



**DOUGLAS ROBERTO FERNANDES DAMASCENO**

**MÉTODO DE CLUSTERIZAÇÃO FUZZY C-MEANS PARA  
DETECÇÃO DE ILHAMENTO EM CONVERSORES  
ELETRÔNICOS**

**LAVRAS - MG**

**2019**

**DOUGLAS ROBERTO FERNANDES DAMASCENO**

**MÉTODO DE CLUSTERIZAÇÃO FUZZY C-MEANS PARA DETECÇÃO DE ILHAMENTO  
EM CONVERSORES ELETRÔNICOS**

Trabalho de Conclusão de Curso  
apresentado à Universidade Federal de  
Lavras, como parte das exigências do  
Curso de Engenharia de Controle e  
Automação, para a obtenção do título de  
Bacharel

Prof. Dra. Sílvia Costa Ferreira  
Orientadora

Daniel Furtado Leite  
Coorientador

**LAVRAS – MG**

**2019**

**DOUGLAS ROBERTO FERNANDES DAMASCENO**

**MÉTODO DE CLUSTERIZAÇÃO FUZZY C-MEANS PARA DETECÇÃO  
DE ILHAMENTO EM CONVERSORES ELETRÔNICOS**  
**FUZZY C-MEANS CLUSTERING METHOD FOR ISLAND DETECTION  
IN ELECTRONIC CONVERTERS**

Trabalho de Conclusão de Curso  
apresentado à Universidade Federal de  
Lavras, como parte das exigências do  
Curso de Engenharia de Controle e  
Automação, para a obtenção do título de  
Bacharel

Prof. Dra. Sílvia Costa Ferreira  
Orientadora

Daniel Furtado Leite  
Coorientador

**LAVRAS – MG**

**2019**

*Dedico este trabalho a Deus  
primeiramente, a minha família por todo  
apoio e a todos que contribuíram na  
pesquisa.*

## RESUMO GERAL

Este trabalho apresenta uma estratégia de detecção de ilhamento para microrredes com conversores eletrônicos com base em uma técnica de aprendizagem de máquina não supervisionado. O método tem por agrupar padrões de comportamento em amostras do sistema. Foram extraídos do sistema, no ponto de acoplamento comum (PCC), valores de tensão e corrente. Estes dados serviram como entrada para um Filtro Adaptativo no intuito de monitorar sete variáveis, sendo a frequência ( $f$ ), o valor eficaz da tensão ( $V_1$ ) e da corrente ( $I_1$ ), distorção harmônica total da tensão ( $THD_V$ ) e da corrente ( $THD_I$ ), potência ativa ( $P$ ) e reativa ( $Q$ ), obtidas por meio de simulação na ferramenta SIMULINK® do *software* MATLAB®. O método proposto utilizou a técnica passiva, visando não interferir nos parâmetros do sistema. Com a finalidade de obter situações realísticas, simulou-se o sistema com variações de cargas e, ao ocorrer o ilhamento, os parâmetros para a carga final e o tempo máximo para a detecção foram regidos pela norma IEEE 1547. Uns dos principais objetivos deste trabalho foi diminuir as zonas de não-deteção (ZNDs), e obter o menor tempo e eficiência possível de detecção. A primeira parte deste trabalho consiste em uma revisão bibliográfica dos tópicos relacionados à detecção de ilhamento, sistemas fuzzy, clusterização e algoritmos de pré-processamento. Na segunda parte do trabalho é apresentado um artigo, no qual a metodologia e os resultados são evidenciados.

## GENERAL ABSTRACT

This paper presents an island detection strategy for microgrids with electronic converters based on an unsupervised clustering algorithm. The method is based on clustering patterns of behaviors uncovered from the data. Voltage and current features were extracted from the power system at the point of common coupling (PCC). These features were used as input to an Adaptive Filter in order to monitor seven variables, namely, frequency ( $f$ ), effective values of voltage ( $V_1$ ) and current ( $I_1$ ), voltage and current harmonic distortion ( $THD_V$ ) ( $THD_I$ ), active power ( $P$ ), and reactive power ( $Q$ ), obtained from a simulations in the SIMULINK® tool of the MATLAB® software. The proposed method used a passive technique aiming not to interfere in the system parameters. In order to obtain realistic situations, the system is simulated with load variations and, in case of islanding, the parameters for the load and maximum detection time are governed by the IEEE 1547 standard. One of the main objectives of this study was to decrease the non-detection zones (NDZs), and to obtain the shortest possible detection time, effectively. The first part of this study consists of a bibliographical review of the topics related to islanding detection, fuzzy systems, clustering, and preprocessing algorithms. In the second part, a paper is presented, in which the methodology and the results are highlighted.



## LISTA DE FIGURAS

Figura 1: Sistema figurado. ....	13
Figura 2: Métodos de detecção de ilhamento. ....	14
Figura 3: Implementação do método PJD. ....	<b>Erro! Indicador não definido.</b>
Figura 4: Estrutura geral de um filtro adaptativo. ....	24
Figura 5: Diagrama em blocos do algoritmo do filtro adaptativo sintonizado. ....	26



## LISTA DE TABELAS

Tabela 1 - Parâmetros estimados dos filtros adaptativos.....	31
Tabela 2 - Diferentes valores da carga RLC simuladas.....	31
Tabela 3 - Parâmetros da DG. ....	32

## SUMÁRIO

PRIMEIRA PARTE .....	11
1. INTRODUÇÃO.....	11
2. REFERENCIAL TEÓRICO.....	13
2.1 Sistemas elétricos de potência em operação ilhada .....	13
2.2 Técnicas de detecção de ilhamento.....	14
2.3 Aplicações de técnicas de inteligência computacional para a detecção do ilhamento ...	17
2.4 Sistemas Fuzzy.....	19
2.4.1 Fundamentos .....	19
2.4.2 Clusterização .....	20
2.4.3 Método de validação .....	23
2.5 Algoritmos de pré-processamento de dados .....	23
2.5.1 Filtros Adaptativos .....	24
2.5.1.1 Filtros adaptativo sintonizado baseado na estimação da frequência .....	25
3. CONSIDERAÇÕES FINAIS .....	30
3.1 Sistema de teste.....	30
3.2 Configurações do sistema .....	31
3.3 Método proposto para detecção do ilhamento .....	32
4. REFERÊNCIAS .....	34
A. APÊNDICE.....	37
SEGUNDA PARTE – ARTIGO .....	39
ARTIGO 1 – MÉTODO DE CLUSTERIZAÇÃO FUZZY C-MEANS PARA DETECÇÃO DE ILHAMENTO EM CONVERSORES ELETRÔNICOS .....	39

## PRIMEIRA PARTE

### 1. INTRODUÇÃO

Com o avanço tecnológico, a busca por fontes de energia elétrica que proporcionam um menor impacto ambiental tem estimulado a utilização sistemas de geração distribuída (GDs). Estes sistemas podem ser de pequeno e médio porte, e são conectados aos sistemas de distribuição globais. O seu uso é vantajoso para as concessionárias, proprietários de GDs e consumidor final, pois é viável economicamente e há uma maior confiabilidade no fornecimento. Os GDs, geralmente, são fontes de energia renovável advindas de centrais eólicas, solar, entre outras, que possuem baixo impacto ambiental.

Com a expansão do uso de fontes distribuídas e intermitentes no sistema elétrico alguns fatores devem ser relevados, tais como: alocação ótima de geradores distribuídos (YADAV e SRIVASTAVA, 2014), problemas relativos ao impacto das gerações distribuídas na coordenação dos dispositivos de proteção (GUTIERRES, et al., 2014), e detecção de ilhamento não intencional, conforme destaca Marchesan (2016, p. 13).

Como a inserção das GDs eleva-se a complexidade do sistema elétrico aumentando a relevância dos estudos em relação à operação de ilha. O ilhamento ocorre quando parte da rede se torna eletricamente isolada da concessionária, porém o subsistema continua energizado pelas GDs. Entretanto, se não operado de forma adequadas, o ilhamento pode ser prejudicial, tornando sua detecção essencial para prevenir diversos problemas, tais como: o comprometimento da segurança das equipes de manutenção e da população; a deterioração da qualidade de energia elétrica; a reconexão automática fora de sincronismo, entre outros. Por isso, a Agência Nacional de Energia Elétrica (ANEEL, 2016) estabelece a detecção de ilhamento como uma função de proteção obrigatória para os conversores eletrônicos.

As técnicas empregadas para a detecção de ilhamento são classificadas em técnica remota e local. A técnica remota envolve algum tipo de comunicação entre concessionária, os dispositivos de proteção e as GDs. Elas são eficientes, porém apresentam custo elevado devido à complexidade de comunicação. Já as técnicas locais envolvem a detecção usando parâmetros de medidas elétricas no ponto de conexão da GD. Diferente da técnica remota, esta técnica não necessita de comunicação entre dispositivo e centro de controle.

A técnica local é subdividida em: técnica passiva baseada apenas em medidas elétricas no ponto de acoplamento da GD; técnica ativa que tem como princípio inserir pequenas perturbações no sistema de potência analisando possíveis anomalias; e, por fim, técnica híbrida, a qual emprega técnica passiva e ativa simultaneamente. As técnicas locais e passivas vêm sendo amplamente utilizadas em conversores eletrônicos e será o foco deste estudo.

A primeira parte do trabalho apresenta os conceitos teóricos relacionados a: técnicas de detecção de ilhamento e aplicação de algoritmos de inteligência computacional, como sistemas fuzzy e clusterização C-Means, e técnicas de pré-processamento de sinais. Esses conceitos serão utilizados para propor o uso de Fuzzy C-Means para a detecção de ilhamento em conversores eletrônicos. Isso será apresentado na segunda parte do trabalho.


## 2. REFERENCIAL TEÓRICO

### 2.1 Sistemas elétricos de potência em operação ilhada

Nos últimos anos, o setor de energia elétrica deparou-se com um constante processo de reestruturação países. Barreiras legais e econômicas no segmento de geração de energia foram reduzidas ou até mesmo eliminadas, fazendo com que novas fontes de energia fossem interconectadas ao sistema de distribuição e subtransmissão. Com a pressão mundial para desenvolvimento de práticas sustentáveis e limpas, as fontes de energia renovável avançaram em pesquisa e desenvolvimento para sua implementação em sistemas de distribuição.

Neste cenário, a inserção de sistemas de geração distribuída (GDs) tem aumentado a complexidade do sistema elétrico impulsionando estudos sobre o modo de operação ilhado. O ilhamento ocorre quando parte do sistema elétrico se torna eletricamente isolado da concessionária, porém continua energizado pelas GDs. A Figura 1 demonstra um sistema figurado, no qual temos a operação da GD em modo ilhado quando o disjuntor  $D_1$  estiver fechado e  $D_2$  aberto. Deste modo, o sistema equivalente não supriria as cargas, apenas a GD energizaria as cargas  $L_1$ ,  $L_2$  e  $L_3$ , tornando o sistema ilhado (MOTTER, 2014).

Figura 1: Sistema figurado.



Fonte: Motter, (2014).

A condição de operação ilhada, se não gerenciada de forma adequada, pode comprometer a segurança das equipes de manutenção e da população, deteriorar a qualidade da energia elétrica e causar problemas em condições de reconexão fora de sincronismo. Desse modo, a ANEEL estabelece que os conversores eletrônicos que interconectam os sistemas de GD com a rede elétrica,

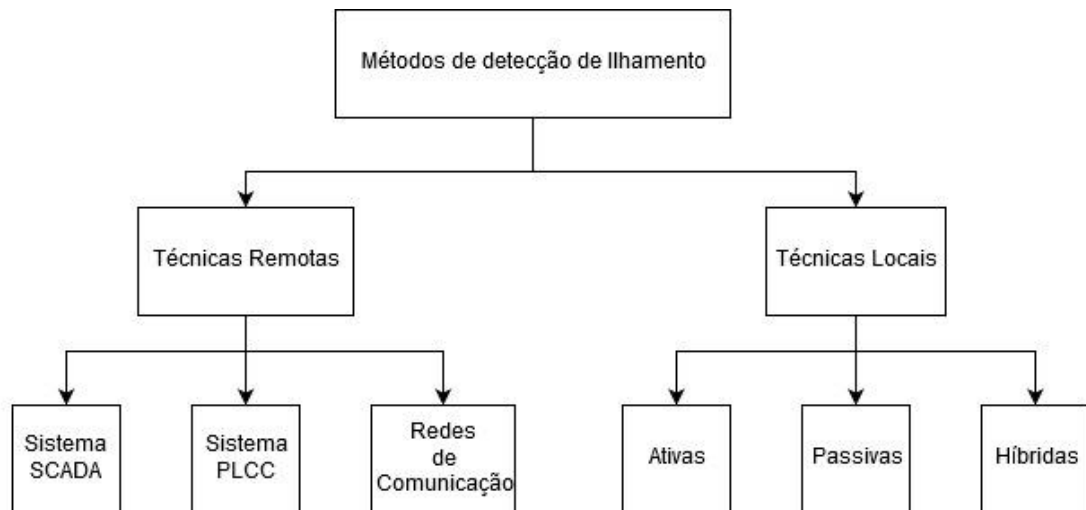
detectem a condição de ilhamento e interrompam o fornecimento de energia nesta condição (ANEEL, 2016).

As técnicas empregadas para a detecção de ilhamento são classificadas em função de seus princípios operativos. Elas serão detalhadas a seguir.

