trabalho original de divulgação do método.

O ELM tem como foco o treinamento de redes neurais com apenas uma camada escondida, como apresentada na Figura 5,

Figura 5 – Rede neural com apenas uma camada escondida.

Fonte: Elaborada pelo autor.

onde,

a é a matriz dos pesos sinápticos entre a camada de entrada e a camada neural escondida;
 f é a saída de cada um dos neurônios da camada neural escondida;

β é a matriz dos pesos sinápticos entre a camada neural escondida e a camada neural de saída; e Y é o vetor de saída da rede neural.

Diferentemente do BP que efetua os ajustes de todos os pesos e limiares da rede neural, o ELM inicializa os pesos com valores aleatórios e ajusta de forma analítica apenas os pesos entre a camada intermediária e a de saída (matriz β), o que garante a sua velocidade, por utilizar apenas uma iteração para treinar a RNA.

Considerando uma função de ativação $g(\cdot)$ para cada um dos neurônios da camada escondida, a saída de cada um dos neurônios pode ser definida como,

$$f_i = g \left(\sum_{j=1}^n (x_{j,1} \cdot a_{i,j} - b_{i,1}) \right), i = 1, \dots, k. \quad (3.3)$$

Assim, com um conjunto de treinamento com N amostras, a saída da rede neural para cada amostra de entrada pode ser calculada da seguinte forma,

$$Y_j = \sum_{i=1}^k \beta_i \cdot f_i, j = 1, \dots, N. \quad (3.4)$$

Como deseja-se que o erro na saída seja igual a zero, a saída da rede neural deverá ser igual ao seu valor desejado (T). Deste modo a Equação (3.4) pode ser reescrita como,

$$H\beta = T \quad (3.5)$$

onde,

$$H = \begin{bmatrix} f_{1,1} & \cdots & f_{1,k} \\ \vdots & \ddots & \vdots \\ f_{N,1} & \cdots & f_{N,k} \end{bmatrix}_{N,k}, \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_k^T \end{bmatrix}_{k,m} \quad e \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N,m}. \quad (3.6)$$

Em seu trabalho, [Huang, Zhu e Siew \(2006\)](#) mostram que a matriz a não precisa ser ajustada para que a rede neural convirja, podendo assumir valores aleatórios. Para obter a saída desejada, a Equação (3.5) se torna um sistema linear, onde os valores de β são encontrados como,

$$\beta = H^\dagger T, \quad (3.7)$$

onde, $H^\dagger$ é a pseudo-inversa da matriz H .

A matriz pseudo-inversa é uma generalização da inversa de uma matriz, apresentando propriedades semelhantes. Nesta caso, o uso da pseudo-inversa da matriz é necessário pois

a matriz H nem sempre será uma matriz quadrada. Dentre diferentes formas de se calcular a pseudo-inversa da matriz H , esta pode ser obtida da seguinte forma,

$$H^{\dagger} = (H^T H)^{-1} H^T. \quad (3.8)$$

Com o cálculo da Equação (3.7), encontra-se uma solução que fornece o menor erro quadrático, o que pode não ser encontrado por alguns algoritmos de treinamento. O processo de treinamento do ELM é apresentado no Algoritmo 2.

Algoritmo 2: Algoritmo de treinamento ELM.

Entrada: Dados de treinamento

Saída: W e θ

início

$X \leftarrow$ Amostras de entrada do treinamento

$T \leftarrow$ Saídas desejadas para cada amostra de treinamento

inicializa os pesos sinápticos e limiares de ativação, W e θ , com valores aleatórios

calcula a saída da camada intermediária $\Rightarrow H$

calcula os pesos da camada de saída $\Rightarrow \beta = H^{\dagger} T$

fim

retorna W e θ ajustados

Fonte: Elaborada pelo autor.

3.1.3 Comparação entre BP e ELM

No estudo realizado por Huang, Zhu e Siew (2006) onde o ELM foi divulgado, foram realizadas diferentes comparações de desempenho e velocidade entre RNAs treinadas com o uso do BP e com o ELM. Os algoritmos foram implementados e executados no mesmo computador com uso do *software* MATLAB®. Foram utilizados bancos de dados comuns na classificação de padrões, sendo estes gratuitos e de livre acesso. A Tabela 2 apresenta de forma resumida os resultados encontrados após 50 treinamentos das redes para cada um dos bancos de dados.

Tabela 2 – Comparação entre a classificação usando BP e ELM em uma RNA.

Banco de dados	Algoritmo	Tempo de treinamento [s]	Taxa de acerto [%]		Número de neurônios
			Treinamento	Teste	
Satellite image	ELM	14,92	93,52	89,04	500
	BP	12561	95,26	82,34	100
Image segment	ELM	1,4	97,35	95,01	200
	BP	4745,7	96,92	86,27	100
Shuttle	ELM	5,74	99,65	99,40	50
	BP	6132,2	99,77	99,27	50
Banana	ELM	2,19	92,36	91,57	100
	BP	6132,2	90,26	88,09	100

Fonte: Adaptada de Huang, Zhu e Siew (2006).

Como pode-se visualizar a partir dos dados da Tabela 2, o ELM apresentou uma taxa de acerto superior à do BP, e quanto a velocidade de treinamento, mesmo utilizando mais neurônios em alguns dos caso, o ELM treinou a rede neural em um tempo bem inferior ao do BP. Isso, mostra que o ELM realmente consegue vencer as limitações do algoritmo convencional de treinamento, com uma melhor resposta em um tempo de treinamento menor.

3.2 Considerações Finais

Neste capítulo foram apresentados os conceitos básicos das técnicas de aprendizagem de máquina, dando foco nas RNAs, que foram utilizadas neste trabalho para a classificação de padrões. Ainda foram abordados dois algoritmos diferentes para o treinamento das RNAs: o algoritmo convencional, *Backpropagation*, e um novo algoritmo, ELM. Dentre as vantagens do ELM pode-se destacar a redução no tempo de treinamento, que pode chegar em alguns casos a 1000 vezes em relação ao algoritmo BP, e a elevação na generalização da RNA e na taxa de acerto.

PROTEÇÃO ANTI-ILHAMENTO BASEADA EM APRENDIZAGEM DE MÁQUINA

A proteção local com técnica passiva inteligente tem como base a leitura de sinais do sistema para decidir sobre a ocorrência ou não de um ilhamento. Primeiramente, a tensão nos terminais do GD passam por um Transformador de Potencial (TP), reduzindo o nível de tensão. Após esta etapa, a tensão passa por um Filtro Passa Baixa (FPB), para evitar o efeito denominado sobreposição de espectros, e então é processado com o uso da TS. O espectro de frequência obtido é discretizado utilizando a energia de cada ordem harmônica. Então, as energias são utilizadas como entrada para as RNAs. Entretanto, a RNA irá classificar o evento apenas após a etapa de detecção de evento acusar a ocorrência de um fenômeno transitório no sistema elétrico por meio de um sinal de *trigger*. O diagrama ilustrado na Figura 6 apresenta o fluxograma geral da técnica de detecção de ilhamento proposta.

Figura 6 – Fluxograma da proteção anti-ilhamento proposta.

Fonte: Elaborada pelo autor.

Para o funcionamento da técnica passiva inteligente é necessário duas etapas principais: a *offline*, em que a proteção passa pelo processo de treinamento, e a *online*, que é quando a proteção entra devidamente em operação. Cada um destas etapas serão explicadas detalhadamente no

decorrer deste capítulo.

4.1 Etapa *offline* - treinamento

Nesta etapa da modelagem da proteção anti-ilhamento, a RNA passa pelo processo de treinamento. Entretanto, para a conclusão desta etapa, etapas menores tiveram de ser concluídas. Inicialmente o sinal de tensão nos terminais do GD passa por um processo de adequação para ser processado pela TS. Em seguida, o espectro de frequência do sinal é discretizado com o cálculo da energia de cada ordem harmônica, para, finalmente, algumas das entradas selecionadas serem utilizadas pela RNA para a classificação do evento como ilhamento ou não. Entretanto, a classificação apenas será realizada após a etapa de detecção de evento identificar a ocorrência de um transitório no sistema.

Ressalta-se que nesta etapa é necessária a simulação dos fenômenos a serem considerados para o treinamento da RNA. As simulações foram desenvolvidas no *software* ATP pela interface do *ATPDraw*. A modelagem do sistema em estudo e os parâmetros para cada um dos casos simulados serão apresentados no próximo capítulo.

4.1.1 Adequação do sinal

Para a leitura da tensão nos terminais do GD, a sua magnitude deve ser reduzida para valores compatíveis com o equipamento de leitura. Deste modo, modelou-se um TP como três transformadores monofásicos para cada uma das fases. O diagrama unifilar do equivalente monofásico do TP está ilustrado na Figura 7. Já os parâmetros elétricos do TP que foram utilizados no modelo elétrico abaixo estão apresentados na Tabela 3.

Figura 7 – Diagrama unifilar do transformador de potencial modelado no ATP.

Fonte: Elaborada pelo autor.

Tabela 3 – Parâmetros elétricos do transformador de potencial.

V_p	V_s	R_p	L_p	R_{mag}	R_s	L_s	R_{carga}
7200 V	120 V	417.3 Ω	0	2.88 M Ω	0.085 Ω	0.498 mH	100 Ω

Fonte: Adaptada de [Barbosa \(2010\)](#).

Adicionalmente, foi inserida a curva de saturação do TP para melhor representatividade de uma situação real de aplicação. Os pontos da curva de saturação estão ilustrados na Tabela 4.

Com a tensão já no nível de leitura do relé, o sinal passa por um filtro passa baixa de segunda ordem com uma frequência de corte igual à metade da taxa de amostragem. Isto é feito

Tabela 4 – Pontos da curva de saturação utilizada no transformador de potencial.

Corrente [A]	Fluxo [Wb]
5,65685425E-04	2,24178763E+00
7,91738900E-04	4,51058474E+00
1,08961059E-03	6,75237237E+00
1,36811690E-03	8,99416000E+00
1,60260804E-03	1,12629571E+01
1,92189590E-03	1,35047447E+01
2,25136411E-03	1,57465324E+01
2,72143978E-03	1,80153295E+01
3,27089474E-03	2,02571171E+01
4,36329487E-03	2,24989047E+01
5,95476411E-03	2,47677019E+01
8,77820543E-03	2,70094895E+01
1,52407918E-02	2,92512771E+01
3,66690375E-02	3,15200742E+01
1,79771541E-01	3,37618619E+01

Fonte: Adaptada de [Barbosa \(2010\)](#).

para garantir que o sinal não sofrerá o efeito da sobreposição de espectros durante a amostragem. Neste trabalho, como a taxa de amostragem utilizada foi de 64 amostras por ciclo, ou 3840 Hz, o filtro foi modelado com uma frequência de corte igual à 1920 Hz.