## 2.2 Técnicas de detecção de ilhamento

Existem duas classes principais para detecção de ilhamento, classificadas em técnica remota e local, sendo subdivididas em subclasses, conforme a Figura 2.1.

Figura 2: Métodos de detecção de ilhamento.



Fonte: adaptado de Motter (2014).

As técnicas remotas possuem em seu fundamento um método de comunicação entre a concessionária, os geradores distribuídos, os dispositivos de segurança e uma determinada interface para a detecção. Elas são eficientes e apresentam uma maior confiabilidade em relação as técnicas locais, porém apresentam custo elevado devido à complexidade de comunicação. Gomes (2016, p.14) discorre sobre as seguintes técnicas de detecção de ilhamento remota:

- a) **Sistemas Supervisory Control and Data Acquisition (SCADA):** são aqueles que monitoram o estado de todos os disjuntores desde a subestação até os GDs. Caso ocorra o ilhamento, o sistema identifica o local e a GD é desligada por esquema de teleproteção;

- b) **Sistemas Power Line Carrier Communication (PLCC):** são instalados receptores de sinal, de uma frequência específica, que recebem sinais enviados pela linha de transmissão. Caso ocorra a interrupção do sinal, o ilhamento é detectado;
- c) **Redes de comunicação dos dispositivos de proteção:** os dispositivos de proteção dos GDs são interligados com os da subestação por redes de comunicação.

Já as técnicas locais envolvem a detecção usando parâmetros de medidas elétricas no ponto de conexão da GD. Diferente da técnica remota, esta técnica não necessita de comunicação entre dispositivo e um centro de controle ou a concessionária.

As técnicas locais são subdivididas em:

- a) **Técnica passiva:** esta é a mais utilizada para detecção de ilhamento, pois apresenta baixo custo e fácil instalação. É baseada em medidas realizadas no ponto de acoplamento comum. Não necessitam de redes de comunicação e não inserem distúrbios na rede, não degradando a qualidade da energia. Entretanto, podem apresentar zonas de não detecção devido à pequenas variações as variáveis medidas (MOTTER, 2014);
- b) **Técnica ativa:** tem como princípio a inserção de perturbações no sistema. Segundo Mahat, Chen e Bak-Jensen (2008) ao inserir uma perturbação na rede, esta irá influenciar em algum parâmetro elétrico quando ocorrer o ilhamento, o que não ocorreria com o sistema operando normalmente. Um tipo de método citado pelos autores é a inserção de potência reativa no sistema, pois, ao ocorrer o ilhamento, a tensão da GD aumentaria significativamente, caracterizando e identificando o ilhamento;
- c) **Técnica híbrida:** assim como a técnica ativa, esta insere perturbações controladas no sistema. Entretanto, o que diferencia esta técnica das técnicas ativas e passivas é que as perturbações são inseridas no sistema caso haja suspeita de ilhamento. Esta suspeita é geralmente obtida por meio da técnica passiva, caracterizando uma união das técnicas passiva e ativa (GOMES, 2016).

Normalmente, as técnicas passivas são as mais empregadas em sistemas de detecção de ilhamento. Isto ocorre pelo fato de apresentarem um menor custo devido à não utilização de uma infraestrutura de comunicação de rede; maior facilidade de instalação, pois necessitam medições

locais dos parâmetros da GD; e não inserção de sinais que possam degradar a qualidade de energia, como ocorre na técnica ativa (GOMES, 2016).

Parâmetros derivados da tensão e frequência são muito utilizados nas técnicas passivas. Entre os métodos mais populares, pode-se destacar: o método de detecção OUV-OUF (em inglês, *Over/Under Voltage e Over /Under Frequency* – OUV-OUF), método Detecção do Salto de Fase (em inglês, *Phase Jump Detection* - PJD).

De acordo com Silva (2016), o método de detecção OUV-OUF é um dos mais simples de ser implementado. Consiste em monitorar a tensão e a frequência do ponto de acoplamento (PCC) e comparar à um determinado limite preestabelecido. Além disso, pode ser aplicado para qualquer tipo de fonte de GD, conectada por conversores eletrônicos ou não. Entretanto, como característica negativa, possui zona de não detecção muito alta e dificuldade na definição dos limites necessários para a detecção.

Outro fator positivo relevante é a utilização deste método para qualquer GD. Porém, como característica negativa, o método apresenta uma grande ZND e a dificuldade de encontrar os limites necessários para a detecção.

A detecção de ilhamento por salto de fase (PJD) é obtida por meio do monitoramento da defasagem entre a tensão do ponto de acoplamento e a corrente de saída do conversor eletrônico (BOWER; ROPP, 2002; KOBAYASHI et al., 1991).

Em condição normal de operação, a corrente do inversor segue a referência fixada por uma malha de controle de fase (em inglês, *Phase Locked Loop* - PLL). No momento em que a rede é desconectada, ocorrendo o desbalanceamento de potência entre inversor e carga, a fase entre a tensão e corrente serão diferentes de zero, sendo detectada pelo PJD, caracterizando o ilhamento (SILVA, 2016).

Como característica positiva, o método PJD é de fácil implementação, pois todo inversor possui um PLL para sincronismo com a rede. Porém, como características negativas, o método apresenta uma grande ZND e difícil ajuste dos limites máximo e mínimo para o erro da fase.

Com base nos dois métodos tradicionais citados e com a revisão das técnicas tradicionais, mostra-se que há um grande desafio para a detecção do ilhamento utilizando técnicas locais, pois apresentam ZND, tempo de detecção longo, falsa operação, e necessidade de inserir perturbações controladas (GOMES, 2016).



Devido aos fatos, a busca por métodos com baixa complexidade e viáveis economicamente está sendo um desafio na atualidade para detecção do ilhamento. Assim, algoritmos apurados têm sido desenvolvidos, os quais relacionam parâmetros adicionais, obtidos no processamento dos sinais de corrente e tensão, para a detecção utilizando a técnica passiva. Entretanto, devido às relações naturalmente complexas dos parâmetros mensuráveis, é necessário recorrer a técnicas que extraiam padrões de um determinado banco de informações em que estão contidas uma série de dados simulados (GOMES, 2016). Portanto, novas técnicas baseadas em algoritmos inteligentes estão sendo desenvolvidas com intuito de minimizar as ZND e a complexidade dos algoritmos, e maximizar o tempo de detecção.

### **2.3 Aplicações de técnicas de inteligência computacional para a detecção do ilhamento**

Diversas metodologias e paradigmas da inteligência computacional já foram utilizados na detecção de forma passiva. Entre diversas técnicas utilizadas destacam-se a Máquina de Vetores de Suporte (em inglês, *Support Vector Machine - SVM*), realimentação positiva de frequência (fuzzy) (em inglês, *Frequency Fuzzy Positive Feedback - FFPPF*), transformada Hilbert modificada em curto prazo (em inglês, *Short-Time Modified Hilbert Transform - STMHT*), controle adaptativo (em inglês, *Adaptative Controle*), sistema de interface neuro fuzzy adaptativo (em inglês, *Adaptive Neuro-Fuzzy Inference System - ANFIS*). Neste contexto, o tempo de detecção do ilhamento é o fator mais relevante.

Matic-Cuka e Kezunovic (2014) utilizaram uma técnica de *machine learning* baseada em SVM como método para detecção de ilhamento. Para tal feito, utilizou-se os valores instantâneos de corrente e tensão o que são processados usando o método de Yule–Walker para cálculo dos coeficientes auto regressivos (AR) e variância dos ruídos. O resultado obtido foi um tempo de 50ms para detecção do ilhamento depois do início do evento.

Aguiar et al. (2015) utilizaram a técnica de realimentação positiva de frequência (fuzzy). O principal objetivo foi reduzir a injeção de distúrbios dos métodos de anti-ilhameno ativos, os quais reduzem a qualidade da energia. Com o intuito de diferenciar a variação da frequência, que pode ser por motivo de ilhamento ou um problema de qualidade de energia, a realimentação positiva fuzzy permite a diferenciação da condição de ilhamento com outros eventos na rede. Como resultados, eliminou-se a injeção de distúrbio, simplificando o uso do método de anti-ilhamento

com ganho dinâmico do PF, e houve uma diminuição do tempo de detecção de 80% em relação aos métodos clássicos.

Chakravorti et al. (2017) apresentaram as técnicas *Multi-Scale Morphological Gradient Filter* (MSMGF) e *Short-Time Modified Hilbert Transform* (STMHT) que são úteis para detecção e classificação de multiclasss de distúrbios em GD baseada em microrrede. Devido à complexidade de diferenciação de padrões de perturbação, utilizou-se uma estrutura de julgamento em árvore fuzzy para a classificação dos eventos multiclasss. Como resultado, as técnicas apresentaram uma maior rapidez computacional em comparação com algumas técnicas de processamento de sinais (SPTs), como Transformada de Fourier (em inglês, *Fourier Transform* - FT), Transformada de Hilbert (em inglês, *Hilbert Transform* - HT), Transformada de Wavelet (em inglês, *Wavelet Transform* - WT), entre outras técnicas utilizadas para detecção de ilhamento.

Pouryektá et al. (2018) apresentaram um método de detecção de ilhamento (em inglês, *Islanding Detection Method- IDM*) híbrido em que consiste de uma técnica de detecção remota e uma passiva, sendo utilizado um detector de sinal (em inglês, *Signal Detector* - SD) e a taxa de variação da fase de tensão (em inglês, *Rate Of Change Of Voltage Phase* - ROCOVP) respectivamente para as técnicas citadas. Após a detecção foi proposta uma estratégia de controle adaptativo para garantir a operação estável de subseções ilhadas. O método utiliza a variação do erro das variáveis do sistema, sendo a tensão e potência. Obteve-se como resultado que o método híbrido foi capaz de detectar o ilhamento na presença de várias unidades de geração distribuída. Outro fator foi que o método de detecção de ilhamento não foi afetado por variações nas cargas e tipo de geração e, por fim, a estratégia de controle adaptativo mantém a operação estável da ilha quando ocorre uma falha.

Por fim, Mlakić et al. (2019) propuseram detecção de ilhamento em microrredes usando inversores de interface de baixa tensão e a técnica de sistema de inferência neuro-fuzzy adaptável (em inglês, *adaptive neuro-fuzzy inference system* – ANFIS). Foram utilizados dois tipos de testes, sendo o primeiro com uma GD e outro com duas GDs em paralelo. Monitorou-se passivamente sete entradas no ANFIS obtidas no ponto comum de acoplamento com o intuito de diminuir consideravelmente as ZNDs. Como resultados, para o primeiro e segundo teste obtiveram tempos de detecção abaixo de 0,046 segundos e um impacto na qualidade da distribuição permitido de acordo com a norma UL1741.

A lógica fuzzy vem se mostrando uma técnica promissora para detecção e classificação de eventos ocorridos na rede elétrica. Diversos autores tem apresentado pesquisas sobre classificação de distúrbios de Qualidade de Energia Elétrica (QEE) em sistemas ilhados utilizando lógica fuzzy. Entre eles: Kermany et al. (2016) utilizou Rede Neuro-Fuzzy (em inglês, Fuzzy-Neural Network - FNN); Mlakić et al. (2019) utilizou ANFIS; Samantaray et al. (2010) utilizou classificador fuzzy, entre outros. O problema da detecção de ilhamento por métodos convencionais apresentam grandes ZNDs em algoritmos que visam detectar por meio de comparação os parâmetros medidos com limites impostos. Devido a este fator, a lógica fuzzy é uma estratégia promissora, pois, como vantagem principal, um classificador baseado em regras aprese com ativação parcial apresenta uma maior flexibilidade do limite de decisão. O classificador fuzzy é mais flexível com os limites desejados, comparado com classificadores baseados em limites fixos. Portanto, o classificador fuzzy apresenta ZNDs mínimas, o que torna o método confiável e condizente para detecção do ilhamento.

## 2.4 Sistemas Fuzzy

### 2.4.1 Fundamentos

A lógica fuzzy foi introduzida por Lotfi Zadeh no início dos anos 1960. Ela possibilita a manipulação de informações vagas, ambíguas e imprecisas, e processamento e aprendizado a partir de dados. Estas informações podem ser quaisquer valores reais que estão entre o intervalo 0 e 1, indicando o grau de relevância ou associação (em inglês, *Membership*) que este elemento possui em um determinado conjunto.

De acordo com Zadeh (1965, p. 339):

“Seja  $X$  um espaço matemático, com um elemento genérico de  $X$  denotado por  $x$ . Assim,  $X = \{x\}$ . Um conjunto fuzzy (classe)  $A$  em  $X$  é caracterizado por uma função de pertinência  $f_A(x)$  que associa a cada ponto em  $X$  um número real no intervalo  $[0, 1]$ .”

Em um conjunto fuzzy as fronteiras não são nitidamente definidas, possibilitando que determinados dados possam pertencer, com um determinado grau de pertinência, a conjuntos diferentes.

Tem sido necessário agrupar ou classificar determinados objetos em categorias devido ao crescente volume de informações disponíveis. Geralmente, um determinado conjunto de dados possui uma organização inerente que pode ser separada em  $m$  partições (*clusters*) (MOTA et al., 2018). Geralmente, esta separação é realizada por especialistas humanos que classificam dados manualmente, porém, esta classificação pode ser influenciada por conhecimentos prévios e inviável para grandes conjuntos de dados. É possível também utilizar um algoritmo supervisionado que consiste de uso de determinado conjunto de dados rotulados em que há conhecimento prévio da saída desejada para cada entrada. Desta forma, pode-se ajustar um modelo, tornando possível o reconhecimento da saída para rótulos desconhecidos. Porém, os processos de rotulagem dos dados podem não ser confiáveis devido à erros de instrumentação ou subjetividades.

Desse modo, a utilização de um algoritmo não supervisionado é o mais indicado para estes casos. Este visa encontrar similaridade entre os dados de entrada. Os algoritmos não supervisionados não possuem conhecimento do valor de saída para determinadas entradas, portanto não possuem orientação de aprendizado. Assim, os padrões são identificados a partir dos dados de entrada (MOTA et al. apud LEITE, 2012).

## 2.4.2 Clusterização

Clusterização é uma abordagem de análise de dados que auxilia na resolução de problemas que necessitam de classificação. O objetivo é subdividir um conjunto de dados em subconjuntos (*clusters*). Estes subconjuntos possuem alto grau de associação entre seus elementos e fraca associação ou fraco grau de associação referente aos elementos dos demais subconjuntos.

Dado um conjunto de dados  $X$ , um algoritmo de clusterização atribui rotulação aos objetos de um determinado subconjunto no conjunto  $X$ . Isso é possível por meio do uso de uma medida de distância entre os objetos. A partir da medida determina-se os *clusters*, particionando o conjunto de objetos em  $c$  *clusters*, tornando os objetos do subconjunto, definido pela medida de distância, altamente associados. As principais medidas de distância usadas nos algoritmos são as normas

Manhattan (1 norma), Euclidiana (2 normas), Chebyshev ( $\infty$ -norma) e a distância de Mahalanobis (Mota et al., 2018). No último caso é necessário o cálculo de uma matriz de covariância. O tempo de computação cresce quadraticamente com a quantidade de variáveis.

A clusterização pode seguir uma abordagem clássica ou fuzzy. Na abordagem clássica cada elemento pertence unicamente a uma determinada classe. Já na abordagem fuzzy, cada elemento pode pertencer a várias classes com diferentes valores de pertinência.

Estão entre os principais algoritmos de clusterização o K-Means (KM), Fuzzy C-Means (FCM), Gustafson-Kessel (GK) e Gath-Geva (GG). Estes possuem aspectos em comum referentes à estrutura do algoritmo, sendo:

- a) Inicialização aleatória dos *clusters* e configuração dos parâmetros iniciais;
- b) Para cada amostra na base de dados, calcular a distância para cada *cluster* e associar ao que estiver mais próximo;
- c) Atualizar a matriz de partição, o centro de cada *cluster*, e parâmetros associados.

Os passos 2 e 3 são repetidos até o algoritmo convergir conforme um critério adotado.

Tem-se como distinção dos algoritmos o método para calcular a distância entre *cluster* e amostra. Os algoritmos KM e FCM utilizam a distância Euclidiana. Já o algoritmo GK utiliza distância de Mahalanobis, e GG a distância Gaussiana.

Este trabalho implementará o algoritmo FCM para a classificação não supervisionada para a detecção do ilhamento.

#### 2.4.2.1 Clusterização Fuzzy C-Means

Vários critérios de clusterização foram propostos para identificar partições fuzzy  $c$  em uma determinada base de dados  $X$ . Destes, o mais corriqueiro está associado ao erro dos mínimos quadrados generalizados (BEZDEK; EHRLICH e FULL, 1982), como apresentado:

$$J_m(U, v) = \sum_{k=1}^N \sum_{i=1}^c (u_{ik})^m \|x_k - v_i\|_A^2 \quad (2.4.1)$$

Sendo:

$$X = \{x_1, x_2, \dots, x_N\} \subset R^n;$$

$c$  – Números de clusters em  $X$  ( $2 \leq c < n$ );

$N$  – Número de amostras;

$m$  – Expoente de ponderação ( $1 \leq m \leq \infty$ );

$U$  – Partições fuzzy de  $X$ ;

$v$  –  $(v_1, v_2, \dots, v_c)$  vetor dos centros;

$v_i$  –  $(v_{i1}, v_{i2}, \dots, v_{in})$  centro do cluster;

$\| \cdot \|_A$  – Norma matricial induzida  $A \in R^n$ ;

$A$  – Matriz de partição ( $n \times n$ ).

A matriz de partição  $A$  é a identidade no FCM, o que induz clusters esféricos.

A distância ao quadrado entre  $x_k$  e  $v_i$  em (2.4.1) é dada pelo produto interno da diferença como:

$$d_{ik}^2 = \|x_k - v_i\|_A^2 = (x_k - v_i)^T A (x_k - v_i) \quad (2.4.2)$$

O peso do erro quadrático está associado a  $(u_{ik})^m$  em (2.4.1), elevado ao  $m$ -ésimo expoente de ponderação da pertinência de  $x_k$  no cluster  $i$ . Os centros dos clusters são obtidos a partir de:

$$v_i = \frac{\sum_{k=1}^N (u_{ki})^m x_k}{\sum_{k=1}^N (u_{ki})^m} \quad (2.4.3)$$

Seja uma matriz de partição  $U \in \mathbb{R}^{c \times N}$  constituídas de elementos  $u_{ik}$  conforme

$$U = \begin{bmatrix} u_{11} & \cdots & u_{1c} \\ \vdots & \ddots & \vdots \\ u_{N1} & \cdots & u_{Nc} \end{bmatrix} \quad (2.4.4)$$

Sendo a partição de  $X$ ,  $u_{ki} \in [0,1] \forall k, i$ ;  $\sum_{i=1}^c u_{ki} = 1 \forall k$ ; e  $0 < \sum_{i=1}^N u_{ki} < N \forall i$ . Os elementos da matriz de partição são dados por:

$$u_{ki} = \frac{1}{\sum_{j=1}^c \left( \frac{d_{ki}}{d_{kj}} \right)^{\frac{1}{m-1}}} \quad (2.4.5)$$

Assim, o valor de (2.4.1) é uma medida da variância total entre  $x_k$  e  $v_i$ , que deve ser minimizado. Os centros dos *cluster* convergem para um determinado ponto no espaço dos dados quando não há mais variação significativa da matriz de partição observada, ou seja  $\|\Delta U\| < \varepsilon$ , em que  $\varepsilon$  é um limiar (MOTA et al., 2018).

### 2.4.3 Método de validação

Um índice de validação geralmente é utilizado para definir a qualidade de partições, buscando uma escolha eficiente do número de grupos. Diversos métodos de validação são propostos na literatura, entre eles estão: critério de Xie-Beni (em inglês, Xie-Beni criterion - XB), coeficiente de Partição (em inglês, Partition Coefficient – PC), índice de partição (em inglês, Partition index - SC), entre outros. Neste trabalho foi utilizado o método de validação XB.

#### 2.4.3.1 Índice Xie-Beni

O índice de validação Xie-Beni é útil para validação do número de *clusters*, sendo definido como (Xie e Beni, 1991):

$$XB(c) = \frac{\sum_{i=1}^c \sum_{k=1}^n (u_{ik})^m \|x_k - v_i\|_A^2}{N \min_{\forall k,i} \|x_k - v_i\|_A^2} \quad (2.4.6)$$

O critério tem por finalidade encontrar o valor mínimo, demonstrando o quão ~~são~~ compactos e bem separados são os clusters.

## 2.5 Algoritmos de pré-processamento de dados

O processamento de dados diz respeito ao processo de extração de variáveis e informações de medições. Esta é uma das partes mais importantes de um sistema de reconhecimento de padrões, que por vez tem por objetivo caracterizar e distinguir diferentes classes. Várias técnicas de processamento de sinal têm sido utilizadas para extração de variáveis, as quais podemos citar (KHOKHAR et al. 2015) a Transformada de Fourier (em inglês, *Fourier Transform* - FT), Transformada Wavelet (em inglês, *Wavelet Transform* - WT), Filtro de Kalman (em inglês, *Kalman*

*Filter* - KF), Transformada de Hilbert (em inglês, *Hilbert Transform* - HT), Filtro Adaptativo (em inglês, *Adaptive Filter* - AF), entre outros.

Geralmente, os variáveis extraídas dos sinais são usadas como entradas no sistema de classificação, ao invés do uso da forma de onda do sinal. Deste modo, é necessário um processamento viável computacionalmente e confiável, pois a seleção de um conjunto de variáveis adequadas é um passo importante para a robustez e acurácia do classificador.

Em técnicas de processamento é desejável que as variáveis selecionados possam caracterizar e distinguir classes e, além disso, que elas não sejam correlacionadas e sejam em um pequeno número. Outros problemas que podem ser relevantes são são aqueles relacionados à estabilidade numérica, insensibilidade ao ruído, e a interpretação física do problema (MORAVEJ, 2011).

Em grande parte dos sistemas a contaminação de um sinal por outros indesejados ou por ruído é um problema comum. Existem situações em que o sinal possui características estacionárias e a variável possui uma faixa de frequência bem definida (FERREIRA, 2012). Porém, há casos em que o sinal não é estacionário, sendo necessário a utilização de filtros que se auto ajustam, sendo estes conhecidos como Filtros Adaptativos.


Um Filtro Adaptativo modifica seus coeficientes de acordo com algum critério, se adaptando às mudanças no sinal de entrada (FERREIRA, 2012). Devido à importância da técnica empregada para processamento de dados, este trabalho utilizou um filtro adaptativo.

### **2.5.1 Filtros Adaptativos**

Filtros devem ser implementados para que sejam extraídas informações relevantes à aprendizagem de máquinas e modelagem inteligente. Filtros adaptativos possuem dois componentes importantes, um filtro digital e um algoritmo que ajusta os coeficientes do filtro, chamado de algoritmo de adaptação, como apresentado na Figura 2.3.

Figura 3: Estrutura geral de um filtro adaptativo.





Fonte: Ferreira (2012).

A partir da Figura 4 mostra um sinal digital  $x(n)$  alimentando à entrada do filtro adaptativo e na entrada do algoritmo de adaptação. A saída do filtro é dada por  $y(n)$ . Esse sinal é comparado com um sinal  $d(n)$  chamado de resposta desejada. Na saída, o erro  $e(n)$  realimenta o algoritmo de adaptação. Desse modo, o algoritmo de adaptação é responsável por minimizar o erro para obter o sinal próximo ao desejado.

Segundo Ferreira (2012) os seguintes aspectos devem ser analisados para a escolha do filtro adaptativo, sendo:

- a) Tipo de sinal a ser analisado;
- b) A estrutura que define como o sinal de saída do filtro é calculada a partir do sinal de entrada;
- c) Os parâmetros da estrutura que serão adaptados;
- d) O algoritmo de adaptação que descreve como os parâmetros serão ajustados.

### 2.5.1.1 Filtros adaptativo sintonizado baseado na estimação da frequência

Mojiri et al. (2004) propõe um filtro sintonizado utilizado para estimar uma frequência contida em um sinal periódico, sendo este de natureza não estacionária e ruidosa. Define-se como sinal de entrada um somatório de senóides, conforme (2.5.1).

$$d(t) = \sum_{i=1}^n A_i \text{sen}(i\omega_0 t + \varphi_i) \quad (2.5.1)$$

Sendo:

$A_i$  – Amplitude;

$\omega_0$  – Frequência;

$\varphi_i$  – Defasagem angular.

As equações deste filtro no domínio do tempo são compostas por (SILVA, 2018):

$$\dot{\omega}(t) = -\gamma\omega(t)x_1(t)e(t) \quad (2.5.2)$$

$$\ddot{x}_1(t) = 2\zeta\omega(t)e(t) - \omega^2(t)x_1(t) \quad (2.5.3)$$

$$e(t) = d(t) - \dot{x}_1(t) \quad (2.5.4)$$

sendo:

$\omega(t)$  – Frequência fundamental;

$e(t)$  – Erro;

$d(t)$  – Sinal de entrada;

$\zeta$  – Fator de amortecimento;

$\gamma$  – Ganho adaptativo;

$\dot{x}_1(t)$  – Componente fundamental de  $d(t)$ ;

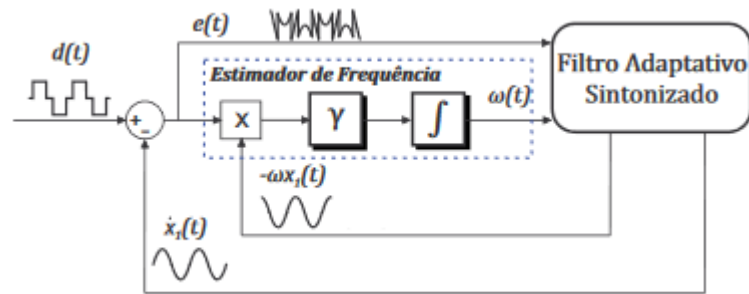
$\ddot{x}_1(t)$  Derivada da componente fundamental de  $d(t)$ .

Ocorrendo a convergência do filtro,  $\dot{x}_1(t)$  será a variável de estado que representará o sinal fundamental, sem os sinais indesejados, os quais foram filtrados.

Tem-se em (2.5.2) a lei de adaptação do estimador de frequência. Em (2.5.3) tem-se a equação diferencial de um filtro ressonante. Por fim, em (2.5.4) tem-se o erro que representa o conteúdo harmônico do sinal de entrada. O parâmetro  $\zeta$  é utilizado para ajustar a banda de passagem do filtro sintonizado e determinar o fator de amortecimento e o parâmetro  $\gamma$  determina a taxa de convergência do estimador de frequência.