4.1.2 Transformada S

Para efetuar a extração de características da tensão nos terminais do gerador, optou-se pela extração de características do sinal utilizando o espectro de frequência, assim como mencionado no trabalho de [Raza et al. \(2015\)](#). Um dos métodos mais utilizados para este tipo de análise do sinal é a Transformada de Fourier de Tempo Curto (TFTC), apresentada na Equação (4.1),

$$X(f) = \int_{-\infty}^{\infty} x(t)g(t)e^{-j2\pi ft} dt, \quad (4.1)$$

onde,

$x(t)$ é o sinal variante no tempo;

$g(t)$ é a função da janela aplicada ao sinal; e

f é a frequência do sinal.

Entretanto, a TFTC não é eficaz para análise de frequências variantes no tempo. Por possuir uma janela de largura fixa, a TFTC considera o sinal como sendo estacionário dentro desta janela com o mesmo espectro durante todo o período e assim não identificando variações na janela analisada ([MOUKADEM; ABDESLAM; DIETERLEN, 2014](#)).

Outra técnica para a análise do espectro de frequência é a Transformada Wavelet, que apresenta uma janela com tamanho variável de acordo com a frequência do sinal, sendo assim capaz de representar melhor o espectro do sinal (DAUBECHIES, 1992).

Sendo considerada um método híbrido entre a TFTC e a TW, a TS foi primeiramente divulgada no trabalho de Stockwell, Mansinha e Lowe (1996). De modo similar a TFTC, a TS apresenta um janelamento no sinal, entretanto, utiliza uma janela com o formato de uma gaussiana, conforme apresentado na Equação (4.2),

$$g(t) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{t^2}{2\sigma^2}}. \quad (4.2)$$

onde,

σ é o desvio padrão da função gaussiana.

Vale ressaltar que, como ocorre com a TW, a janela da TS apresenta largura variável, pois o desvio padrão da janela gaussiana é inversamente proporcional à frequência do sinal, como expresso na Equação (4.3),

$$\sigma(f) = \frac{1}{|f|}. \quad (4.3)$$

Assim, com a inclusão do equacionamento da janela gaussiana, a equação final da TS fica da seguinte forma,

$$X(f) = \frac{|f|}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x(t) e^{-\frac{t^2 f^2}{2}} e^{-j2\pi f t} dt. \quad (4.4)$$

onde,

$X(f)$ é a representação do sinal $x(t)$ no domínio da frequência.

Dentre as vantagens para o uso da TS podemos citar a sua contante referência do espectro de frequência em relação à origem no tempo, a janela com largura variável e capacidade de mitigar a influência de ruídos (MOUKADEM; ABDESLAM; DIETERLEN, 2014).

Considerando a taxa amostral utilizada de 64 amostras por ciclo, de acordo com o teorema da amostragem, a máxima frequência que pode ser analisada é igual à metade desta taxa amostral (LATHI, 2007). Assim, a máxima frequência representada no espectro da TS é igual a 1920 Hz, equivalente à 32ª ordem harmônica.

Utilizando uma janela de um ciclo com deslocamento de meio ciclo, as Figuras 8 e 9 representam cinco janelas consecutivas do espectro de frequência para a tensão na fase A concatenadas, considerando dois eventos distintos. A Figura 8 corresponde a um caso de falta trifásica e a Figura 9 a um caso de ilhamento. Em ambos os casos os eventos tiveram início na metade da segunda janela, 96ª amostra. As cores em cada uma das figuras estão relacionadas ao valor da tensão para cada ordem harmônica em uma determinada amostra no tempo. Ressalta-

se que a frequência fundamental foi retirada para facilitar a visualização das demais ordens harmônicas, já que sua amplitude é muito maior que a das demais. Logo, apenas estão presentes nas figuras a faixa entre a 2ª e a 32ª ordem harmônica.

Figura 8 – Espectro de frequência da tensão na fase A com cinco janelas de um ciclo cada com deslocamento de meio ciclo para um caso de falta trifásica de $20\ \Omega$ no sistema ocorrendo no meio da segunda janela.

Fonte: Elaborada pelo autor.

Figura 9 – Espectro de frequência da tensão na fase A com cinco janelas de um ciclo cada com deslocamento de meio ciclo para um caso de ilhamento com $\Delta P = 0,409$ p.u. e $\Delta Q = -0,132$ p.u. de desbalanço de potência ocorrendo no meio da segunda janela.

Fonte: Elaborada pelo autor.

Como é possível perceber pelas figuras acima, na primeira janela analisada não há presença de componentes harmônicos, já que o sistema está em regime permanente. Já a partir da segunda janela, que é quando o evento tem início, é possível identificar algumas ordens harmônicas. No ilhamento houve uma maior amplitude para as harmônicas da 8ª à 20ª ordem,

enquanto para a falta houve o surgimento de componentes harmônicas ao longo de todo o espectro de frequência. Um ponto a se destacar é que no caso da falta trifásica a amplitude da tensão para as ordens harmônicas é mais elevada que para o ilhamento.

Com relação à amplitude da frequência fundamental (primeira ordem harmônica), considerando as mesmas cinco janelas apresentadas anteriormente, o seu valor obtido com a TS e está ilustrado na Figura 10.

Figura 10 – Valor da componente fundamental da tensão na fase A em cinco janelas consecutivas para os casos de (a) falta trifásica de 20 Ω e (b) ilhamento com $\Delta P = 0,409$ p.u. e $\Delta Q = -0,132$ p.u. de desbalanço de potência.

Fonte: Elaborada pelo autor.

É possível perceber que a magnitude para a frequência fundamental sofre uma grande atenuação durante a falta trifásica. No entanto, para o caso de ilhamento, ela permanece estável com o mesmo valor pré-evento.

4.1.3 Energia do sinal

Após o cálculo da TS, obtém-se o espectro de frequência do sinal com 32 níveis, referentes às ordens harmônicas, para cada uma das fases do sistema. Entretanto, cada ordem harmônica obtida com a TS não é apenas um valor, mas sim um vetor com 64 amostras no tempo. Assim, para que essas ordens harmônicas possam ser utilizadas pelo classificador, a informação presente em cada nível deve ser quantificada, processo este conhecido com discretização.

Comumente, para a discretização são utilizados métodos como o valor de máximo e energia do sinal. Neste trabalho, após realizar alguns testes com a energia e o valor de máximo, optou-se pelo uso da energia do sinal para a discretização já que este método apresentou melhor desempenho. Desta forma, para cada fase as energias para uma determinada ordem harmônica foram obtidas de forma independente, e no final somada com as energias da mesma ordem harmônica das demais fases, resultando assim em apenas um valor de energia correspondente à combinação linear das energias das fases. A Figura 11 apresenta esta simplificação de forma detalhada.

Figura 11 – Níveis de frequência do espectro obtido pela TS e suas simplificações.

Fonte: Elaborada pelo autor.

O vetor de energia resultante é então utilizado na etapa de detecção de evento e na classificação pela RNA. Neste trabalho foi utilizada a forma discreta para o cálculo da energia de sinais, em acordo com o teorema de Parseval (LATHI, 2007), a qual está apresentada na Equação (4.5) para o cálculo da energia de todas as n amostras do sinal x .

$$E = \sum_{n=-\infty}^{\infty} |x(n)|^2 \quad (4.5)$$

No entanto, o sinal em análise possui uma janela com 64 amostra. Deste modo a equação pode ser reescrita como,

$$E = \sum_{n=1}^{64} |x(n)|^2. \quad (4.6)$$

Após calcular a energia para cada ordem harmônica, percebeu-se uma grande diferença em magnitude entre a frequência fundamental e as demais ordens harmônicas. Logo, o valor da energia obtida a partir da Equação (4.6) foi convertido para decibéis (dB), para facilitar a visualização e reduzir a diferença da ordem de magnitude entre os valores. Assim, a energia em decibéis é calculada como,

$$E_{dB} = 20 \cdot \log \left(\sum_{n=1}^{64} |x(n)|^2 \right). \quad (4.7)$$

Com o uso do equacionamento acima, é possível a discretização das ordens harmônicas para cada janela em análise. Para exemplificar esta discretização, são mostradas nas Figuras 12 e 13 as energias de todas as ordens harmônicas para cada uma das cinco janelas apresentadas na subsecção anterior, já convertidas para decibéis.

Figura 12 – Valores de energia do espectro de frequência da tensão na fase A para o caso de falta trifásica de $20\ \Omega$ para a (a) 1ª janela, (b) 2ª janela, (c) 3ª janela, (d) 4ª janela e (e) 5ª janela apresentadas anteriormente.

(a)

(b)

(c)

(d)

(e)

Fonte: Elaborada pelo autor.

Figura 13 – Valores de energia do espectro de frequência da tensão na fase A para o caso de ilhamento com $\Delta P = 0,409$ p.u. e $\Delta Q = -0,132$ p.u. de desbalanço de potência para a (a) 1ª janela, (b) 2ª janela, (c) 3ª janela, (d) 4ª janela e (e) 5ª janela apresentadas anteriormente.

(a)

(b)

(c)

(d)

(e)

Fonte: Elaborada pelo autor.

Como é possível perceber, cada ordem harmônica agora não é mais representada por um vetor, mas sim por um único valor de energia. Nas Figuras 12(a) e 13(a), algumas ordens harmônicas possuem amplitudes negativas pois o seu valor é muito pequeno, e após a conversão da energia para decibéis estes valores passam a ser negativos. O mesmo ocorre nas Figuras 12(d) e 12(e) onde devido à amplitude das ordens harmônicas sofre um amortecimento, passando a ser muito pequena e assim a energia em decibéis também fica negativa.

4.1.4 Detecção de eventos

Para evitar a constante execução do algoritmo de classificação, foi modelada uma etapa de detecção de eventos com o objetivo de executar o classificador apenas quando necessário. Na detecção de evento do método foram utilizadas as energias de uma faixa específica do espectro de frequência obtido pela TS. Esta faixa corresponde às ordens harmônicas entre a 8^a e a 32^a. Em condições normais de operação, esta faixa do espectro de frequência se encontra vazia ou mesmo com valores muito pequenos, no entanto, na ocorrência de um fenômeno transitório é possível detectar ordens harmônicas nesta banda espectral com magnitudes consideráveis.