Segundo a configuração de entrada, a estrutura utilizada é apresentada na Figura 5.

Figura 4: Diagrama em blocos do algoritmo do filtro adaptativo sintonizado.



Fonte: Ferreira et al. (2014).

Salienta-se que, caso haja necessidade de extrair mais de uma frequência, é preciso utilizar sub-filtros responsáveis por estimar as demais frequências desejadas.

A utilização do Filtro Adaptativo pode fornecer informações confiáveis sobre as componentes fundamentais dos sinais, tornando sua implementação viável para detecção de frequência em sistemas elétricos.

### 2.5.1.1 Aplicação do Filtro Adaptativo

Além da estimação da frequência fundamental da rede elétrica, as variáveis de estado do filtro adaptativo podem ser utilizadas para estimar outros parâmetros da rede elétrica, tais como valores eficaz das componentes fundamentais de tensão e corrente, potências ativa, reativa e aparente fundamental, taxa de distorção harmônica total, entre outros. Para exemplificar estas aplicações, será utilizado um sistema trifásico equilibrado, o qual será detalhado a seguir.

O sistema trifásico equilibrado tem por característica tensões e correntes balanceadas e defasadas em  $120^\circ$ . Assim, uma fase é utilizada como referência para o Filtro Adaptativo e assume-se que as demais fases estão defasadas em  $120^\circ$ . Com isso, primeiramente obtém-se a componente fundamental da tensão, corrente e frequência, as quais podem ser obtidas pelas equações (2.5.2), (2.5.3) e (2.5.4).

A primeira etapa para implementação deste filtro adaptativo é a sua discretização por meio de equações de diferenças. Para tanto, pode-se utilizar a aproximação de Euler, conforme apresentado e justificados por Ferreira, (2012).

Assim, aplicando a aproximação de Euler nas equações (2.5.2) e (2.5.3) tem-se:

$$\omega(n+1) = \omega(n) - \gamma\omega(n)x_1e(n)T \quad (2.5.5)$$

$$\dot{x}_1(n+1) = \dot{x}_1(n) + 2T\zeta\omega(n)e(n) - 1^2T\omega^2(n)x_1(n) \quad (2.5.6)$$

$$x_1(n+1) = x_1(n) + T\dot{x}_1 \quad (2.5.7)$$

$$e(n) = d(n) - \dot{x}_1(n) \quad (2.4.8)$$

A partir do Filtro Adaptativo Sintonizado é possível obter a componente fundamental de  $i_1$  e  $v_1$  e suas componentes  $i_{1_{90^\circ}}$  e  $v_{1_{90^\circ}}$  conforme:

$$v_1 = \dot{x}_{v1} = \sqrt{2} V_1 \text{sen}(\omega_0 t + \varphi_v) \quad (2.5.9)$$

$$v_{1_{90^\circ}} = -\omega x_{v1} = \sqrt{2} V_1 \text{cos}(\omega_0 t + \varphi_v)$$

$$i_1 = \dot{x}_{i1} = \sqrt{2} I_1 \text{sen}(\omega_0 t + \varphi_i) \quad (2.5.10)$$

$$i_{1_{90^\circ}} = -\omega x_{i1} = \sqrt{2} I_1 \text{cos}(\omega_0 t + \varphi_i)$$

sendo  $\dot{x}_{v1}$ ,  $x_{v1}$ ,  $\dot{x}_{i1}$ ,  $x_{i1}$  as saídas do filtro para a tensão e corrente respectivamente e o valor eficaz das mesmas.

A partir das variáveis do filtro, os valores eficazes fundamentais da tensão e corrente  $V_1$ , e  $I_1$ , podem ser obtidos por:

$$V_1 = \sqrt{V_1^2 + V_{1_{90^\circ}}^2} \quad (2.5.11)$$

$$I_1 = \sqrt{I_1^2 + I_{1_{90^\circ}}^2} \quad (2.5.12)$$

a potência ativa e reativa fundamental é obtida por meio da multiplicação da tensão e corrente e suas ortogonais, conforme apresentado por Ferreira (2012), isto é

$$Q_1 = \frac{2}{3} v_1 \cdot i_{1_{90^\circ}} - v_{1_{90^\circ}} \cdot i_1 \quad (2.5.13)$$

$$P_1 = \frac{2}{3} v_{1_{90^\circ}} \cdot i_{1_{90^\circ}} - v_1 \cdot i_1 \quad (2.5.14)$$

onde  $P_1$  é a potência ativa fundamental e  $Q_1$  é a potência reativa fundamental.

Por fim, a componente harmônica da tensão e corrente, pode ser obtida por meio do valor eficaz do erro do filtro adaptativo. Conforme apresentado por Ferreira et al. (2015), o erro do filtro

adaptativo possui as componentes harmônicas do mesmo, podendo-se calcular a tensão harmônica,  $V_h$ , da seguinte maneira:

$$V_h = \frac{1}{n} \sum_{n=1}^N e(n)^2 \quad (2.5.15)$$

As taxa de distorção harmônica da tensão ( $THD_V$ ) é calculada no domínio do tempo, de acordo com a norma IEEE 1459-2010, por:

$$THD_V = \frac{V_h}{V_1} \quad (2.5.16)$$

Para o cálculo da corrente harmônica,  $I_h$ , e da taxa de distorção harmônica,  $THD_I$ , utilizou-se procedimentos análogos àquelas apresentados em (2.5.15) e (2.5.16).

### 3. CONSIDERAÇÕES FINAIS

O ilhamento deve ser detectado logo após sua ocorrência e o sistema de geração distribuída deve ser desligado em seguida. Uma detecção tardia resulta em risco de vida às equipes de manutenção e uma deterioração da qualidade de energia. Assim, algumas normas visam padronizar os parâmetros básicos para a detecção do ilhamento, como o tempo que o sistema deve detectar o ilhamento. Neste trabalho utilizou-se a norma regida pelo Instituto de Engenharia Elétrica e Eletrônica (IEEE) conforme a 1547<sup>TM</sup> IEEE *Standard for Interconnecting Distributed Resources with Electric Power Systems*. O sistema teste apresentado neste trabalho é descrito a seguir.

#### 3.1 Sistema de teste

O estudos de detecção de ilhamento utilizou um projeto de simulação simplificado, o qual foi projetado na ferramenta SIMULINK® do *software* MATLAB®.

O sistema de potência é constituído por uma unidade fotovoltaica, representado a GD, conectada a um conversor eletrônico com filtro indutivo, o qual estão encapsulados no bloco GD, conforme a Figura A.1 no anexo A. Utilizou-se três cargas RLC em paralelo com diferentes valores de potência ativa e reativa no intuito de simular variações de cargas no sistema ao longo do tempo.

A GD foi conectada na rede de distribuição principal no ponto de acoplamento comum e uma chave foi instalada neste ponto com o propósito de simular o ilhamento. Em um determinado tempo, a chave será aberta e apenas a GD irá alimentar as cargas no sistema, caracterizando o ilhamento.

O bloco *s-function* foi utilizado para a simulação de um sistema embarcado com a finalidade de programar o filtro adaptativo, conforme apresentado na seção 2.5.1.1, para estimar as seguintes variáveis:  $THD_V$ ,  $THD_I$ ,  $V_1$ ,  $I_1$ ,  $f$ ,  $P_1$  e  $Q_1$ . Para tal feito, utilizou-se 3 filtros adaptativos, conforme a Figura A.1. Os filtros FA1 e FA2 tem como parâmetros de entrada a medição da tensão e corrente respectivamente, e o filtro FA3 utiliza as informações da saída dos filtros anteriores descritos, para obter as potências desejadas. A Tabela 3.1 apresenta os parâmetros estimados por cada filtro.

Tabela 1 - Parâmetros estimados dos filtros adaptativos.

FA1	FA2	FA3
$THD_V$	$THD_I$	$P_1$
$V_1$	$I_1$	$Q_1$
$f$		

Fonte: Do autor (2019).

### 3.2 Configurações do sistema

Aplicou-se uma frequência de amostragem de 40080 Hz, necessária para discretização dos parâmetros obtidos pelos filtros adaptativos. Configurou-se as chaves das cargas para que fossem desconectadas nos tempos de 1 e 6 segundos e conectada duas nos tempos de 3 e 5 segundos. Uma carga foi fixada durante toda a simulação. Estes tempos foram escolhidos aleatoriamente.

Estipulou-se o tempo de 10 segundos para o ilhamento, o qual o tempo total de simulação foi de 15 segundos.

Para configurar os valores das cargas RLC do sistema, utilizou-se o pior caso para detecção de ilhamento segundo a norma 1547<sup>TM</sup>, em que a carga reativa é balanceada para que a frequência ressonante do circuito ilhado esteja dentro das configurações de disparo e o mais próximo da frequência nominal e ajustou o valor de potência da carga para a mesma fornecida pela GD.

Assim, os valores obtidos para cargas estão listados na Tabela 3.2. Estes valores tiveram como embasamento os utilizados por Mlakić et al. (2019). Na Tabela 3.2.2 estão os parâmetros fornecidos ao DG.

Tabela 2 - Diferentes valores da carga RLC simuladas.

Casos	Q	R [ $\Omega$ ]	L [H]	C [F]
1	1,002852	2.3048	0.0061	0.0012
2	2,008407	2.3048	0.0030	0.0023
3	2,503132	2.3048	0.0024	0.0029
4	3,007963	2.3048	0.0020	0.0035
5	4,012464	2.3048	0.0015	0.0046
6	5,001917	2.3048	0.0012	0.0058

Fonte: Do autor (2019).

Tabela 3 - Parâmetros da DG.

Parâmetro	Valor
Potência	21kW
Tensão L-L	220V
Frequência nominal	60 Hz
Indutância filtro	0.016 F
Resistência filtro	0.89 $\Omega$

Fonte: Do autor (2019).

### 3.3 Método proposto para detecção do ilhamento

Conforme descrito na seção 2.4.2.1, o algoritmo FCM foi utilizado para detecção do ilhamento. Para isso, os seguintes passos foram realizados:

- a) Simulou-se o sistema com os parâmetros da seção 3.2;
- b) Realizou-se a normalização dos dados coletados;
- c) Criou-se uma base de dados com os parâmetros  $THD_V$ ,  $THD_I$ ,  $V_1$ ,  $I_1$ ,  $f$ ,  $P_1$  e  $Q_1$ ;
- d) Definiu-se o número de *clusters*;
- e) Utilizou-se a função do MATLAB® FCM para estimar a matriz de partição e os centros dos *clusters* com a base de dados proposta anteriormente;
- f) Validou-se o modelo;
- g) Caso o modelo não fosse validado, voltava-se ao item d e realizava os passos seguintes.

A partir disso, testou-se vários valores de *cluster* no intuito de encontrar o valor mínimo do critério XB. Deste modo, chegou-se ao modelo com 15 *clusters*.

Após definir o número ideal de 15 *clusters*, calculou-se a acurácia, obtendo 96.98%, o qual é aceitável. Após isso, definiu-se os pesos de cada *cluster*, em que 0 caracterizava o não ilhamento e 1 o ilhamento.

Com o peso de cada *cluster* e os valores dos centers, incluiu-se um bloco S-function conforme a Figura A.2, em anexo, no sistema com o intuito de cadastrar os valores dos centers para utilizá-los na detecção do ilhamento. Posteriormente, utilizou-se a distância Euclidiana entre os



centers e as variáveis propostas, a qual a menor distância caracterizava o *cluster* vencedor e seu peso foi utilizado na saída.

#### 4. REFERÊNCIAS

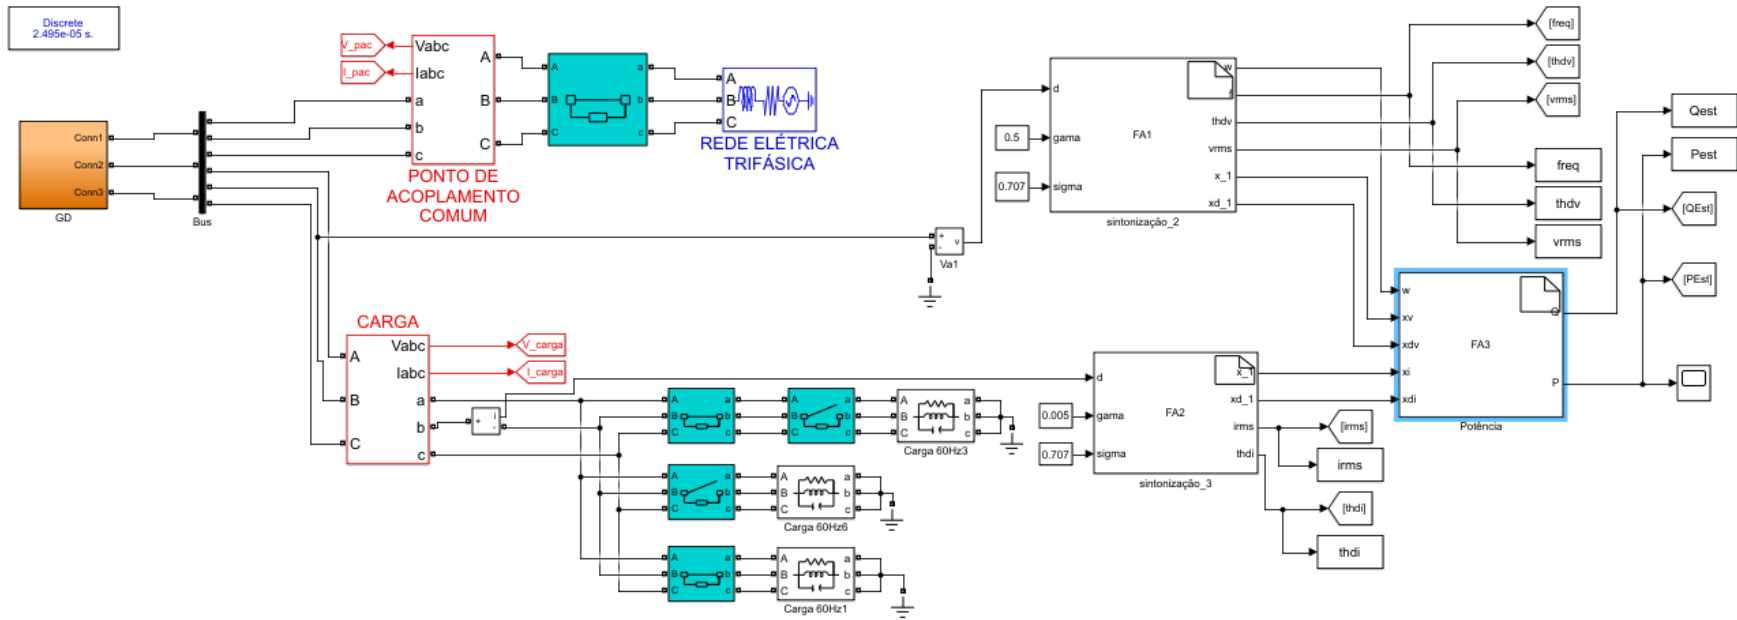
- AGUIAR, C. R. et al. Frequency fuzzy anti-islanding for grid-connected and islanding operation in distributed generation systems. **IET Power Electronics**, v. 8, p. 1255–1262, 15 Agosto 2014.
- BEZDEK, J. C.; EHRLICH, R.; FULL, W. FCM: the fuzzy c-means clustering algorithm. **Computers & Geosciences**, v. 10, p. 191-203, Maio 1983.
- CANNON, R. L.; DAVE, J. V.; BEZDEK, J. C. Efficient Implementation of the Fuzzy c-Means Clusteng Algorntms. **IEEE Transactions on pattern analysis and machine intelligence**, v. 8, p. 248-255, Março 1986.
- CHAKRAVORTI, T.; PATNAIK, R. K.; DASH, P. K. Detection and classification of islanding and power quality disturbances in microgrid using hybrid signal processing and data mining techniques. **IET Signal Process**, v. 12, p. 82-94, Junho 2016.
- DONG, D. et al. Modeling and Design of Islanding Detection Using Phase-Locked Loops in Three-Phase Grid-Interface Power Converters. **IEEE Journal of emerging and select topics in power electronics**, v. 2, n. 4, p. 1032-1040, Dezembro 2014.
- FERREIRA, S. C. **Aplicação de Filtros Adaptativos em Compensadores Híbridos de Reativos**. Universidade Federal de Itajubá. Itajubá, p. 333. 2012.
- FERREIRA, S. C. et al. Filtros Adaptativos Aplicados em Condicionadores de Energia. **Eletrônica de Potência**, Campo Grande, v. 19, p. 377-385, Setembro 2014.
- FERREIRA, S. C. et al. Adaptive Real-time Power Measurement Based on IEEE Standard 1459-2010. **Electric Power Components and Systems**, 2015. 1307-1317.
- GOMES, E. A. P. **Deteção de ilhamento de Geradores síncronos distribuídos por correlações da mineração complexa de dados. Mestrado. São Carlos 2016**. Universidade de São Paulo. São Carlos. 2016.
- HARIRCHI, F. et al. **Advanced Three-Phase Instantaneous Power Theory Feature Extraction for Microgrid Islanding and Synchronized Measurements**. International Conference on Smart Grid Synchronized Measurements and Analytics (SGSMA). Texas: IEEE. 2019. p. 1-8.
- IEEE P1547.1/D7.0. **Draft Standard for Conformance Test Procedures for Equipment Interconnecting Distributed Resources with Electric Power Systems**, New York, 4 maio 2005. 1-77.
- KERMANY, S. D. et al. **IEEE Transactions on Power Systems**, 2016.
- KHOKHAR, S. et al. **Renewable and Sustainable Energy Reviews**, p. 1650–1663, 15 Julho 2015.
- KIM, M.-S. et al. Comprehensive Review of Islanding Detection Methods for Distributed Generation Systems. **Energies**, v. 12, p. 837, Março 2019. ISSN ISSN.

- LAGHARI, J. A. et al. Energy Conversion and Management. **Computational Intelligence based techniques for islanding detection of distributed generation in distribution network: A review**, 7 Setembro 2014. 139–152.
- MAHAT, P.; CHEN, Z.; BAK-JENSEN, B. **Review of Islanding Detection Methods for Distributed Generation**. Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies. Nanjing: [s.n.]. 2008. p. 2743-2748.
- MAHAT, P.; CHEN, Z.; BAK-JENSEN, B. Review of Islanding Detection Methods for Distributed Generation, Nanjing, April 2008. 2743-2748.
- MATIC-CUKA, B.; KEZUNOVIC, M. Islanding Detection for Inverter-Based Distributed Generation Using Support Vector Machine Method. **IEEE TRANSACTIONS ON SMART GRID**, v. 5, p. 2676-2686, Novembro 2014.
- MLAKIĆ, D.; BAGHAEI, H. R.; NIKOLOVSKI, S. IEEE Transactions on smart grid. **A Novel ANFIS-Based Islanding Detection for Inverter-Interfaced Microgrids**, 10, Julho 2019. 4411-4424.
- MOJIRI, M.; BAKHSHAI, A. R. Estimation of n Frequencies Using Adaptive Notch Filter. **IEEE Transactions on Circuits and Systems II: Express Briefs** , v. 54, n. 4, p. 338 - 342, April 2007.
- MORAVEJ, Z.; PAZOKI, M.; ABDOOS, A. A. Application of Signal Processing in Power Quality Monitoring. **Power Quality – Monitoring, Analysis and Enhancement**, p. 77-100, Setembro 2011.
- MOTA, V. C.; DAMASCENO, F. A.; LEITE, D. F. Fuzzy Clustering and Fuzzy Validity Measures for Knowledge Discovery and Decision Making in Agricultural Engineering. **Computers and Electronics in Agriculture**, 24 April 2018. 118-124.
- MOTTER, D. **Modelagem Computacional de Funções de Proteção Baseadas em Medidas de Frequência para Detecção de Ilhamento de Geração Distribuída**. Universidade de São Paulo. São Carlos. 2014.
- PAL, N. R. et al. A Possibilistic Fuzzy c-Means Clustering Algorithm. **IEEE Transactions on fuzzy systems**, v. 13, p. 517-530, Agosto 2005.
- PHAM, J.-P. et al. **Hardware implementation of an islanding detection approach based on current and voltage transients**. IEEE Electrical Power and Energy Conference. Winnipeg: IEEE. 2011. p. 152-157.
- POURYEKTA, A. et al. IEEE SYSTEMS JOURNAL. **Islanding Detection and Enhancement of Microgrid Performance**, 4 dezembro 2018. 3131-3141.
- RAZA, S. et al. Energy Conversion and Management. **Application of signal processing techniques for islanding detection of distributed generation in distribution network: A review**, 6 Março 2015. 613–624.

- REDDY, M. J. B. et al. Smart Fault Location for Smart Grid Operation Using RTUs and Computational Intelligence Techniques. **IEEE SYSTEMS JOURNAL**, v. 8, p. 1260-1271, Fevereiro 2014.
- SALIMI, S.; KOOCHAKI, A.; HAJIZADEH, A. An Effective Index for Islanding Detection Based on Fast Discrete S-Transform. **POWER ENGINEERING AND ELECTRICAL ENGINEERING**, v. 17, p. 127-137, Junho 2019.
- SAMANTARAY, S. R. et al. A Fuzzy Rule-Based Approach for Islanding Detection in Distributed Generation. **IEEE TRANSACTIONS ON POWER DELIVERY**, v. 25, n. 3, p. 1427-1433, Julho 2010.
- SILVA, H. T. D. **Estudo sobre a interação de métodos anti-ilhamento para sistemas fotovoltaicos conectados a rede de distribuição de baixa tensão com múltiplos inversores**. Escola Politécnica da Universidade de São Paulo. São Paulo, p. 132. 2016.
- WU, K.-L.; YANG, M.-S. Pattern Recognition Letters. **A cluster validity index for fuzzy clustering**, 19 Dezembro 2004. 275–1291.
- XIE, X. L.; BENI, G. A validity measure for fuzzy clustering. **IEEE Trans. Pattern Anal. Mach.**, v. 13, p. 841–847, 1991.
- YONAMINE, F. S. et al. **Aprendizado não supervisionado em domínios fuzzy-algoritmo fuzzy c-means**. Universidade Federal de São Carlos. São Carlos, p. 18. 2002.
- ZADEH, L. A. information and control. **Fuzzy sets**, California, 8, 30 Novembro 1965. 338-353.

## A. APÊNDICE


Figura A1: Sistema de simulação.



Fonte: Do autor (2019).

A Figura A1 demonstra um sistema elétrico de potência na qual é constituído de uma fonte principal de energia principal, um bloco GD que simula um gerador fotovoltaico, juntamente com três cargas RLC que possuem chaves para ocorrer a variação de cargas no sistema, simulando uma situação real. Há uma chave conectando a fonte principal com o restante do sistema com o intuito de simular o ilhamento no sistema. Os três blocos *s-function* contêm os algoritmos do filtro adaptativo.

Figura A2: Bloco S-Function para detecção do ilhamento.



Fonte: Do autor (2019).

## **SEGUNDA PARTE – ARTIGO**

### **ARTIGO 1 – MÉTODO DE CLUSTERIZAÇÃO FUZZY C-MEANS PARA DETECÇÃO DE ILHAMENTO EM CONVERSORES ELETRÔNICOS**

Artigo Formatado de Acordo com as Normas do SBSE 2020– Simpósio Brasileiro De Sistemas  
Elétricos.

# Método de clusterização Fuzzy C-Means para Detecção de Ilhamento em Conversores Eletrônicos

D. R. F. Damasceno\*, S. C. Ferreira\*, D. F. Leite\*

\*Universidade Federal de Lavras, Lavras-MG

(e-mail:douglas.r.f.damasceno@gmail.com; silvia.ferreira@ufla.br; daniel.leite@ufla.br).

---

**Abstract:** This paper presents an island detection strategy for microgrids with electronic converters based on an unsupervised clustering algorithm. The method is based on clustering patterns of behaviors uncovered from the data. Voltage and current features were extracted from the power system at the point of common coupling (PCC). These features were used as input to an Adaptive Filter in order to monitor seven variables, namely, frequency (f), effective values of voltage ( $V_1$ ) and current ( $I_1$ ), voltage and current harmonic distortion ( $THD_V$ ) ( $THD_I$ ), active power (P), and reactive power (Q), obtained from a simulations in the SIMULINK® tool of the MATLAB® software. The proposed method used a passive technique aiming not to interfere in the system parameters. In order to obtain realistic situations, the system is simulated with load variations and, in case of islanding, the parameters for the load and maximum detection time are governed by the IEEE 1547 standard. One of the main objectives of this study was to decrease the non-detection zones (NDZs), and to obtain the shortest possible detection time, effectively. The first part of this study consists of a bibliographical review of the topics related to islanding detection, fuzzy systems, clustering, and preprocessing algorithms. In the second part, a paper is presented, in which the methodology and the results are highlighted.

**Resumo:** Este trabalho apresenta uma estratégia de detecção de ilhamento para microrredes com conversores eletrônicos com base em uma técnica de aprendizagem de máquina não supervisionado. O método tem por agrupar padrões de comportamento em amostras do sistema. Foram extraídos do sistema, no ponto de acoplamento comum (PCC), valores de tensão e corrente. Estes dados serviram como entrada para um Filtro Adaptativo no intuito de monitorar sete variáveis, sendo a frequência (f), o valor eficaz da tensão ( $V_1$ ) e da corrente ( $I_1$ ), distorção harmônica total da tensão ( $THD_V$ ) e da corrente ( $THD_I$ ), potência ativa (P) e reativa (Q), obtidas por meio de simulação na ferramenta SIMULINK® do software MATLAB®. O método proposto utilizou a técnica passiva, visando não interferir nos parâmetros do sistema. Com a finalidade de obter situações realísticas, simulou-se o sistema com variações de cargas e, ao ocorrer o ilhamento, os parâmetros para a carga final e o tempo máximo para a detecção foram regidos pela norma IEEE 1547. Uns dos principais objetivos deste trabalho foi diminuir as zonas de não-detecção (ZNDs), e obter o menor tempo e eficiência possível de detecção. A primeira parte deste trabalho consiste em uma revisão bibliográfica dos tópicos relacionados à detecção de ilhamento, sistemas fuzzy, clusterização e algoritmos de pré-processamento. Na segunda parte do trabalho é apresentado um artigo, no qual a metodologia e os resultados são evidenciados.