A energia do espectro na faixa de frequência mencionada é calculado em uma janela de um ciclo, que se move com um passo de meio ciclo. Todavia, para atenuar possíveis flutuações na energia, foi utilizado o filtro da Média Móvel (MM), considerando-se as últimas dez energias calculadas. Com a energia filtrada pela MM, efetua-se por fim o cálculo da Taxa de Variação da Média Móvel (TVMM), que é o parâmetro utilizado para detectar o evento. Caso a TVMM exceda o valor do limiar, a ocorrência de um evento transitório no sistema é detectada, logo autorizando a execução do classificador para identificar se ele corresponde ou não a um caso de ilhamento.

Devido as diferentes características dos eventos simulados (incluindo faltas, chaveamento de cargas e ilhamento), estabelecer um limiar fixo para esta etapa de detecção não foi possível. Assim, foi utilizado um limiar adaptativo, correspondendo à 10% do valor da energia espectral do sinal, já filtrada pela MM. Dois exemplos da detecção de evento no sistema simulado estão apresentados nas Figuras 14 e 15, as quais correspondem a um caso de falta trifásica e um caso de ilhamento, respectivamente. Em ambos os casos o evento tem início no sexto ciclo da janela, sendo apresentadas as formas de onda da tensão, a energia filtrada pela MM e a sua taxa de variação com o limiar adaptativo.

Comparado o valor da energia nas Figuras 14 e 15 é possível perceber a diferença em magnitude, pois no caso da falta trifásica a TVMM é cerca de 100 vezes maior que no caso de ilhamento. Assim, um limiar definido para um caso de falta poderia não ser suficiente para detectar a ocorrência de um ilhamento. Deste modo, o uso do limiar adaptativo se mostrou bastante eficaz por ser capaz de se ajustar para os diferentes fenômenos simulados. Além disso, para todos os testes realizados com o método de detecção de evento, o tempo de detecção ficou próximo a meio ciclo.

Figura 14 – Detecção de uma falta trifásica-terra na barra 4 com resistência de falta igual à 20Ω , com a (a) forma de onda da tensão no secundário do TP, (b) energia do espectro de frequência filtrada pela MM e (c) a sua taxa de variação com o limiar adaptativo.

Fonte: Elaborada pelo autor.

Figura 15 – Detecção de um ilhamento com $\Delta P = 0,409$ p.u. e $\Delta Q = -0,132$ p.u. de desbalanço de potência, com a (a) forma de onda da tensão no secundário do TP, (b) energia do espectro de frequência filtrada pela MM e (c) a sua taxa de variação com o limiar adaptativo.

Fonte: Elaborada pelo autor.

Esta etapa de detecção de evento também foi executada durante o treinamento da proteção proposta para a extração da energia de um ciclo de sinal após a ocorrência do evento. Isso é de fundamental importância, pois, este ciclo pós-evento utilizado durante o treinamento será equivalente ao que será analisado na etapa de operação.

4.1.5 Seleção de Atributos

Com o objetivo de reduzir o esforço computacional, tanto no treinamento quanto durante a fase de operação da proteção proposta, foi utilizada uma ferramenta de seleção de atributos para reduzir o número de entradas para o classificador. Tendo isso em vista, foi utilizada a *toolbox* desenvolvida e disponibilizada gratuitamente por [Brown et al. \(2016\)](#), com todos os algoritmos apresentados no seu trabalho. Esta *toolbox* pode ser encontrada e baixada gratuitamente em ([BROWN et al., 2019](#)).

Utilizando os cinco algoritmos lineares para a seleção de atributos presentes na *toolbox*, foi realizada uma análise inicial para determinar qual algoritmo apresentaria o melhor resultado na classificação. Desta forma, foi analisada a seleção de diferentes quantidades de entradas para cada algoritmo, sendo realizado o treinamento de uma RNA para cada valor analisado. Durante este treinamento da RNA, foi realizada a identificação do número de neurônios necessário e a taxa de acerto final, armazenando os seus valores para a etapa de avaliação.

Para avaliar e comparar os algoritmos de seleção de atributos, foram criados dois índices de avaliação, um para a quantidade de neurônios ($\eta_{neurônios}$) e outro para a taxa de acerto (η_{acerto}), apresentados nas Equações (4.8) e (4.9). Considerando os vetores N e A correspondem à quantidade média de neurônios e a taxa de acerto média para cada algoritmo, respectivamente, para o i -ésimo algoritmo de seleção de atributos tem-se:

$$\eta_{neurônios}(i) = \frac{\min(N)}{N(i)}, \quad (4.8)$$

$$\eta_{acerto}(i) = \frac{A(i)}{\max(A)}, \quad (4.9)$$

onde,

$\min(N)$ é o menor número de neurônios no vetor N ; e

$\max(A)$ é a maior taxa de acerto no vetor A .

Para se obter apenas um índice de avaliação, η_{final} , foi feita a soma ponderada dos índices apresentados acima pelos fatores a_1 e a_2 , permitindo que durante esta etapa haja a priorização da redução de neurônios ou elevação da taxa de acerto, respectivamente. O índice final de avaliação é dado na Equação (4.10),

$$\eta_{final}(i) = a_1 \cdot \eta_{neurônios}(i) + a_2 \cdot \eta_{acerto}(i). \quad (4.10)$$

Neste trabalho, foram utilizados $a_1 = 0,6$ e $a_2 = 0,4$, visando preferencialmente a redução na quantidade de neurônios. Com isso, foi possível montar a Tabela 5 com os índices para cada um dos algoritmos testados.

Tabela 5 – Índices de avaliação para cada algoritmo de seleção de atributos.

Algoritmos	$\eta_{neurônios}$	η_{acerto}	η_{final}
MIM	0,831	0,998	0,898
MIFS	0,970	0,999	0,982
JMI	0,865	1,000	0,919
CIFE	0,771	0,999	0,862
mRMR	1,000	0,999	1,000

Fonte: Elaborada pelo autor.

Com base na Tabela 5, o melhor resultado na classificação do ilhamento foi obtido pelo método *Minimal-Redundancy-Maximal-Relevance* (mRMR), já que este obteve o maior valor para o índice η_{final} . Este método foi proposto por [Peng, Long e Ding \(2005\)](#) com o objetivo de selecionar atributos com alta relevância para a classificação e, ao mesmo tempo, com baixa redundância entre os atributos selecionados. Assim, utilizando o algoritmo mRMR se repetiu a análise realizada anteriormente, e de forma análoga, foi feita a identificação da melhor quantidade de atributos. Este passo é necessário, pois uma das entradas do algoritmo é a quantidade de atributos que serão selecionados. Portanto, com a quantidade de atributos variando entre 3 e 16, foi montada a Tabela 6.

Tabela 6 – Índices de avaliação para cada quantidade de atributos selecionados pelo algoritmo mRMR.

Índices	Número de atributos													
	3	4	5	6	7	8	9	10	11	12	13	14	15	16
$\eta_{neurônios}$	0,60	0,50	0,60	0,75	1,00	0,50	0,50	0,75	0,60	0,75	0,75	0,75	0,75	0,75
η_{acerto}	0,99	0,99	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
η_{final}	0,75	0,70	0,76	0,85	1,00	0,70	0,70	0,85	0,76	0,85	0,85	0,85	0,85	0,85

Fonte: Elaborada pelo autor.

Logo, com base nos valores obtidos nesta etapa, a melhor quantidade de atributos a ser utilizada é igual a 7, permitindo, ao mesmo tempo, a melhor taxa de acerto como a menor quantidade de neurônios, por ter obtido todos os índices de avaliação iguais a 1. Com isso, foi possível reduzir o número de entradas para o classificador de 32 para apenas 7. As entradas selecionadas pelo mRMR foram as energias da 1^a, 2^a, 3^a, 12^a, 14^a, 15^a e 19^a ordem harmônica.

4.1.6 Treinamento da RNA

Após a detecção de um evento no sistema, o próximo passo é a classificação dos eventos. Esta etapa é realizada por uma RNA com arquitetura *feedforward*, apenas uma camada escondida

e função de ativação sigmoideal. A camada de saída possui apenas um neurônio com função de ativação linear. Com relação à quantidade de neurônios na camada escondida da RNA, foi efetuado um estudo para verificar o número de neurônios que possibilitaria a melhor resposta para cada algoritmo de treinamento. Neste estudo a quantidade de neurônios foi variada de 10 à 60, sendo efetuados 1000 treinamentos consecutivos para cada topologia a fim de encontrar uma resposta média da topologia. Isso é necessário para minimizar a característica estocástica do treinamento da RNA. Por fim, a topologia que apresentou melhor resposta foi escolhida como a topologia final para a rede.

Outra análise efetuada com a RNA foi a comparação dos dois algoritmos de treinamentos apresentados anteriormente, o BP e ELM. Por esta razão, a RNA foi modelada com apenas uma camada escondida, da mesma forma que foi proposta para o uso do ELM. O treinamento com o algoritmo BP foi efetuado utilizando o *toolbox* de redes neurais do *software* MATLAB®, enquanto o treinamento com o ELM foi realizado com uma função implementada no mesmo ambiente. Os resultados encontrados com cada um deles serão apresentados na Seção 5.4.

4.2 Etapa *online* - operação

Nesta etapa, a RNA já passou pelo processo de treinamento e está pronta para operar. O fluxograma da etapa *online* da proteção anti-ilhamento proposta é mostrado na Figura 16.

Primeiramente, é realizada a leitura de um ciclo da tensão nos terminais do GD, após esta ter passado pelo TP e filtro *anti-aliasing*. A janela contendo um ciclo da tensão é então processada pela TS, retornando o espectro de frequência da janela. Passando pelo processo de discretização, as energias do espectro de frequência são encaminhadas para a etapa de detecção de eventos. Caso seja detectada a ocorrência de algum evento transitório no sistema, um sinal de *trigger* é enviado para que o processo de classificação tenha início. Entretanto, se não for detectado um evento no sistema, a janela de amostragem é deslocada em meio ciclo, e o processo de leitura da tensão reinicia.

Após receber o sinal de *trigger* da etapa de detecção de evento, o primeiro passo para a classificação é a amostragem de um novo ciclo completo da tensão nos terminais do GD. Após ser processada pela TS e discretizada pelo cálculo da energia, as energias das ordens harmônicas selecionadas na seleção de atributos são encaminhadas para a RNA. Ao receber as sete entradas com os valores das energias da 1ª, 2ª, 3ª, 12ª, 14ª, 15ª e 19ª ordem harmônica, a RNA efetua a classificação do evento. Caso o evento seja identificado como ilhamento, um sinal de *trip* é enviado para o disjuntor de conexão do GD para efetuar a sua desconexão com a rede. Porém, caso o evento não seja um ilhamento, o algoritmo retorna ao ponto de leitura da tensão deslocando a janela em meio ciclo.

Vale ressaltar que, ao receber o sinal de *trigger* da etapa de detecção de eventos, a RNA utiliza as energias do espectro de frequência do próximo ciclo a partir do ponto em que o evento

Figura 16 – Fluxograma da etapa *online* da proteção anti-ilhamento proposta.

Fonte: Elaborada pelo autor.

foi detectado. Logo, além do tempo de detecção de evento, há o tempo para o preenchimento da janela com um ciclo do sinal de tensão, o seu processamento pela TS, o cálculo da energia de cada ordem harmônica e a classificação propriamente dita. Mais adiante, estes tempos estarão inseridos na medida do tempo para a detecção de ilhamento do método.

4.3 Considerações Finais

Este capítulo teve por objetivo apresentar a metodologia desenvolvida para a detecção do ilhamento, utilizando o espectro de frequência obtido com a TS e a classificação efetuada pela RNA. Ainda, foram detalhados os processos de seleção de atributos e detecção de evento. No caso do processo de detecção de evento, este é utilizado para identificar a ocorrência de fenômenos transitórios no sistema, dando início à classificação pela RNA. Já a etapa de seleção de atributos foi utilizada para minimizar o esforço computacional na operação, e consequentemente reduzir o tempo de execução.

No capítulo seguinte serão apresentados os resultados obtidos com o uso do classificador mencionado em comparação com três métodos convencionais de detecção do ilhamento. Foi ainda analisada a resposta do método proposto em algumas situações ausentes no conjunto de

treinamento para verificar a generalização da técnica, durante a construção das ZNDs.

RESULTADOS E DISCUSSÕES DA METODOLOGIA PROPOSTA

Este capítulo apresenta os resultados obtidos com a metodologia previamente apresentada com a sua aplicação em um sistema teste. O sistema em estudo, os parâmetros das simulações, os índices de avaliação utilizados e os resultados obtidos serão apresentados nas seções a seguir.

Dentre os resultados, ressalta-se a análise das ZNDs (apresentada na seção 5.6), que são importantes para compreender o funcionamento da proteção, mas que comumente não são apresentadas na bibliografia para técnicas passivas inteligentes.

5.1 Sistema em estudo

Um ponto de extrema importância no desenvolvimento de um técnica passiva inteligente para a detecção de ilhamento é a modelagem do sistema elétrico. Para este trabalho, optou-se por utilizar o *software* ATP com o auxílio da interface *ATPDraw* devido ao seu extensivo uso para simulação de transitórios eletromagnéticos e velocidade para efetuar os cálculos.

O sistema elétrico em estudo é um sistema de distribuição para testes do Conselho Internacional de Grandes Sistemas Elétricos, em francês *Conseil International des Grands Réseaux Électriques* (CIGRÉ). Este sistema é baseado em um sistema de distribuição europeu real, com tensão nominal de 20 kV e frequência nominal de 50 Hz. Todos os seus valores originais foram retirados da brochura oficial do CIGRÉ ([CIGRÉ Task Force C6.04, 2014](#)). Entretanto, para este trabalho, a frequência do sistema foi alterada para 60 Hz, porém, o valor das impedâncias não foi alterado. Esta alteração na frequência foi feita para deixar o sistema teste mais próximo de um sistema brasileiro em que a frequência nominal é 60 Hz.

Todavia, antes de efetuar a alteração da frequência, o sistema foi modelado com os seus valores nominais a fim de validar a modelagem. Nesta etapa, obteve-se um erro menor que 0,1 %

abertura do disjuntor D1 conectado entre as barras 2 e 3.

5.1.1 Transformadores

Os transformadores presentes no sistemas foram modelados no *software* ATP com o modelo de transformador saturável trifásico presente. Na Figura 18 está ilustrada uma representação monofásica do modelo do transformador utilizado pelo *software*.

Figura 18 – Representação monofásica do modelo do transformador saturável no *software* ATP.

Fonte: Adaptada de CAUE (2002).

Esta representação do transformador permite a inclusão das perdas nos enrolamentos e no núcleo. Além disso, é possível incluir uma curva de saturação do transformador para permitir uma representação ainda mais real do transformador. Entretanto, para este trabalho foram modeladas apenas as perdas elétricas nos enrolamentos do transformador, pois a curva de saturação não é disponibilizada no dados gerais do sistema do CIGRÉ (CIGRÉ Task Force C6.04, 2014).

Os dois transformadores de cada um dos alimentadores possuem os mesmos valores de tensão e potência nominal, mas possuem valores diferentes de *tap* no secundário. Os dados de tensão, *tap*, resistência e indutância referidas ao secundário e potência nominal de cada um dos transformadores estão apresentados na Tabela 7.

Tabela 7 – Parâmetros dos transformadores dos alimentadores.

Barramentos		V_1	V_2	$V_{2,tap}$	R_t	X_t	S_n
Primário	Secundário	[kV]	[kV]	[%]	[Ω]	[mH]	[MVA]
0	1	110	20	6,250	0,016	6,111	25
0	12	110	20	3,125	0,016	6,111	25

Fonte: Adaptada de CIGRÉ Task Force C6.04 (2014).

Já o transformador de interconexão do GD foi modelado com base em dados de fabricante, com potência nominal de 5 MVA, impedância percentual de 7% e tensões de primário e secundário de 6,6 kV e 20 kV, respectivamente.

5.1.2 Gerador Síncrono

O gerador síncrono presente no sistema possui potência e tensão nominal de 5 MVA e 6,6 kV, respectivamente. Este gerador está acoplado a uma turbina a vapor que fornece potência

mecânica ao eixo. Os dados elétricos e mecânicos do gerador síncrono foram retirados de (MOURA, 2011) e estão disponíveis no Anexo A.

O modelo de máquina síncrona utilizada pelo ATP inclui a representação da massa no eixo do gerador, permitindo a análise de transitórios mecânicos da máquina. Eletricamente, o gerador síncrono é trifásico, balanceado e os enrolamentos do estator estão conectados em estrela, com a possibilidade de conectar uma impedância entre o neutro e o aterramento. Este modelo possui como variáveis de saída a velocidade e ângulo do rotor, torque mecânico, correntes nos enrolamentos de armadura dentre outras, que podem ser utilizadas para monitorar a operação do gerador e efetuar o seu controle (CAUE, 2002).

Com relação ao controle do gerador, ele foi simulado operando no modo de injeção constante de potência ativa e reativa. Esta injeção de potências é controlada com o uso do controle de excitação e velocidade, os quais serão detalhados na sequência.

5.1.2.1 Regulador de tensão

Para o projeto do regulador de tensão foi utilizado o modelo DC1A do IEEE para o controle de excitação da máquina síncrona (IEEE... , 2006). Neste modelo a tensão nos terminais do gerador é amostrada para todas as fases e seu valor eficaz médio é utilizado como entrada do controle. Porém, antes de entrar na malha de controle a tensão passa por um filtro anti-aliasing (Butterworth de 2ª ordem com frequência de corte em 1 kHz).

Além de controlar a tensão de saída da máquina síncrona, o regulador de excitação pode ser usado para controlar a potência reativa injetada na rede. Esta alteração no controle é feita a partir de um sinal de entrada presente na malha de controle, onde o valor “0” define o controle de tensão e “1” a injeção de potência reativa. No caso do controle de injeção, é calculado o erro entre a potência reativa gerada e o valor de referência para ela. Esse erro passa por um controlador PID e sua saída é utilizada pelo controle de excitação.

A malha de controle do regulador de excitação está apresentada na Figura 19. Os valores dos parâmetros do regulador de excitação utilizados durante este trabalho estão apresentados na Tabela 8.

Figura 19 – Malha do regulador de excitação para o controle de tensão e potência reativa do gerador síncrono.

Fonte: Elaborada pelo autor.

onde,

Q_{ref} é a potência reativa de referência;

Q_{med} é a potência reativa medida;

V_{ref} é a tensão de referência;

V_{med} é a tensão de terminal após a filtragem;

T_c constante de tempo de derivação para redução de transitório;

T_b constante de tempo de integração para redução de transitório;

K_a ganho do regulador;

T_a constante de tempo do regulador;

K_e ganho da excitatriz;

T_e constante de tempo da excitatriz;

K_f ganho de amortecimento;

T_f constante de tempo de amortecimento;

$V_{r_{min}}$ limite inferior da saída do regulador;

$V_{r_{max}}$ limite superior da saída do regulador;

V_{min} limite inferior da tensão de saída da excitatriz;

V_{max} limite superior da tensão de saída da excitatriz; e

V_F é a tensão aplicada ao enrolamento de campo.

Tabela 8 – Valores dos parâmetros do regulador de excitação.

Parâmetro	Valor
T_c	0
T_b	0
K_a	120
T_a	0,02 s
K_e	1
T_e	0,8 s
K_f	1
T_f	0,01 s
$V_{r_{min}}$	-1 p.u.
$V_{r_{max}}$	5 p.u.
V_{min}	0,001 p.u.
V_{max}	1,05 p.u.

Fonte: Elaborada pelo autor.

5.1.2.2 Regulador de velocidade

O regulador de velocidade do gerador foi modelado com base no modelo genérico do IEEE ([REPORT](#), 2013). Este modelo pode ser utilizado para controlar a frequência do gerador

e a potência ativa gerada. De modo similar ao regulador de tensão, o tipo do controle pode ser definido através de um sinal de entrada, onde o valor “0” representa o controle de frequência e “1” a injeção de potência ativa na rede de distribuição.

Na malha do regulador de velocidade há um controlador PID, que teve os valores de seus ganhos otimizados com o uso da ferramenta de otimização presente na interface do *ATPDraw*. A malha de controle deste regulador está apresentada na Figura 20. Já os valores dos parâmetros do regulador de velocidade e os ganhos do controlador PID (K_p , K_i e K_d) estão apresentados na Tabela 9.

Figura 20 – Malha do regulador de velocidade para o controle de frequência e potência ativa do gerador síncrono.