**Keywords:** Island Detection; Power Converters; Microgrid; Clustering.

**Palavras-chaves:** Detecção de ilhamento; Conversores eletrônicos; Microrrede; Clusterização.

---

## 1. INTRODUÇÃO

Com o avanço tecnológico, a busca por fontes de energia elétrica que proporcionam um menor impacto ambiental tem estimulado a utilização de geradores de energia, podendo ser de pequeno e médio porte que são conectadas aos sistemas de distribuição, sendo chamadas de Gerações Distribuídas (GDs). O seu uso é vantajoso para as concessionárias, proprietários de GDs e consumidor final, pois é viável economicamente e há uma maior confiabilidade no fornecimento. As GDs podem ser do tipo fonte de energia renovável advindas de centrais eólicas, solar, entre outras que possuem baixo impacto ambiental ou por fontes convencionais como geradores a diesel. Os GDs podem ser inseridas em sistemas de energia com o intuito de

reforçar a rede, redução de custos operacionais e diminuição de perdas de energia em horários de maior demanda, confiabilidade, integridade e eficiência do sistema (YADAV, 2014).

Com a inserção das GDs eleva-se a complexidade do sistema necessitando o estudo da operação de ilhamento. Este fato ocorre quando parte da rede elétrica se torna eletricamente isolada da concessionária, porém o subsistema continua energizado pelas GDs, sendo conhecido como ilhamento não intencional. Este é prejudicial ao sistema, tornando sua detecção essencial para prevenir diversos problemas tais como comprometimento da segurança das equipes de manutenção e da população, deterioração da qualidade de energia elétrica, reconexão automática fora de sincronismo, entre outros. Por



isso, a norma IEEE 1547 estabelece um conjunto de critérios e requisitos para a interconexão da GD ao sistema elétrico.

Deste modo, diversos autores implementaram metodologias e paradigmas da inteligência computacional para a detecção do ilhamento. Entre diversas técnicas utilizadas destacam-se a Máquina de Vetores de Suporte, as Redes Neurais Artificiais, controle adaptativo, sistema de interface neuro fuzzy adaptativo. Estes são utilizados devido à padrões existentes no sistema que facilitam sua implementação.

A lógica fuzzy vem se mostrando uma técnica promissora para detecção e classificação de eventos ocorridos na rede elétrica. Os métodos convencionais vêm se tornando obsoletos por apresentarem grandes ZNDs por se tratar de algoritmos que visam detectar por meio de comparação entre as variáveis medidas com limites impostos. Assim, a lógica fuzzy apresenta como vantagem principal um classificador baseado em regras que apresentam uma maior flexibilidade do limite de decisão, tornando adaptável os limites desejados proporcionando ZNDs mínimas.

Este trabalho apresenta uma técnica fuzzy conhecida como clusterização que tem por finalidade fornecer parâmetro para auxiliarem na detecção do ilhamento. Esta técnica consiste em uma classificação não supervisionada de dados, ou seja, classifica os dados em conjuntos que possuem um determinado padrão. O intuito foi encontrar padrões nos sinais medidos que caracterizam o ilhamento. Teve-se como resultado uma detecção de 0.42 segundos. Este tempo foi menor que o tempo mínimo estipulado pela norma IEEE 1547, segundo condições estipuladas pela mesma.

## 2. INTELIGÊNCIA COMPUTACIONAL PARA DETECÇÃO DE ILHAMENTO

As técnicas empregadas para a detecção de ilhamento são classificadas em função de seus princípios operativos. Existem duas classes principais, classificadas em técnica remota e local.

As técnicas remotas possuem em seu fundamento um método de comunicação entre a concessionária, os geradores distribuídos, os dispositivos de segurança e uma determinada interface para a detecção. Estas são eficientes e apresentam uma maior confiabilidade em relação as técnicas locais, porém apresentam custo elevado devido à complexidade de comunicação (MAHAT et al., 2008).

Já as técnicas locais envolvem a detecção usando parâmetros de medidas elétricas no ponto de conexão da GD. As técnicas locais são subdivididas em: passivas, ativas e híbridas. As técnicas passivas são as mais utilizadas para detecção de ilhamento, pois apresentam baixo custo e fácil instalação. Além disso, não necessitam de redes de comunicação e não inserem distúrbios na rede, como é o caso das técnicas ativas e híbridas. Entretanto, podem apresentar zonas de não detecção (ZNDs) devido às pequenas variações nos parâmetros medidos (MOTTER, 2014).

A busca por métodos confiáveis e de baixa complexidade está sendo um desafio na atualidade para detecção do ilhamento. Diversas metodologias e paradigmas da

inteligência computacional já foram utilizados na detecção de forma passiva.

Entre diversas técnicas utilizadas destacam-se a Máquina de Vetores de Suporte (*Support Vector Machine - SVM*), realimentação positiva de frequência baseada em Fuzzy (*Frequency Fuzzy Positive Feedback - FFPF*), transformada de Hilbert modificada em curto prazo (*Short-Time Modified Hilbert Transform - STMHT*), controle adaptativo, sistema de inferência neuro-fuzzy adaptativo (*Adaptive Neuro-Fuzzy Inference System - ANFIS*), entre outros. Essas técnicas buscam minimizar as ZNDs, a complexidade dos algoritmos e o tempo de detecção de ilhamento.

Os autores Samantaray et al. (2010) aplicaram aprendizado de máquina baseado em SVM como método para detecção de ilhamento. Para tal, utilizou-se os valores instantâneos de corrente e tensão, que são processados usando o método de Yule-Walker para cálculo dos coeficientes auto regressivos (AR) e variância nos ruídos. O resultado obtido foi um tempo de 50ms para detecção do ilhamento depois do início do evento.

Outra técnica empregada por Aguiar et al. (2014) foi a realimentação positiva de frequência baseada em fuzzy (FFPF). O principal objetivo foi reduzir a injeção de distúrbios dos métodos de detecção ativos de ilhamento existentes, os quais reduzem a qualidade da energia. Com o intuito de diferenciar a variação da frequência, que pode ser por motivo de ilhamento ou um problema de qualidade de energia, o FFPF permite a diferenciação da condição de ilhamento com outros eventos na rede. Como resultados, houve uma diminuição do tempo de detecção de 80% em relação aos métodos clássicos que utilizam limiares.

Já os autores Chakravorti (2016) apresentaram as técnicas filtro gradiente morfológico de múltipla escala (em inglês, *Multi-Scale Morphological Gradient Filter - MSMGF*) e a transformada modificada de Hilbert de tempo curto (em inglês, *Short-Time Modified Hilbert Transform - STMHT*) que são de detecção e classificação de multiclases de distúrbios em GD baseada em microrrede. Devido à complexidade de diferenciação de padrões de perturbação, utilizou-se uma estrutura de julgamento em árvore fuzzy para a classificação dos eventos multiclases. Como resultado, as técnicas apresentaram uma maior rapidez computacional em comparação com algumas técnicas de processamento de sinais, como a Transformada de Fourier, a Transformada de Hilbert, a Transformada Wavelet, entre outras técnicas utilizadas para detecção de ilhamento.

Outro método proposto em Pouryektá et al. (2018) foi a detecção de ilhamento híbrido, que consiste em um método de detecção remoto e passivo, sendo utilizado um detector de sinal e a taxa de variação da fase de tensão, respectivamente para as técnicas citadas. Após a detecção foi proposta uma estratégia de controle adaptativo para garantir a operação estável de subseções ilhadas. O método utiliza a variação do erro dos parâmetros do sistema, sendo a tensão e potência. Obteve-se como resultado que o método híbrido foi capaz de detectar o ilhamento na presença de várias unidades de geração distribuída. Outro fator foi que o método de detecção de ilhamento não é afetado por variações nas cargas e tipo de

geração e, por fim, a estratégia de controle adaptativo mantém a operação estável da ilha quando ocorre uma falha.

Mlakić et al. (2019) propuseram detecção de ilhamento em microrredes com inversores de baixa tensão com a técnica ANFIS. Foram realizados dois tipos de testes, sendo o primeiro com uma GD e segundo com duas GDs em paralelo. Monitorou-se passivamente sete entradas no ANFIS obtidos no ponto comum de acoplamento com o intuito de diminuir consideravelmente as ZNDs. Como resultados, para o primeiro e segundo teste os autores obtiveram tempos de detecção abaixo de 46ms.

Como alternativa aos métodos anteriores, a lógica fuzzy vem se mostrando uma técnica promissora para detecção e classificação de eventos ocorridos na rede elétrica. Diversos autores têm apresentado pesquisas sobre classificação de distúrbios de Qualidade de Energia Elétrica (QEE) em sistemas ilhados utilizando lógica fuzzy. Entre eles estão: Rede Neuro-Fuzzy (KERMANY et al. 2016); ANFIS (MLAKIĆ et al. 2019); classificador fuzzy (SAMANTARAY, 2010), entre outros.

### 3. MODELAGEM NÃO SUPERVISIONADA FUZZY

A lógica fuzzy foi introduzida por Lotfi Zadeh no início dos anos 1960. Ela possibilita a manipulação de informações vagas, ambíguas e imprecisas e processamento e aprendizado a parti de dados (KIM, 2019).

Geralmente, um determinado conjunto de dados possui uma organização inerente que pode ser separada em  $m$  partições (*clusters*). Para esta separação é possível utilizar algoritmos supervisionados ou não supervisionados. Os algoritmos supervisionados utilizam um determinado conjunto de dados rotulados em que há conhecimento prévio da saída desejada para cada entrada. Dessa forma, é possível ajustar um modelo viabilizando o reconhecimento da saída para rótulos desconhecidos. Entretanto, os processos de rotulagem dos dados podem não ser confiáveis devido à erros de instrumentação ou ruídos no experimento (MOTA et al., 2018).

Os algoritmos não supervisionados, por sua vez, não possuem conhecimento do conjunto de saída para determinadas entradas, portanto não possuem orientação de aprendizado. Assim, os padrões são identificados a partir dos dados de entrada (MOTA et al., 2018).

#### 3.1 Clusterização

Clusterização é uma abordagem de análise de dados que auxilia na resolução de problemas que necessitam de classificação. O objetivo é subdividir um conjunto de dados em subconjuntos (*clusters*). Estes subconjuntos possuem alto grau de associação entre seus elementos e fraco grau de associação referente aos elementos dos demais subconjuntos.

Dado um conjunto de dados  $X$ , um algoritmo de clusterização atribui rotulação aos objetos de um determinado subconjunto no conjunto  $X$ . Isso é possível por meio do uso de uma medida de distância entre os objetos. A partir da medida determina-se os *clusters*, particionando o conjunto de objetos

em  $c$  clusters, tornando os objetos do subconjunto, definido pela medida de distância, altamente associados. As principais medidas de distância usadas nos algoritmos são as normas Manhattan (1 norma), Euclidiana (2 normas), Chebyshev ( $\infty$ -norma) e a distância de Mahalanobis (MOTA et al., 2018).

Há diversos algoritmos baseados em clusterização, os quais podem ser citados o K-Means (KM), Fuzzy C-Means (FCM), Gustafson-Kessel (GK) e Gath-Geva (GG). Os algoritmos são possuem aspectos em comum, porém a diferenciação entre estão relacionados ao método proposto para calcular a distância entre o cluster e o dado mais próximo. Os algoritmos KM e FCM utilizam a distância Euclidiana, o algoritmo GK utiliza distância de Mahalanobis, e o algoritmo GG utiliza a distância Gaussiana.

Este trabalho implementará o algoritmo FCM para a classificação não supervisionada para a detecção do ilhamento.

#### 3.2. Clusterização Fuzzy C-Means

Vários critérios de clusterização foram propostos para identificar partições fuzzy  $c$  em uma determinada base de dados  $X$ . Destes, o mais corriqueiro está associado no erro dos mínimos quadrados generalizados (BEZDEK et al. 1983), dado por:

$$J_m(U, v) = \sum_{k=1}^N \sum_{i=1}^c (u_{ik})^m \|x_k - v_i\|_A^2 \quad (1)$$

Em que:

- $X - \{x_1, x_2, \dots, x_N\} \subset R^n$ ;
- $c - \text{números de clusters em } X (2 \leq c < n)$ ;
- $N - \text{número de amostras}$ ;
- $m - \text{expoente de ponderação } (1 \leq m \leq \infty)$ ;
- $U - \text{partições } c \text{ fuzzy de } X$ ;
- $v - (v_1, v_2, \dots, v_c) \text{ vetor dos centros}$ ;
- $v_i - (v_{i1}, v_{i2}, \dots, v_{in}) \text{ centro do cluster}$ ;
- $\| \|_A - \text{norma matricial induzida } A \in R^n$ ;
- $A - \text{Matriz de covariância}$ .

No FCM, a matriz de covariância é a identidade, o que induz cluster esférico.

A distância ao quadrado entre  $y_k$  e  $v_i$  em (1) é dada pelo produto interno da diferença por meio de:

$$d_{ik}^2 = \|x_k - v_i\|_A^2 = (x_k - v_i)^T A (x_k - v_i) \quad (2)$$

O peso do erro quadrático está associado a  $(u_{ik})^m$ , sendo elevado ao  $m$ -ésimo expoente de ponderação da pertinência de  $x_k$  no cluster  $i$ . Os centros dos clusters são obtidos a partir de

$$v_i = \frac{\sum_{k=1}^N (u_{ki})^m x_k}{\sum_{k=1}^N (u_{ki})^m} \quad (3)$$

Seja uma matriz de partição  $U \in \mathbb{R}^{c \times N}$  constituída de elementos  $u_{ik}$  conforme

$$U = \begin{bmatrix} u_{11} & \cdots & u_{1c} \\ \vdots & \ddots & \vdots \\ u_{N1} & \cdots & u_{Nc} \end{bmatrix} \quad (4)$$

sendo a partição de  $X$ ,  $u_{ki} \in [0,1] \forall k, i$ ;  $\sum_{i=1}^c u_{ki} = 1 \forall k$ ; e  $0 < \sum_{i=1}^N u_{ki} < N \forall i$ . Os elementos da matriz de partição são dados por:

$$u_{ki} = \frac{1}{\sum_{j=1}^c \left( \frac{d_{ki}}{d_{kj}} \right)^{\frac{1}{m-1}}} \quad (5)$$

Os centros dos cluster convergem para um determinado ponto no espaço dos dados quando não há mais variação significativa da matriz de partição observada, ou seja  $\|\Delta U\| < \varepsilon$ , em que  $\varepsilon$  é um limiar (MOTA et al., 2018).