Fonte: Elaborada pelo autor.

onde,

P_{ref} é a potência ativa de referência;

P_{med} é a potência ativa medida;

ω_{ref} é a velocidade angular de referência;

ω_{med} é a velocidade angular medida;

R é o ganho referente a queda de velocidade da máquina;

K_i é o ganho de malha direta; e

P_{mec} é a potência mecânica aplicada no eixo da máquina geradora.

Tabela 9 – Valores dos parâmetros do regulador de velocidade.

Parâmetro	Valor
R	0,05
K_i	1
K_p	120
K_i	80
K_d	0
P_{min}	0 p.u.
P_{max}	1,6 p.u.

Fonte: Elaborada pelo autor.

5.2 Simulações Computacionais do Sistema Teste

As simulações foram conduzidas no *software* ATP pela interface do ATPDraw, incluindo casos de falta, entrada/saída de cargas e ilhamento. Entretanto, o processamento dos sinais e classificação foram implementados no *software* MATLAB® 2018b. No total foram simulados 1600 casos para o treinamento e 5776 casos para o teste, correspondendo à cerca de 22% dos casos para treinamento e 78% para teste. Todavia, outras divisões no banco de dados foram analisadas com 79%/21%, 51%/49% e 10%/90% para o treinamento e teste, respectivamente, sendo a proporção utilizada de 22%/78% por ter apresentado o melhor comprometimento entre a menor tendência de *overfitting* e o maior desempenho final. Todos os parâmetros para cada caso simulado estão detalhados na Tabela 10.

Tabela 10 – Configurações de cada cenário simulado para treinamento e teste da proteção.

Treinamento	Faltas	Barras: 1 à 11. Tipos: AT, BC, CAT e ABCT. Resistência: 0 e 50 Ω . Total: 88 casos.
	Chaveamento de cargas e ilhamento	Cargas: barra 3, 5, 6, 7 e 11. Perfil de carga: 0,2; 0,6; 1,0 e 1,2 p.u.. Potência de saída do GD: 0,5 e 1,0 p.u.. Total: 504 casos (para cada um dos três cenário).
Teste	Faltas	Barras: 1 à 11. Tipos: todos os 11 tipos. Resistência: 10, 20, 30 e 40 Ω . Total: 484 casos.
	Chaveamento de cargas e ilhamento	Cargas: barra 3, 5, 6, 7 e 11. Perfil de carga: 0,3; 0,4; 0,5; 0,7; 0,8; 0,9 e 1,1 p.u.. Potência de saída do GD: 0,6; 0,7; 0,8 e 0,9 p.u.. Total: 1764 casos (para cada um dos três cenário).

Fonte: Elaborada pelo autor.

Vale ressaltar que os fenômenos simulados consideraram ocorrências apenas no Alimentador 1, pois, devido ao elevado nível de curto-circuito da subestação, eventos no Alimentador 2 são praticamente imperceptíveis no Alimentador 1. Outro ponto a se destacar é a utilização de apenas 4 tipos de falta (monofásica, bifásica, bifásica-terra e trifásica-terra) para o treinamento da proteção anti-ilhamento. Nota-se que, devido ao sistema utilizado ser equilibrado, não foi necessária a inclusão de falta trifásica no banco de treinamento por esta apresentar o mesmo comportamento que a falta trifásica-terra. Entretanto, para o teste da proteção foram utilizados todos os 11 tipos de falta para validar a generalização da proteção com o banco de treinamento utilizado.

5.3 Métricas de avaliação de desempenho

Para avaliar o desempenho dos diferentes métodos de detecção de ilhamento e comparar os resultados obtidos, foram utilizadas métricas baseadas na matriz de confusão, exemplificada na Figura 21.

Figura 21 – Exemplo de matriz de confusão.

Classe real			
		1	0
	VP	FP	Classe de saída
	FN	VN	
P			N

Fonte: Elaborada pelo autor.

onde,

VP é o número de casos de verdadeiro positivo;

FN é o número de casos de falso negativo;

FP é o número de casos de falso positivo;

VN é o número de casos de verdadeiro negativos;

P é o número total de casos positivos; e

N é o número total de casos negativos.

Nesse estudo foram utilizadas a Taxa de acerto, Taxa de Falso Positivo (TFP) e Taxa de Falso Negativo (TFN) para mensurar o desempenho dos métodos de detecção de ilhamento. As equações desses índices estão apresentadas em (5.1), (5.2) e (5.3):

$$Taxa\ de\ acerto = \frac{VP + VN}{P + N} = \frac{VP + VN}{VP + FN + FP + VN} , \quad (5.1)$$

$$TFP = \frac{FP}{N} = \frac{FP}{FP + VN} , \quad (5.2)$$

$$TFN = \frac{FN}{P} = \frac{FN}{VP + FN} . \quad (5.3)$$

5.4 Resultados do método proposto

O método de detecção de ilhamento proposto foi avaliado com as 7 entradas selecionadas pelo algoritmo de seleção de atributo, as energias da 1ª, 2ª, 3ª, 12ª, 14ª, 15ª e 19ª ordem harmônica. Adicionalmente, a RNA foi treinada com os algoritmos BP e ELM, e após a etapa de validação cruzada foi encontrado que os melhores resultados para os algoritmos foram obtidos com 20 e 30 neurônios na camada escondida para o BP e ELM, respectivamente.

Para minimizar a estocasticidade no resultado obtido por cada um dos algoritmos, foram executados 500 treinamentos consecutivos. A Tabela 11 apresenta a taxa de acerto média e o desvio padrão (DP) para o treinamento e teste das RNAs treinadas por cada um dos algoritmos após os 500 treinamentos consecutivos.

Tabela 11 – Desempenho médio do método proposto após 500 treinamentos.

Algoritmo	Treinamento		Teste		Número de neurônios
	Taxa de acerto	DP	Taxa de acerto	DP	
BP	99,999%	0,007%	99,945%	0,139%	20
ELM	99,998%	0,017%	99,981%	0,042%	30

Fonte: Elaborada pelo autor.

Como pode ser visto na Tabela 11, os dois algoritmos apresentaram taxa de acerto similar. Todavia, o desvio padrão do ELM foi consideravelmente menor para o teste, assim comprovando que o ELM converge para pontos próximos em diferentes treinamentos. Isto é esperado já que o ELM tende a evitar mínimos locais durante o treinamento. Outro ponto interessante é a maior queda na taxa de acerto entre o treinamento e teste obtida pelo BP, quando comparada com o ELM. Isto pode ser causado por *overfitting*, que também é minimizado com o ELM, novamente explicando esta menor queda em desempenho. Em relação ao tempo de treinamento, o algoritmo BP necessitou em média 10,3 segundos enquanto o ELM executou em apenas 0,018 segundos, sendo cerca de 570 vezes mais rápido que o BP por treinamento. De modo geral, o ELM apresentou uma taxa de acerto média levemente melhor quando comparado com os resultados obtidos pelo BP. No entanto, por a diferença na taxa de acerto ser extremamente pequena (igual a 0,036% para os testes) fica difícil afirmar, com base apenas neste resultados, qual o melhor algoritmo para o treinamento da RNA visando à classificação do ilhamento. Com esse objetivo, foi realizada a análise do pior resultados obtido pela RNA treinada por cada um dos algoritmos, cujos valores são apresentados na Tabela 12.

Tabela 12 – Piores resultados das RNAs treinadas por cada algoritmo.

Algoritmo	Taxa de acerto no treinamento	Taxa de acerto no teste	Matriz de confusão do teste		
			1	0	
BP	100,0%	99,24%	1764	44	1
			0	3968	0
ELM	99,75%	99,72%	1764	16	1
			0	3996	0

Nota-se que, com base nos resultados apresentados acima, mesmo no pior treinamento o ELM conseguiu um melhor resultado com o treinamento da RNA que o BP, apresentando um número menor de casos de falso-positivo, sendo este um ponto muito importante para o método

proposto. Assim sendo, o GD protegido pela proteção anti-ilhamento proposta treinada pelo ELM permaneceria conectado ao sistema por mais tempo, já que com a identificação de um falso-positivo o GD seria desconectado do sistema de forma errônea.

5.5 Comparação com métodos convencionais

Para comparar os resultados obtidos com o método proposto, foram modeladas três funções de proteção comumente empregadas para a detecção de ilhamento, sendo elas a de sub/sobre frequência (81U/O), taxa de variação da frequência (81R) e sub/sobre tensão (27/59). A modelagem de cada uma das funções de proteção, bem como os blocos para estimação da tensão e frequência estão descritos de forma detalhada no Apêndice A.

Estas funções de proteção necessitam de ajuste do limiar para a correta atuação. Deste modo, o ajuste dos limiares de cada uma das proteções foi realizado com base no banco treinamento, onde vários valores para o limiar, temporização e tensão de bloqueio foram testados. Os melhores resultados obtidos foram então considerados o ajuste final de cada função de proteção, sendo utilizado para as demais análises apresentadas no decorrer deste capítulo. A Tabela 13 apresenta os valores de ajustes para os quais as funções de proteção tiveram o melhor desempenho.

Tabela 13 – Ajuste das funções de proteção convencionais modeladas.

Função de proteção	Temporização	Limiar	$V_{bloqueio}$
81U/O	6 ciclos	$\pm 0,12$ Hz	0,85 p.u.
81R	2 ciclos	$\pm 1,65$ Hz/s	0,90 p.u.
27/59	6 ciclos	$\pm 0,07$ pu	-

Fonte: Elaborada pelo autor.

Após esta etapa de ajuste das proteções convencionais, partiu-se para a validação junto ao banco de testes. Tanto os métodos convencionais quanto os métodos propostos foram testados e tiveram o seu desempenho medido com base nas métricas apresentadas anteriormente. Além disso, o tempo médio de atuação e seu desvio padrão para todos os 5776 casos do conjunto de teste foi medido. Vale ressaltar que todas as proteções foram implementadas no *software* MATLAB® 2018b em um computador com processador AMD Ryzen 7 de 3,2 GHz. O desempenho de cada um dos métodos modelados pode ser observado na Tabela 14.

Como pode ser visto na Tabela 14, os métodos baseados em aprendizagem de máquina apresentaram uma taxa de acerto muito superior aos métodos convencionais e com um tempo médio de atuação bastante inferior. Nota-se ainda que os casos de falso negativo e falso positivo também foram mitigados com o método proposto. Entretanto, pelo fato dos dois algoritmos de treinamento da RNA terem apresentado a mesma taxa de acerto e tempo de atuação praticamente idênticos, ainda não é possível afirmar qual deles apresenta a melhor resposta para a detecção do ilhamento.

Tabela 14 – Resultados obtidos pelas proteções convencionais e o método proposto.

Função de proteção	Taxa de acerto	TFN	TFP	Tempo de atuação	
				Média	Desvio padrão
81U/O	96,80%	0,00%	4,61%	134,3 ms	77,77 ms
81R	90,15%	4,82%	12,06%	54,16 ms	7,14 ms
27/59	93,91%	0,00%	8,77%	796,1 ms	121,7 ms
BP	100,0%	0,00%	0,00%	26,02 ms	0,06 ms
ELM	100,0%	0,00%	0,00%	26,03 ms	0,06 ms

Fonte: Elaborada pelo autor.

5.6 Zona de não detecção

Um problema enfrentado pela detecção passiva do ilhamento é a zona de não detecção. Por se basear em medidas locais, para casos com pequenos desbalanços entre a potência ativa (ΔP) e/ou reativa (ΔQ) do sistema, a proteção anti-ilhamento pode não ser sensibilizada, consequentemente não atuando como esperado. Assim, o conhecimento do tamanho desta zona de não detecção do ilhamento é um parâmetro interessante para avaliar o desempenho deste tipo de proteção.

Desta forma, foram efetuadas novas simulações (5544 casos de ilhamento) com diferentes valores de geração e carga no sistema de modo a criar uma área maior de desbalanço de potências e consequentemente verificar a capacidade de generalização dos classificadores baseados em técnicas de aprendizagem de máquina. Os casos de ilhamento para a análise das ZNDs foram simulados com base nos valores da Tabela 15.

Tabela 15 – Configurações de cada cenário simulado para a análise das zonas de não detecção.

Geração	P: 0,1 à 0,9 p.u.; e Q: 0,1 à 0,5 p.u..	, tal que $S \leq 1$ p.u.
Cargas	Barras: 3, 5, 6, 7 e 11; e Carregamento: 0,5 e 1 p.u..	

Fonte: Elaborada pelo autor.

A título de comparação, a Figura 22 apresenta a região de desbalanço de potência ativa e reativa utilizada no treinamento dos classificadores (região escura) e a nova região que será utilizada para determinar o tamanho das zonas de não detecção (região clara). É possível perceber que a nova região é maior e apresenta valores de desbalanço que não estavam presentes no conjunto de treinamento.

Com os novos casos de ilhamento simulados, as funções de proteção convencionais foram utilizadas com o mesmos ajustes determinados anteriormente, com uma janela de 500 ms para a atuação, sendo esta utilizada para todas as proteções. As ZNDs de cada uma das proteções estão apresentadas nas Figuras de 23 à 27.

Figura 22 – Região de desbalanço de potência utilizada para o treinamento (região escura) em comparação com a região utilizada na análise das ZNDs (região clara).

Fonte: Elaborada pelo autor.

Figura 23 – Zona de não detecção da função de proteção 81U/O.

Fonte: Elaborada pelo autor.

Figura 24 – Zona de não detecção da função de proteção 81R.

Fonte: Elaborada pelo autor.

Figura 25 – Zona de não detecção da função de proteção 27/59.

Fonte: Elaborada pelo autor.

Figura 26 – Zona de não detecção da proteção proposta treinada com o BP.

Fonte: Elaborada pelo autor.

Figura 27 – Zona de não detecção da proteção proposta treinada com o ELM.

Fonte: Elaborada pelo autor.

Visualmente é possível perceber que os métodos baseados em aprendizagem de máquina foram capazes de reduzir o tamanho das ZNDs. Todavia, o desempenho de cada uma das técnicas de detecção de ilhamento é apresentado de forma quantitativa na Tabela 16, com a taxa de acerto, o total de verdadeiros positivos e falsos negativos e a área relativa da ZND em relação à área total da região simulada do plano $\Delta P \times \Delta Q$.

Tabela 16 – Desempenho de cada proteção para a análise da zona de não detecção.

Proteções	Taxa de acerto	VP	FN	Área relativa
81U/O	93.11%	5162	382	7,12%
81R	87.39%	4845	699	10,94%
27/59	51.66%	2864	2680	56,42%
BP	97.42%	5401	143	4,53%
ELM	99.53%	5518	26	1,39%

Fonte: Elaborada pelo autor.

De modo geral, a proteção proposta apresentou uma ZND menor que a das proteções convencionais, mas ainda assim apresentando problema para a classificação de alguns eventos em que o desbalanço de potência ativa e reativa são pequenos. Ressalta-se que, embora as RNAs tenham sido treinadas com uma região de desbalanço de potência bem menor que a utilizada nesta análise, ainda assim foram capazes de apresentar resultados superiores às proteções convencionais.

Com a análise da ZND fica claro que a RNA treinada pelo ELM teve um melhor desempenho que a treinada pelo BP. Isso mostra que a capacidade de generalização do ELM é superior à do BP, pois a ZND do ELM foi cerca de três vezes menor que a do BP. Sendo assim, para a classificação de ilhamento, o ELM é o algoritmo mais indicado para o treinamento de uma RNA por produzir melhores resultados e uma rede neural com maior capacidade de generalização, a qual conseguiu atuar com ótimo desempenho mesmo fora da região utilizada no conjunto de treinamento.

5.7 Considerações Finais

Este capítulo teve por objetivo apresentar os resultados obtidos com a aplicação da metodologia proposta e a comparação com métodos convencionais para a detecção de ilhamento. A proteção anti-ilhamento proposta apresentou resultados satisfatórios, sendo superiores aos das proteções convencionais para todos os casos analisados. Destaca-se o desempenho obtido com a proteção baseada em RNAs que foi treinada com o algoritmo ELM, que alcançou as maiores taxas de acerto, conseguindo também reduzir os casos de falso *trip*, como é esperado da técnica passiva inteligente.

A análise das ZNDs se mostrou um excelente método para avaliar o desempenho das proteções, já que a sua redução é algo desejado para a proteção anti-ilhamento. Com a comparação das ZNDs das proteções passivas inteligentes modeladas com a das proteções convencionais, pode-se perceber que houve uma redução no número de ilhamentos não detectados, como apresentado na Tabela 16. Todavia, apesar de ser uma característica muito importante para a detecção do ilhamento, a análise das ZNDs não é comumente encontrada em trabalhos com técnicas passivas inteligentes, sendo este um dos diferenciais apresentados neste trabalho.

CONCLUSÕES

Este trabalho tem como tema a proteção dos sistemas elétricos de potência, mais especificamente, a proteção anti-ilhamento de geradores síncronos distribuídos com o uso de técnicas passivas inteligentes. O método proposto utiliza técnicas de aprendizagem de máquina para distinguir condições de ilhamento das demais condições normais de operação do sistema elétrico estudado, tendo como entrada medidas locais de tensão.

Com base nos resultados obtidos, pode-se concluir que o método proposto conseguiu um resultado bastante promissor, quando comparado com métodos convencionais de proteção anti-ilhamento. Todos os métodos baseados em aprendizagem de máquina conseguiram reduzir o número de ilhamentos não detectados e os falsos *trips*, que é uma característica muito importante para a proteção anti-ilhamento. Porém, ressalta-se o desempenho da RNA treinada com o ELM, a qual obteve taxas de acerto superior à 99,5 % para todas as análises.

Outro ponto de destaque da proteção proposta é o seu tempo de atuação, o qual foi de aproximadamente 26 ms para todos os casos de teste apresentados na seção 5.5. Este tempo extremamente pequeno foi obtido principalmente devido à velocidade da etapa de detecção de evento, cujo tempo de identificação é da ordem de meio ciclo. Ao receber o sinal de *trigger* da etapa de detecção de evento, uma nova janela de um ciclo é processada e classificada pela RNA, sendo que esta fase final da operação levou pouco mais de um ciclo para a sua execução. Este tempo pode obviamente sofrer alterações dependendo do *hardware* responsável pelo processamento dos dados de entrada.

Vale a pena ressaltar que além do tempo de detecção reduzido, outra característica desejada para a proteção anti-ilhamento é a redução de casos de falso *trip*. O método proposto conseguiu eliminar os casos de falso *trip*. Isso implica que com o método proposto o GD não seria removido do sistema por uma atuação indevida da proteção, garantindo que a sua desconexão será efetuada apenas em casos verdadeiros de ilhamento. Em geral a atuação da metodologia proposta se mostra bastante promissora frente as convencionais, justificando assim o ônus de

desenvolvimento e implementação da nova tecnologia, mais complexa computacionalmente.

6.1 Publicações decorrentes desta pesquisa

- 1- MENEZES, T. S.; GOMES, E. A. P.; COURY, D. V.; OLESKOVICZ, M.. A Hybrid Method for Islanding Stability Detection of Distributed Generators using Wavelet Transform and Artificial Neural Networks. **VII Simpósio Brasileiro de Energia Elétrica - SBSE**, Niterói, RJ, Brasil, de 12 a 16 de maio de 2018. (Artigo publicado e apresentado no congresso)
- 2- MENEZES, T. S.; CARVALHO, W. C. de; COURY, D. V.. Detecção de ilhamento de geradores distribuídos utilizando técnicas de aprendizagem de máquina. **XXII Congresso Brasileiro de Automática - CBA**, João Pessoa, PB, Brasil, de 9 a 12 de setembro de 2018. (Artigo publicado e apresentado no congresso)
- 3- MENEZES, T. S.; COURY, D. V.; FERNANDES, R. A. S.. *Islanding Detection Based on Artificial Neural Network and S-transform for Distributed Generators*. **13th IEEE PES PowerTech Conference 2019**, Milão, MI, Itália, de 23 a 27 de junho de 2019. (Artigo aceito para publicação)

6.2 Publicações em áreas correlatas a pesquisa

Durante o período do mestrado os seguintes trabalhos foram desenvolvidos em áreas correlatas em conjunto com membros do laboratório:

- 1- TRESSO, Y. V.; MENEZES, T. S.; COURY, D. V.; OLESKOVICZ, M.. Synchronous Generator Protection in the Context of Microgrids. **VII Simpósio Brasileiro de Energia Elétrica - SBSE**, Niterói, RJ, Brasil, de 12 a 16 de maio de 2018. (Artigo publicado e apresentado no congresso)
- 2- FARIA, I. M.; FURLAN, R. H.; MARTINS, P. E. T.; MENEZES, T. S.; OLESKOVICZ, M.; COURY, D. V.. The Proposition of a Multiagent System for Adaptive Protection of a Distribution System. **VII Simpósio Brasileiro de Energia Elétrica - SBSE**, Niterói, RJ, Brasil, de 12 a 16 de maio de 2018. (Artigo publicado e apresentado no congresso)
- 3- CARVALHO, W. C. de; MENEZES, T. S.; COURY, D. V.. Aplicação de supercapacitor para a proteção do elo CC e a suavização da potência da geração eólica. **XXII Congresso Brasileiro de Automática - CBA**, João Pessoa, PB, Brasil, de 9 a 12 de setembro de 2018. (Artigo publicado e apresentado no congresso)
- 4- SANTOS, G. G.; MENEZES, T. S.; VIEIRA JUNIOR, J. C. M.; BARRA, P. H. A.. *An S-Transform based approach for fault detection and classification in power distribution*

systems. **2019 IEEE Power & Energy Society General Meeting (PESGM)**, Atlanta, GA, Estados Unidos, de 4 à 8 de agosto de 2019. (Artigo aceito para publicação)

6.3 Trabalhos futuros

As sugestões para a continuidade da pesquisa são:

- Analisar o uso de diferentes transformadas para o pré-processamento do sinal de tensão;
- Efetuar testes de sensibilidade ao ruído da metodologia proposta de modo a averiguar sua influência no desempenho da metodologia;
- Incluir outros geradores no sistema, especialmente com conexão por inversores de potência;
- Testar a inserção de cargas com injeção harmônica no sistema, estudando os seus efeitos e possíveis formas de mitigá-los;
- Avaliar o desempenho da proteção proposta frente à mudanças topológicas do sistema teste; e
- Implementação da metodologia proposta em um sistema embarcado para melhor avaliar os tempos de processamento e resposta final, ficando assim o mais próximo de uma aplicação real.

REFERÊNCIAS

AGHDAM, H. N.; GHADIMI, N.; FARHADI, P.; HASHEMI, F.; GHADIMI, R. Detecting the anti-islanding protection based on combined changes of active and reactive output powers of distributed generations. In: **2011 3rd International Conference on Computer Research and Development**. Shanghai, China: IEEE, 2011. v. 3, p. 285–289. Citado na página 8.

ANEEL. **Geração Distribuída**. 2019. Disponível em: <<http://www2.aneel.gov.br/scg/gd/VerGD.asp>>. Acesso em 28/01/2019. Citado na página 1.

AWAD, M.; KHANNA, R. **Efficient learning machines: Theories, concepts, and applications for engineers and system designers**. Berkeley, CA: Apress, 2015. 1–248 p. Citado na página 13.

BARBOSA, D. **Sistema híbrido inteligente para o monitoramento e proteção de transformadores de potência**. Tese (Doutorado), 2010. Citado 2 vezes nas páginas 22 e 23.

BROWN, G.; POCOCK, A.; LUJÁN, M.; ZHAO, M. M.-J. **A Feature Selection Toolbox for C and Matlab**. 2019. Disponível em: <<http://www.cs.man.ac.uk/~gbrown/fstoolbox/>>. Acesso em 28/01/2019. Citado na página 32.

BROWN, G.; POCOCK, A.; ZHAO, M. M.-J.; LUJÁN, M. Conditional Likelihood Maximisation: A Unifying Framework for Information Theoretic Feature Selection. **Journal of Machine Learning Research**, v. 53, p. 46–58, may 2016. ISSN 1532-4435. Citado na página 32.

CAUE. **Alternative Transient Program (ATP) - Rulebook**. 2002. Comitê Argentino de Usuários de EMTP-ATP. Citado 2 vezes nas páginas 39 e 40.

CIGRÉ Task Force C6.04. **Benchmark Systems for Network Integration of Renewable and Distributed Energy Resources**. 2014. Brochura Técnica 575. Citado 4 vezes nas páginas 37, 39, 65 e 66.

DAUBECHIES, I. **Ten Lectures on Wavelets**. Philadelphia: Society for Industrial and Applied Mathematics, 1992. Citado na página 24.

FAYYAD, Y.; OSMAN, A. Neuro-wavelet based islanding detection technique. **EPEC 2010 - IEEE Electrical Power and Energy Conference: "Sustainable Energy for an Intelligent Grid"**, 2010. Citado 2 vezes nas páginas 9 e 10.

GHANEM, A.; RASHED, M.; SUMNER, M.; ELSAYES, M. A.; MANSY, I. I. I. Grid impedance estimation for islanding detection and adaptive control of converters. **IET Power Electronics**, v. 10, n. 11, p. 1279–1288, 2017. ISSN 1755-4535. Citado na página 8.

HUANG, G. B.; ZHU, Q. Y.; SIEW, C. K. Extreme learning machine: Theory and applications. **Neurocomputing**, v. 70, n. 1-3, p. 489–501, 2006. Citado 4 vezes nas páginas 3, 17, 18 e 19.

IEEE Recommended Practice for Excitation System Models for Power System Stability Studies. **IEEE Std 421.5-2005 (Revision of IEEE Std 421.5-1992)**, p. 1–93, April 2006. Citado na página 40.

IEEE Standard for Interconnection and Interoperability of Distributed Energy Resources with Associated Electric Power Systems Interfaces. **IEEE Std 1547-2018 (Revision of IEEE Std 1547-2003)**, p. 1–138, April 2018. Citado 2 vezes nas páginas 2 e 6.

JANG, S. I.; KIM, K. H. An islanding detection method for distributed generations using voltage unbalance and total harmonic distortion of current. **IEEE Transactions on Power Delivery**, v. 19, n. 2, p. 745–752, 2004. Citado na página 8.

LAGHARI, J. A.; MOKHLIS, H.; KARIMI, M.; BAKAR, A. H. A.; MOHAMAD, H. Computational Intelligence based techniques for islanding detection of distributed generation in distribution network: A review. **Energy Conversion and Management**, v. 88, p. 139–152, 2014. Citado na página 7.

LATHI, B. P. **Sinais e Sistemas Lineares**. 2. ed. Porto Alegre: Bookman, 2007. 678–691 p. ISBN 9788577803910. Citado 2 vezes nas páginas 24 e 27.

LIDULA, N. W. A.; RAJAPAKSE, A. D. Investigation of a fast islanding detection methodology using transient signals. **2009 IEEE Power & Energy Society General Meeting**, p. 1–6, 2009. Citado 3 vezes nas páginas 8, 9 e 10.

_____. A Pattern Recognition Approach for Detecting Power Islands Using Transient Signals - Part I : Design and Implementation. **IEEE Transactions on Power Delivery**, v. 25, n. 4, p. 3070–3077, 2010. Citado 3 vezes nas páginas 8, 9 e 10.

_____. A Pattern-Recognition Approach for Detecting Power Islands Using Transient Signals - Part II: Performance Evaluation. **IEEE Transactions on Power Delivery**, v. 27, n. 3, p. 1071–1080, 2012. Citado 2 vezes nas páginas 9 e 10.

MAHAT, P.; CHEN, Z.; BAK-JENSEN, B. Review of islanding detection methods for distributed generation. In: **2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies**. Nanjing, China: IEEE, 2008. p. 2743–2748. Citado na página 7.

Ministério de Minas e Energia. **Balanco Energético Nacional**. 2018. Disponível em: <http://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2018>. Citado na página 2.

MISHRA, M.; ROUT, P. K.; SAHU, R.; RAY, D.; SWARUP, S. Study the performance of S-transform based extreme learning Machine for islanding detection in distributed generation. In: **2016 National Power Systems Conference (NPSC)**. Bhubaneswar, India: IEEE, 2016. p. 1–6. ISBN 978-1-4673-9968-5. Citado na página 10.

MISHRA, M.; SAHU, R.; RAY, D.; SWARUP, S.; ROUT, P. K. Study of performance of pattern recognition techniques based on wavelet features for islanding detection in distributed generation. In: **2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)**. Delhi, India: IEEE, 2016. p. 1–6. Citado 2 vezes nas páginas 9 e 10.

MOUKADEM, A.; ABDESLAM, D. O.; DIETERLEN, A. **Time-Frequency Domain for Segmentation and Classification of Non-stationary Signals: The Stockwell Transform Applied on Bio-signals and Electric Signals**. Hoboken, NJ, USA: John Wiley & Sons, 2014. 21–59 p. Citado 3 vezes nas páginas 3, 23 e 24.

MOURA, F. A. M. **Geração Distribuída - Impactos e contribuições para a qualidade da energia elétrica e dinâmica dos sistemas elétricos - Uma análise através do ATP-EMTP**. 258 p. Tese (Doutorado) — Universidade Federal de Uberlândia, 2011. Citado 2 vezes nas páginas 40 e 66.

PENG, H.; LONG, F.; DING, C. Feature selection based on mutual information: Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy. **IEEE Trans. on Pattern Analysis and Machine Intelligence**, v. 27, n. 8, p. 1226–1238, 2005. ISSN 01628828. Citado na página 33.

RAY, P. K.; KISHOR, N.; MOHANTY, S. R. Islanding and Power Quality Disturbance Detection in Grid-Connected Hybrid Power System Using Wavelet and S-Transform. **IEEE Transactions on Smart Grid**, v. 3, n. 3, p. 1082–1094, 2012. ISSN 1949-3053. Citado 2 vezes nas páginas 9 e 10.

RAZA, S.; MOKHLIS, H.; AROF, H.; LAGHARI, J.; WANG, L. Application of signal processing techniques for islanding detection of distributed generation in distribution network: A review. **Energy Conversion and Management**, Elsevier, v. 96, p. 613–624, may 2015. Citado na página 23.

REPORT, T. Jan 2013 Dynamic Models for Turbine-Governors in Power System Studies. p. 26–27, 2013. Citado na página 41.

SILVA, I. N. d.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo, SP: Artliber, 2010. 91–162 p. Citado na página 16.

STOCKWELL, R. G.; MANSINHA, L.; LOWE, R. P. Localization of the complex spectrum: the S transform. **IEEE Transactions on Signal Processing**, Institute of Electrical and Electronics Engineers (IEEE), v. 44, n. 4, p. 998–1001, Apr. 1996. Citado na página 24.

WALLING, R. A.; MILLER, N. W. Distributed generation islanding-implications on power system dynamic performance. In: **IEEE Power Engineering Society Summer Meeting**,. Chicago, IL, USA: IEEE, 2002. v. 1, p. 92–96. Citado na página 5.

XU, W.; MAUCH, K.; MARTEL, S. An Assessment of Distributed Generation Islanding Detection Methods and Issues for Canada. **Report # CETC-Varenes 2004-074 (TR), CANMET Energy Technology Centre-Varenes, Natural Resources Canada**, p. 53, 2004. Citado 2 vezes nas páginas 7 e 8.