### 3.3. Método de validação

Um índice de validação geralmente é utilizado para definir a qualidade de partições, buscando de uma escolha eficiente dos grupos. Diversos critérios de validação são propostos na literatura, entre eles estão: critério de Xie-Beni (XB), coeficiente de Partição (PC), índice de partição (SC), entre outros.

O índice de validação Xie-Beni foi utilizado para busca dos grupos ideais, pois é uma medida popular para validação. Este é definido como (XIE et al. 1991):

$$XB(c) = \frac{\sum_{i=1}^c \sum_{k=1}^n (u_{ik})^m \|x_k - v_i\|_A^2}{N \min_{v_{k,i}} \|x_k - v_i\|_A^2} \quad (6)$$

O critério tem por finalidade encontrar o valor mínimo, demonstrando os quão compactos e bem separados são os *clusters*.

## 4. PRÉ-PROCESSAMENTO DE DADOS

O processamento de sinal digital diz respeito ao processo de extração de recursos e informações de medições. Esta é uma das partes mais importantes do sistema de reconhecimento de padrões que tem por objetivo caracterizar e distinguir diferentes classes. Várias técnicas de processamento de sinal têm sido utilizadas para extração de recursos, as quais pode-se citar a Transformada de Fourier, a Transformada de Wavelet, o Filtro de Kalman, a Transformada de Hilbert, Filtros Adaptativos, entre outros (KHOKHAR et al. 2015).

Geralmente, os recursos extraídos dos sinais são usados como entradas no sistema de classificação. Deste modo, é necessário um processamento viável computacionalmente e confiável, pois a seleção de um conjunto de recursos adequados é um passo importante para a robustez do classificador (MORAVEJ, 2011).

Ferreira et al. (2015), apresentaram as principais vantagens em utilizar filtros adaptativos na extração de informação dos

sinais da tensão e corrente. Os autores apresentam e comparam duas estruturas de filtros adaptativos para extração das parcelas harmônicas e reativas da corrente.

### 4.1. Filtro Adaptativo Sintonizado Baseado na estimação da frequência

A estrutura dos filtros adaptativos sintonizados com estimador de frequência é apresentada por Mojiri et al. (2007) e Ferreira (2012). As equações no domínio do tempo são dadas por:

$$\dot{\omega}(t) = -\gamma \omega(t) x_1(t) e(t) \quad (7)$$

$$\dot{x}_1(t) = 2\zeta \omega(t) e(t) - \omega^2(t) x_1(t) \quad (8)$$

$$e(t) = d(t) - \hat{x}_1(t) \quad (9)$$

sendo

$\omega(t)$  – Frequência fundamental;

$e(t)$  – Erro;

$d(t)$  – Sinal de entrada;

$\zeta$  – Fator de amortecimento;

$\gamma$  – Ganho adaptativo;

$\hat{x}_1(t)$  – Componente fundamental de  $d(t)$ ;

$\dot{\hat{x}}_1(t)$  – derivada da componente fundamental.

Ocorrendo a convergência do filtro,  $\hat{x}_1(t)$  será a variável de estado que representará o sinal fundamental, sem os sinais indesejados, os quais foram filtrados.

Tem-se em (8) a lei de adaptação do estimador de frequência, em (9) tem-se a equação diferencial de um filtro ressonante e, por fim, em (10) tem-se o erro que representa o conteúdo harmônico do sinal de entrada. O parâmetro  $\zeta$  é utilizado para ajustar a banda de passagem do filtro sintonizado e determinar o fator de amortecimento e o parâmetro  $\gamma$  determina a taxa de convergência do estimador de frequência.

Segundo a configuração de entrada, a estrutura utilizada é apresentada na Fig. 1 (FERREIRA et al. 2014).




Fig. 1: Diagrama em blocos do Algoritmo do Filtro Adaptativo Sintonizado.

Salienta-se que caso haja necessidade de extrair mais de uma frequência, é preciso utilizar sub-filtros responsáveis por estimar as demais frequências desejadas.

Além da estimação da frequência fundamental da rede elétrica, as variáveis de estado do filtro adaptativo podem ser

utilizadas para estimar outros parâmetros da rede elétrica, tais como valores eficazes das componentes fundamentais de tensão e corrente, potências ativa, reativa e aparente fundamental, taxa de distorção harmônica total, entre outros.

Ao aplicar o filtro adaptativo para a tensão é possível obter a componente fundamental ( $v_1$ ) e sua componente ortogonal ( $v_{190^\circ}$ ) da seguinte maneira:

$$v_1 = \hat{x}_{v1} = \sqrt{2} V_1 \text{sen}(\omega t + \varphi_v) \quad (10)$$

$$v_{190^\circ} = -\omega x_{v1} = \sqrt{2} V_1 \text{cos}(\omega t + \varphi_v) \quad (11)$$

onde,  $\varphi_v$  é o ângulo da tensão,  $\hat{x}_{v1}$ ,  $x_{v1}$  e  $V_1$  são as saídas do filtro adaptativo e valor eficaz da tensão, respectivamente. Por meio de (10) e (11), o valor eficaz da tensão é dado por:

$$V_1 = \sqrt{v_1^2 + v_{190^\circ}^2} \quad (12)$$

Para obtenção de  $i_1$ ,  $i_{190^\circ}$  e  $I_1$ , utilizou-se os mesmos procedimentos apresentados em (10), (11) e (12), para variável de corrente.

A potência ativa e reativa fundamental será obtida por meio da multiplicação da tensão e corrente e suas ortogonais conforme apresentado por Ferreira (2012), isto é

$$Q_1 = \frac{2}{3}(v_1 \cdot i_{190^\circ} - v_{190^\circ} \cdot i_1) \quad (13)$$

$$P_1 = \frac{2}{3}(v_{190^\circ} \cdot i_{190^\circ} - v_1 \cdot i_1) \quad (14)$$

onde  $P_1$  é a potência ativa fundamental e  $Q_1$  é a potência reativa fundamental.

O erro do filtro adaptativo possui as componentes harmônicas do mesmo, logo, pode-se calcular a tensão harmônica,  $V_h$ , da seguinte maneira:

$$V_h = \frac{1}{N} \sum_{n=1}^N e(n)^2 \quad (15)$$

A taxa de distorção harmônica da tensão ( $THD_V$ ) é calculada no domínio do tempo, de acordo com a norma IEEE 1459-2010, da seguinte maneira:

$$THD_V = \frac{V_h}{V_1} \quad (16)$$

Para o cálculo da corrente harmônica,  $I_h$ , e da taxa de distorção harmônica,  $THD_I$ , utilizou-se procedimentos análogos àqueles apresentados em (15) e (16).

## 5. METODOLOGIA

### 5.1. Sistema de teste

Para gerar uma base de dados, utilizou-se um projeto de simulação simplificado, o qual foi projetado na ferramenta SIMULINK® do software MATLAB®. O sistema de potência

é constituído por uma geração distribuída conectado à rede conforme apresentado na Fig. 2 adaptada de Mlakić et al. (2019).




Fig. 2: Sistema de testes.

Como pode ser visto na Fig.2, tem-se a GD conectada à rede em paralelo com PAC. Foram utilizadas três cargas RLC com diferentes valores de potência ativa e reativa no intuito de simular variações de cargas no sistema ao longo do tempo. Em cada carga são conectadas chaves para auxiliar na introdução e retirada das cargas no sistema. O controlador tem por objetivo detectar o ilhamento no sistema.

Foi proposta uma frequência de amostragem de 40,08 kHz e um tempo total de 16 segundos. O ilhamento ocorreu no instante de 12 segundos. A GD utilizada tem como parâmetros os apresentados na Tabela 1.

Tabela 1 – Parâmetros do Sistema de Geração Distribuída.

Parâmetros	Valores
Potência	21 kW
Frequência Nominal	60 Hz
Tensão (F-F)	220 V
Indutância Filtro	0.016 H
Resistência Filtro	0.89 Ω

Para configurar os valores das cargas RLC do sistema, empregou-se o pior caso para detecção de ilhamento, segundo a norma IEEE 1547. Nesta condição, os valores de indutância e capacitância são balanceados para que a frequência de ressonância coincida com a frequência fundamental, e a potência ativa requerida coincida com a entregue pela GD. Essas cargas são denominadas filtros sintonizados que são avaliados por um fator de qualidade  $Q$ . O fator de qualidade está relacionado com a largura de banda do filtro sintonizado. De forma que, quanto maior for  $Q$  menor é banda de passagem do mesmo.

Visando padronizar os resultados, foram utilizados seis casos em que se diferenciam nos valores do fator de carga, apresentados por Mlakić et al. (2019). Os valores utilizados estão listados na Tabela 2.

Durante a simulação, foram feitos degraus de carga aleatórios, visando testar a acurácia do algoritmo de detecção de ilhamento. Entretanto, garantiu-se que o ilhamento sempre ocorresse quando apenas as cargas com características ressonantes, Tabela 2, estivessem conectadas à rede elétrica.

Tabela 2 – Diferentes valores da carga RLC ressonantes.

Casos	Q	R [ $\Omega$ ]	L[H]	C[F]
1	1.002852	2.3048	0.0061	0.0012
2	2.008407	2.3048	0.0030	0.0023
3	2.503132	2.3048	0.0024	0.0029
4	3.007963	2.3048	0.0020	0.0035
5	4.012464	2.3048	0.0015	0.0046
6	5.001917	2.3048	0.0012	0.0058

Para finalizar a validação do algoritmo, foram testadas mais duas condições: quando a potência ativa fornecida pela GD não coincide com a requerida pela carga e para cargas com frequência de sintonia diferente de frequência da rede. As condições testadas para variação da potência ativa consideram um aumento e uma diminuição de 25% da potência da carga em relação à gerada pela GD. Já para a variação da frequência de sintonia, a frequência foi de 50Hz nas mesmas condições de potência ativa citadas anteriormente.

### 5.2 Premissas adotadas

Neste trabalho será utilizada como premissa a norma IEEE 1547 que aborda os seguintes parâmetros: fator de qualidade da carga, o tempo de detecção e as faixas operacionais permitidas para a frequência e tensão como descritas na Tabela 3.

Tabela 3 – Padrões para detecção do ilhamento.

Parâmetros	IEEE Std. 1547
Fator de qualidade	Q=1 (Caso 1)
Tempo de detecção	$t < 2s$
Frequência nominal	$59.3Hz \leq f \leq 60.5Hz$
Tensão nominal	$0.88 \leq V(pu) \leq 1.10$

O filtro adaptativo sintonizado utilizado no pré-processamento de dados de tensão de corrente foi ajustado com os parâmetros apresentados na Tabela 4.

Tabela 4 – Parâmetros do Filtro Adaptativo Sintonizado.

Parâmetro	Tensão	Corrente
$\gamma$	0.5	0.005
$\zeta$	0.707	0.707

### 5.3. Método proposto para detecção do ilhamento

O algoritmo FCM foi utilizado para obter os parâmetros necessários para a detecção. Para isso, primeiramente, configurou-se a GD com os parâmetros da Tabela 1. Após isso,

simulou-se o sistema para os seis casos da Tabela 2. Com as variáveis propostas, obtidas pelo filtro adaptativo, foi gerado um banco de dados no intuito de utilizá-lo para obtenção do número de clusters ideal, obtidos pelo algoritmo FCM, para auxiliar na detecção. Para encontrar o número ideal, utilizou-se o critério de XB.

Após isso, obteve-se o número de 15 clusters. A Fig.3 estão os valores obtidos pelo critério de XB.

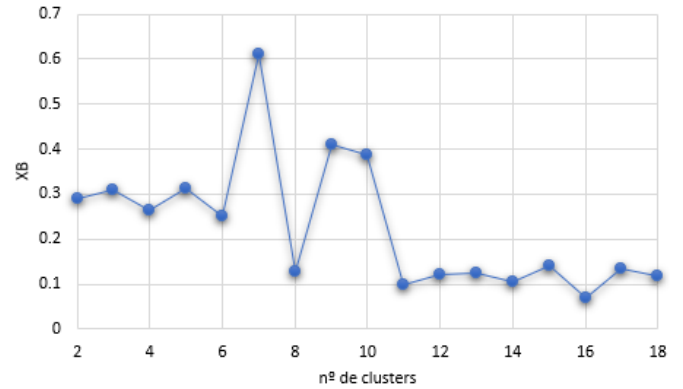


Fig. 3: Critério de XB.

Por fim, calculou-se a acurácia do valor obtido, o qual foi de 96.98%, valor esperado e aceitável. Após isso, definiu-se os pesos de cada cluster, em que 0 caracterizava o não ilhamento e 1 o ilhamento.