FUNÇÕES DE PROTEÇÃO CONVENCIONAIS

Este apêndice apresenta os componentes modelados para as funções de proteção convencionais.

A.1 Aquisição de dados

A princípio, foi modelada no ambiente do *ATPDraw* a aquisição dos sinais de tensão no terminal do GD para obtenção da tensão eficaz ou *Root Mean Square* (RMS), frequência e taxa de variação da frequência, de acordo com as funções de proteção escolhidas. Assim como para a proteção proposta, para as funções de proteção também se utilizou o transformador de potencial e o filtro anti-aliasing, FPB de segunda ordem com frequência de corte igual à 1920 Hz.

A.1.1 Tensão eficaz

O primeiro valor a ser calculado é o da tensão eficaz. A tensão de cada uma das fases entra em um bloco de cálculo de valor eficaz, e em seguida obtém-se a média das 3 fases, sendo este o valor de tensão utilizado pela proteção. Assim, a tensão eficaz do gerador é dividida pelo valor de base para a obtenção do valor final já em por unidade (p.u.). O diagrama desta etapa do cálculo da tensão está ilustrado na Figura 28.

Figura 28 – Aquisição e cálculo da tensão trifásica de saída do gerador distribuído.

Fonte: Elaborada pelo autor.

A.1.2 Frequência e taxa de variação da frequência

De modo similar ao cálculo da tensão, a estimação da frequência foi obtida para cada fase, e em seguida a média das três frequências foi utilizada pelas funções de proteção. A estimação em cada uma das fases foi feita a partir do cruzamento por zero, sendo que o bloco de estimação modelado no ATP efetua o cálculo da frequência por borda de subida e descida, assim sendo capaz de atualizar o valor da frequência a cada meio ciclo. Entretanto, para reduzir perturbações causadas por ruídos e/ou componentes harmônicos nos sinais, antes de passar pelo bloco de estimação da frequência, a tensão passa por um FPB com frequência de corte igual à 180 Hz.

Devido à frequência estimada pelo ATP apresentar um formato em degrau, a saída de cada bloco de estimação passou ainda por mais um FPB, mas neste caso de primeira ordem e com frequência de corte igual à 30 Hz. O diagrama completo da estimação de frequência é apresentado na Figura 29.

Figura 29 – Aquisição e cálculo da frequência na saída do gerador distribuído.

Fonte: Elaborada pelo autor.

Por fim, após a obtenção da frequência de saída do GD, efetuou-se o cálculo da taxa de variação da frequência. Entretanto, os valores da taxa de variação podem apresentar grandes variações em um curto período de tempo. Assim, para reduzir variações abruptas na estimação, após a taxa de variação ser calculada, um FPB de segunda ordem é utilizado, com uma frequência de corte igual a 5 Hz. O diagrama da estimação da taxa de variação da frequência é ilustrado na Figura 30.

Figura 30 – Cálculo da taxa de variação da frequência na saída do gerador distribuído.

Fonte: Elaborada pelo autor.

A.2 Funções de proteção

As funções de proteção foram modeladas no *software* MATLAB® 2018b com base no sinal de entrada já processado no ATP durante a simulação. A decisão de modelar as funções fora do ATP foi tomada por facilitar a etapa de ajuste das proteções, não sendo assim necessário executar novamente todo o conjunto de simulações a cada alteração nos ajustes. Cada uma das funções de proteção modelada serão detalhadas nas subseções a seguir.

A.2.1 Função 81U/O

A função de proteção de sub/sobre frequência (81U/O) foi modelada com o limiar de ajuste, tempo de atraso na atuação (Δt) e tensão de bloqueio ($V_{bloqueio}$). Desta forma, para a atuação da função de proteção, a frequência deve exceder os limiares e, ao mesmo tempo, a tensão no barramento deve ser superior à tensão de bloqueio. Este bloqueio por tensão é de grande importância para evitar a atuação da função de proteção durante faltas no sistema. Vale destacar ainda que, o sinal de *trip* só será enviado para o disjuntor caso a frequência se mantenha fora dos limites dos ajustes por um tempo superior ao tempo de espera. O diagrama de blocos da função de proteção é apresentado na Figura 31.

Figura 31 – Diagrama de blocos da função de proteção 81U/O.

Fonte: Elaborada pelo autor.

A.2.2 Função 81R

Similarmente à função 81U/O, a função de proteção de taxa de variação da frequência (81R) foi modelada com o limiar de ajuste, tempo de atraso na atuação e tensão de bloqueio. Assim, para a atuação da função de proteção a taxa de variação da frequência deve exceder os limiares e, ao mesmo tempo, a tensão no barramento deve ser superior à tensão de bloqueio,

novamente para evitar a atuação da função de proteção durante faltas. Vale destacar ainda que, o sinal de *trip* só será enviado para o disjuntor caso a taxa de variação da frequência se mantenha fora dos limites dos ajustes por um tempo superior ao tempo de espera. O diagrama de blocos da função de proteção é apresentado na Figura 32.

Figura 32 – Diagrama de blocos da função de proteção 81R.

Fonte: Elaborada pelo autor.

A.2.3 Função 27/59

A função de proteção de sub/sobre tensão (27/59) foi modelada com o limiar de ajuste e tempo de atraso na atuação. Desta forma, para a atuação da função de proteção a frequência deve exceder os limiares e se manter acima dos mesmos por um tempo superior ao tempo de espera. O diagrama de blocos da função de proteção é apresentado na Figura 33.

Figura 33 – Diagrama de blocos da função de proteção 27/59.

Fonte: Elaborada pelo autor.

SISTEMA DE TESTE DO CIGRÉ

Este apêndice apresenta os componentes modelados no ambiente do *software* ATP para o sistema de teste europeu de média tensão do CIGRÉ, apresentado no Capítulo 5, seção 5.1 na Figura 17.

A.1 Sistema Elétrico

A Tabela 17 apresenta os valores de resistência, indutância e capacitância de sequência positiva e negativa dos condutores de cada um dos trechos de linhas do sistema.

Tabela 17 – Dados dos trechos de linha do sistema e seu comprimento.

Trecho de linha		R_1	X_1	C_1	R_0	X_0	C_0	L
De	Até	[Ω/km]	[mH/km]	[$\mu\text{F}/\text{km}$]	[Ω/km]	[mH/km]	[$\mu\text{F}/\text{km}$]	[km]
1	2	0,501	2,279	0,151	0,817	5,087	0,151	2,82
2	3	0,501	2,279	0,151	0,817	5,087	0,151	4,42
3	4	0,501	2,279	0,151	0,817	5,087	0,151	0,61
4	5	0,501	2,279	0,151	0,817	5,087	0,151	0,56
5	6	0,501	2,279	0,151	0,817	5,087	0,151	1,54
6	7	0,501	2,279	0,151	0,817	5,087	0,151	0,24
7	8	0,501	2,279	0,151	0,817	5,087	0,151	1,67
8	9	0,501	2,279	0,151	0,817	5,087	0,151	0,32
9	10	0,501	2,279	0,151	0,817	5,087	0,151	0,77
10	11	0,501	2,279	0,151	0,817	5,087	0,151	0,33
11	4	0,501	2,279	0,151	0,817	5,087	0,151	0,49
3	8	0,501	2,279	0,151	0,817	5,087	0,151	1,30
12	13	0,510	1,165	0,010	0,658	5,128	0,004	4,89
13	14	0,510	1,165	0,010	0,658	5,128	0,004	2,99
14	8	0,510	1,165	0,010	0,658	5,128	0,004	2,00

Fonte: Adaptada de [CIGRÉ Task Force C6.04 \(2014\)](#).

As cargas presentes no sistemas são de perfil residencial e comercial/industrial. O valor da potência nominal de cada uma das cargas conectadas às barras do sistema estão apresentadas na Tabela 18. Ressalta-se que a barra 2 do sistema não possui nenhuma carga conectada, sendo apenas uma barra de passagem.

Tabela 18 – Potências das cargas em cada uma das barras do sistema.

Barra	Residencial		Comercial/Industrial	
	Potência Aparente [kVA]	Fator de potência	Potência Aparente [kVA]	Fator de potência
1	15300	0,98	5100	0,95
3	285	0,97	265	0,85
4	445	0,97	-	-
5	750	0,97	-	-
6	565	0,97	-	-
7	-	-	90	0,85
8	605	0,97	-	-
9	-	-	675	0,85
10	490	0,97	80	0,85
11	340	0,97	-	-
12	15300	0,98	5280	0,95
13	-	-	40	0,85
14	215	0,97	390	0,85

Fonte: CIGRÉ Task Force C6.04 (2014).

A.2 Gerador Síncrono

As especificações elétricas e mecânicas do gerador síncrono utilizado neste estudo estão reunidas na Tabela 19.

Tabela 19 – Dados elétricos e mecânicos da máquina síncrona.

Parâmetro	Valor	Parâmetro	Valor
S_n	5 MVA	U_n	6,6 kV
f	60 Hz	P	4 pólos
ω_s	188,5 rad/s	R_a	0,004 p.u.
x_L	0,1 p.u.	x_d	1,8 p.u.
x_q	1,793 p.u.	x'_d	0,166 p.u.
x'_q	0,98 p.u.	x''_d	0,119 p.u.
x''_q	0,17 p.u.	T'_{d0}	1,754 s
T'_{q0}	0 s	T''_{d0}	0,019 s
T''_{q0}	0,164 s	x_0	0,046 p.u.
H	1 s		

Fonte: Adaptada de Moura (2011).

onde,

S_n : potência aparente nominal do gerador;

U_n : tensão nominal de saída;

f : frequência do gerador;

P : número de pólos;

ω_s : velocidade síncrona do gerador;

R_a : resistência de armadura;

x_L : reatância de dispersão da armadura;

x_d : reatância de eixo direto;

x_q : reatância de eixo de quadratura;

x'_d : reatância transitória de eixo direto;

x'_q : reatância transitória de eixo de quadratura;

x''_d : reatância subtransitória de eixo direto;

x''_q : reatância subtransitória de eixo de quadratura;

T'_{d0} : constante de tempo transitória de eixo direto;

T'_{q0} : constante de tempo transitória de eixo de quadratura;

T''_{d0} : constante de tempo subtransitória de eixo direto;

T''_{q0} : constante de tempo subtransitória de eixo de quadratura;

x_0 : reatância de sequência zero; e

H : constante de inércia.