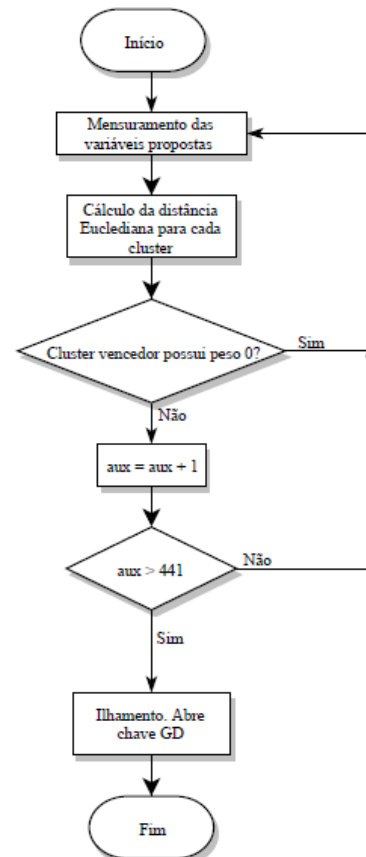


Fig. 4: Fluxograma para detectar o ilhamento.

Com o peso de cada cluster e os valores dos centers, incluiu-se um bloco *s-function* no sistema com o intuito de



cadastrar seus valores para auxiliar na detecção. Posteriormente, utilizou-se a distância Euclidiana entre os centers e as variáveis propostas, com a finalidade encontrar o cluster que possui a menor distância e utilizar na saída do bloco seu peso estimado.

A Fig.4 demonstra um fluxograma detalhando o método utilizado para detectar o ilhamento.

## 6. RESULTADOS

A seguir são apresentados os resultados de simulação da técnica proposta na detecção de ilhamento FCM. As Figuras a seguir apresentam o comportamento das variáveis utilizadas para a detecção de ilhamento para o Caso 1.




Fig. 5a: Frequência.




Fig. 5b: Tensão eficaz.




Fig. 5c: Corrente eficaz.




Fig. 5d: Potência ativa.

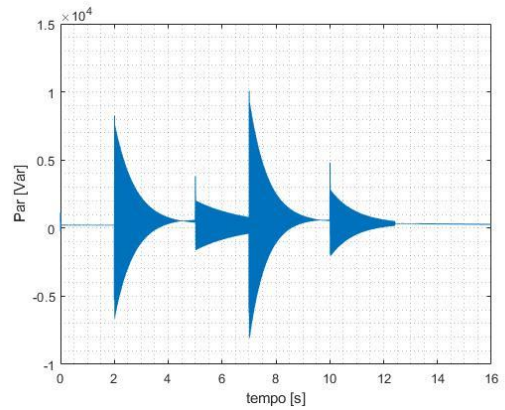


Fig. 5e: Potência reativa.




Fig. 5f: Distorção harmônica total da tensão.




Fig. 5g: Distorção harmônica total da corrente.

A partir das Figuras, nota-se as variações nas variáveis ao longo de toda a simulação. Isto ocorreu pelo fato de haver inserção e retirada de cargas ao longo da simulação a fim de simular um sistema real. Outro fator relevante nota-se que este caso é considerado o mais complexo, pois ao ocorrer o ilhamento em 12 segundos ocorreram pequenas variações nas variáveis, dificultando a detecção.

Para o caso 1, o classificador detectou o ilhamento no tempo de 0.41 segundos. Tempo abaixo dos 2 segundos conforme proposto pela norma IEEE 1547 Tabela 3. Entretanto, se comparado com outros trabalhos, como ANFIS Mlakić et al. (2019) que detectaram o ilhamento em 0.04 segundos, este tempo é relativamente alto. Portanto, como melhoria, alterações nos parâmetros do filtro adaptativo podem ser realizadas no intuito de melhorar o sinal de entrada no classificador.

A Tabela 5 mostra os tempos de detecção para os seis casos simulados. A partir desses resultados, nota-se que os valores obtidos foram

Um fato a ser ressaltado, foi que ao verificar o erro da saída do classificador percebeu-se que havia instantes de tempo em que ocorriam a inserção ou retirada de cargas a saída do classificador ficava intermitente o que ocasionaria uma falsa detecção. Assim, ao comparar a intermitência entre os casos, notou-se que o maior tempo de variação ocorreu no caso 1. Deste modo, este tempo foi utilizado como retardo para a detecção. Este tempo foi de 0.011 segundos equivalente a 441 amostras.

Tabela 5 – Tempos de detecção.

Casos	Tempos [s]
1	0.410
2	0.021
3	0.021
4	0.021
5	0.023
6	0.023

Em seguida, simulou-se o sistema para os casos em que a potência ativa da carga será menor e maior em 25% referente a GD. Esses casos não foram utilizados para obter os pesos dos clusters. Na Tabela 6 estão os resultados obtidos. Nota-se que para esses casos o tempo continuou abaixo do máximo permitido pela norma IEEE 1547 e são próximos aos valores obtidos na Tabela 5, exceto para o caso 1.

Tabela 6 – Resultados para casos em que a potência ativa será diferente.

Casos considerando diferença de 25% da potência ativa	Tempo [s]
Carga > GD	0.034
Carga < GD	0.021

Finalmente, alterou-se o valor da frequência de ressonância da carga para 50Hz e os resultados são apresentados na Tabela 7. Como esperado, estes valores também foram abaixo no máximo permitido pela norma.

Tabela 7 – Resultados para casos em que a potência ativa e a frequência são diferentes.

Casos considerando diferença de 25% da potência ativa	Tempo [s]
Carga > GD	0.033
Carga < GD	0.021

Portanto, ao analisar os tempos das Tabela 5, 6 e 7 nota-se que os valores para dos centers e os pesos dos clusters podem ser utilizados para auxiliar na detecção do ilhamento, por apresentarem acurácia e precisão na detecção.

## 7. CONCLUSÕES

Este estudo avaliou o método de clusterização Fuzzy C-Means para detecção do ilhamento em uma microrrede composta por um conversor eletrônico. O método proposto monitora sete variáveis do sistema que são analisadas constantemente pelo classificador obtido por meio do FCM. Foram testados cenários contendo cargas ressonantes com diferentes valores de fator de qualidade, incluindo o estipulado pela norma IEEE 1547. Foram simuladas diferentes circunstâncias que podem ocorrer em um sistema realístico. Como esperado, os resultados mostraram que o método proposto detectou o ilhamento em tempos abaixo do máximo estipulado pela norma, o qual, para o cenário proposto pela mesma, o tempo máxima para detecção foi de 0,42 segundos, para a carga com fator de qualidade  $Q=1$ . Porém, este tempo mostra-se superior a outros métodos propostos, assim, melhorias foram apresentadas no intuito de diminuir este tempo. O critério de Xie-Beni foi essencial para a obtenção dos clusters, proporcionando acurácia e precisão na detecção. Devido aos fatos, tem-se por objetivo implementar este classificador em um sistema real para analisar seu desempenho.

## 8. REFERÊNCIAS

- BLAZ, B. M.; LOPES T. T.; Marcio Zamboti Fortes; Vitor Hugo Ferreira et al. *Detecção de Ilhamento Não Intencionais em Redes de Distribuição com Geração Distribuída Utilizando Neurais Artificiais*. In: pré-anais: 14º simpósio brasileiro de automação inteligente, 2019, Ouro Preto. Anais eletrônicos... Campinas, GALOÁ, 2019. Disponível em: <<https://proceedings.science/sbai-2019/papers/deteccao-ao-de-ilhamentos-ao-intencionais-em-redes-de-distribuicao-com-geracao-distribuida-utilizando-redes-neurais-arti>>. Acesso em: 02 nov. 2019.
- FERREIRA, S. C. Aplicação de Filtros Adaptativos em Compensadores Híbridos de Reativos. Universidade Federal de Itajubá. Itajubá, p. 333. 2012.
- YADAV, A.; SRIVASTAVA, L. Optimal placement of distributed generation: An overview and key issues. *Power Signals Control and Computation (EPSCICON)*. January, p. 8–10, 2014. Disponível em: <[http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=6887517](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6887517)>.

- FERREIRA, S. C. et al. *Filtros Adaptativos Aplicados em Condicionadores de Energia. Eletrônica de Potência*, Campo Grande, v. 19, p. 377-385, Setembro 2014.
- MOTTER, D. *Modelagem Computacional de Funções de Proteção Baseadas em Medidas de Frequência para Detecção de Ilhamento de Geração Distribuída*. Universidade de São Paulo. São Carlos. 2014.
- MOJIRI, M.; BAKHSHAI, A. R. *Estimation of n Frequencies Using Adaptive Notch Filter*. IEEE Transactions on Circuits and Systems II: Express Briefs, v. 54, n. 4, p. 338 - 342, April 2007.
- KHOKHAR, S. et al. *Renewable and Sustainable Energy Reviews. A Comprehensive Overview on Signal Processing and Artificial Intelligence Techniques Applications in Classification of Power Quality Disturbances*, 15 Julho 2015. 1650–1663.
- MOTA, V. C.; DAMASCENO, F. A.; LEITE, D. F. *Fuzzy Clustering and Fuzzy Validity Measures for Knowledge Discovery and Decision Making in Agricultural Engineering. Computers and Electronics in Agriculture*, 24 April 2018. 118-124.
- MAHAT, P.; CHEN, Z.; BAK-JENSEN, B. *Review of Islanding Detection Methods for Distributed Generation. Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*. Nanjing: [s.n.]. 2008. p. 2743-2748.
- CHAKRAVORTI, T.; PATNAIK, R. K.; DASH, P. K. *Detection and classification of islanding and power quality disturbances in microgrid using hybrid signal processing and data mining techniques*. IET Signal Process, v. 12, p. 82-94, Junho 2016.
- GUTIERRES, L. F. F.; MARCHESAN, G.; CARDOSO, G. *Recloser-fuse coordination protection for distributed generation systems: methodology and priorities for optimal disconnections. 12th IET International Conference on Developments in Power System Protection (DPSP 2014)*. Anais. p.12.68–12.68, 2014. Disponível em: <<http://digital-library.theiet.org/content/conferences/10.1049/cp.2014.0141>>.
- BEZDEK, J. C.; EHRlich, R.; FULL, W. *FCM: The Fuzzy c-means Clustering Algorithm*. Computers & Geosciences, v. 10, p. 191-203, Maio 1983.
- MORAVEJ, Z.; PAZOKI, M.; ABDOOS, A. A. *Application of Signal Processing in Power Quality Monitoring. Power Quality – Monitoring, Analysis and Enhancement*, p. 77-100, Setembro 2011.
- MLAKIĆ, D.; BAGHAEE, H. R.; NIKOLOVSKI, S. *IEEE TRANSACTIONS ON SMART GRID. A Novel ANFIS-Based Islanding Detection for Inverter-Interfaced Microgrids*, 10, Julho 2019. 4411-4424.
- IEEE P1547.1/D7.0. *Draft Standard for Conformance Test Procedures for Equipment Interconnecting Distributed Resources with Electric Power Systems*, New York, 4 maio 2005. 1-77.
- ZADEH, L. A. *information and control. Fuzzy sets*, California, 8, 30 Novembro 1965. 338-353.
- SILVA, H. T. *Estudo sobre a interação de métodos anti-ilhamento para sistemas fotovoltaicos conectados à rede de distribuição de baixa tensão com múltiplos inversores*. São Paulo, 2016.p. 132
- KIM, M.-S. et al. *Comprehensive Review of Islanding Detection Methods for Distributed Generation Systems. Energies*, v. 12, p. 837, Março 2019. ISSN ISSN.
- XIE, X. L. . B. G. *A validity measure for fuzzy clustering*. IEEE Trans. Pattern Anal. Mach, v. 13, p. 841–847, 1991.
- MLAKIĆ, D.; BAGHAEE, H. R.; NIKOLOVSKI, S. *IEEE TRANSACTIONS ON SMART GRID. A Novel ANFIS-Based Islanding Detection for Inverter-Interfaced Microgrids*, 10, Julho 2019. 4411-4424.
- POURYEKTA, A. et al. *IEEE SYSTEMS JOURNAL. Islanding Detection and Enhancement of Microgrid Performance*, 4 dezembro 2018. 3131-3141.
- KERMANY, S. D. et al. *IEEE Transactions on Power Systems. Hybrid Islanding Detection in Microgrid with Multiple Connection Points to Smart Grids using Fuzzy-Neural Network*, 2016.
- SAMANTARAY, S. R. et al. *A Fuzzy Rule-Based Approach for Islanding Detection in Distributed Generation*. IEEE transactions on power delivery, v. 25, n. 3, p. 1427-1433, Julho 2010.
- MATIC-CUKA, B.; KEZUNOVIC, M. *Islanding Detection for Inverter-Based Distributed Generation Using Support Vector Machine Method*. IEEE transaction on smat grid, v. 5, p. 2676-2686, Novembro 2014.
- AGUIAR, C. R. et al. *Frequency fuzzy anti-islanding for grid-connected and islanding operation in distributed generation systems*. IET Power Electronics, v. 8, p. 1255–1262, 15 Agosto 2014.
- MAHAT, P.; CHEN, Z.; BAK-JENSEN, B. *Review of Islanding Detection Methods for Distributed Generation. Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*. Nanjing: [s.n.]. 2008. p. 2743-2748.
- S. C. Ferreira et al., "Adaptive notch filters: Comparison and applications in power conditioning," IECON 2014 - 40th Annual Conference of the IEEE Industrial Electronics Society, Dallas, TX, 2014, pp. 1194-1200.