

Reconhecimento de padrões e classificação não supervisionada baseada em sistemas conexionistas evolutivos

Pattern recognition and unsupervised classification based on evolving connectionist systems

Reconocimiento de criterios y clasificación no supervisada basada en sistemas conectistas evolutivos

Resumo

O reconhecimento de padrões é uma área da ciência cujo objetivo é a classificação de objetos em um número de categorias ou classes. Estes objetos podem ser imagens, formas de onda de sinais ou qualquer tipo de medição que necessita ser distinguida. Na área de sistemas elétricos de potência, com foco em qualidade de energia, o reconhecimento de padrões tem sido cada vez mais usado para detectar e classificar distúrbios que ocorrem nos sinais de tensão e corrente. Estes eventos são chamados de distúrbios de qualidade de energia elétrica e causam prejuízos financeiros tanto às concessionárias de energia quanto aos consumidores. Portanto, a detecção e classificação destes distúrbios são de fundamental importância. Este trabalho apresenta o sistema conexionista evolutivo eCF (*evolving Classifier Function*) para a classificação não supervisionada de distúrbios de qualidade da energia elétrica em sinais de tensão elétrica. Para extração de características indicadoras de presença de distúrbios é considerado um método híbrido composto pelas seguintes técnicas de análise de sinais: filtro Hodrick e Prescott, raiz do valor quadrático médio e transformada rápida de Fourier. Os resultados mostram uma comparação entre o desempenho do eCF e outros classificadores. O modelo eCF obteve acurácia média de 100%.

Palavras-chave: Reconhecimento de padrões. Qualidade de energia elétrica. Sistema conexionista evolutivo. Classificação de distúrbios.

Abstract

Pattern recognition is an area of science whose objective is to classify objects into a number of categories or classes. These objects can be images, wave-form signals, or any measurement that needs to be distinguished. In the area of power systems, with a focus on power quality, pattern recognition has been increasingly used to detect and classify disturbances that occur in voltage and current signals. These events are called power quality disturbances and can cause financial losses to energy utilities and consumers. Therefore, the detection and classification of these disturbances are of fundamental importance. This work presents the evolving connectionist system ECF (evolving Classifier Function) for the unsupervised classification of power quality disturbances in electrical voltage signals. For the extraction of characteristics indicating the presence of disturbances, a hybrid method composed of the following signal analysis techniques is considered: Hodrick and Prescott filter, root mean square, and fast Fourier transform. The results show a comparison between the performance of the ECF and other classifiers. The ECF model obtained an average accuracy of 100%.

Keywords: Pattern recognition. Power quality. Evolving connectionist system. Classification of disturbances.

Resumen

El reconocimiento de criterios es un área de la ciencia cuyo objetivo es la clasificación de objetos en un número de categorías o clases. Estos objetos pueden ser imágenes,

Márcio Wladimir Santana  
marciosantana@cefetmg.br

Stella Marys Dornelas Lamounier  
stella.lamounier@gmail.com

Danielle Abreu Fortunato  
danielle.afortunato@gmail.com

Jader Bôsko Gomes  
jader@cefetmg.br

Israel Teodoro Mendes  
israel@cefetmg.br

formas de onda de señales o cualquier tipo de medición que necesita ser distinguida. En el área de sistemas eléctricos de potencia, con enfoque en calidad de energía, el reconocimiento de criterios está siendo cada vez más utilizado para detectar y clasificar trastornos que ocurren en los señales de tensión y corriente. Estos eventos son llamados de trastornos de calidad de energía eléctrica y causan perjuicios financieros tanto para las concesionarias de energía cuanto para los consumidores. Por lo tanto, la detección y clasificación de estos trastornos son de fundamental importancia. Este trabajo presenta el sistema conectista evolutivo eCF (evolving Classifier Function) para la clasificación no supervisada de trastornos de calidad de la energía eléctrica en señales de tensión eléctrica. Para extracción de características indicadoras de presencia de trastornos es considerado un método híbrido compuesto por las siguientes técnicas de análisis de señales: filtro Hodrick y Prescott, raíz del valor cuadrático medio y transformada rápida de Fournier. Los resultados muestran una comparación entre e rendimiento del eCF y otros clasificadores. El modelo eCF obtuvo precisión media de 100%.

Palabras clave: Reconocimiento de criterios. Calidad de energía eléctrica. Sistema conectista evolutivo. Clasificación de trastornos.

1 Introdução

Conforme Theodoridis e Koutroubas (1999), o reconhecimento de padrões é uma área da ciência cujo objetivo é a classificação de objetos em um número de categorias ou classes. Nos seres humanos reconhecer padrões é uma característica nata. Somos capazes de reconhecer expressões, sons e estado de humor de pessoas do nosso convívio. Nosso grau de refinamento no reconhecimento de padrões pode ser capaz de distinguir uma pintura autêntica daquela feita por um falsário ou pode tomar decisões para compra ou venda de contratos no mercado futuro. Portanto, conclui-se que interpretamos tudo o que nos cerca através de padrões e, a partir desta interpretação, tomamos nossas decisões. Além disso, essa aptidão para o reconhecimento de padrões está diretamente ligada às informações que as pessoas tiveram contato. Atualmente, o grande desafio na área de sistemas inteligentes é desenvolver algoritmos com essa aptidão de reconhecimento dos seres humanos (MARQUES, 1999; THEODORIDIS; KOUTROUBAS, 1999; TOU, 2018).

De acordo com Tou (2018), padrões são características que tornam possível associar informações similares em uma mesma classe. Define-se classe como sendo um conjunto de características comuns dos objetos em estudo. Desta forma, reconhecer padrões é um procedimento que procura identificar características nas informações de entrada de um sistema e comparar com características conhecidas para realizar a classificação destes objetos. Conceitualmente, o grau de compatibilidade ou semelhança entre os atributos (características) deve ser consideravelmente maior entre dados da mesma categoria, definindo assim uma classe. Normalmente, as informações de entrada (dados de entrada) são coletadas a partir de sensores, passando, posteriormente, por um pré-processamento, a fim de evidenciar as características de cada classe e, também, para redução da dimensionalidade dos dados de entrada, com o objetivo de melhorar a performance do classificador (MARQUES, 1999; THEODORIDIS; KOUTROUBAS, 1999; PAL; WANG, 2017).

Os sistemas de reconhecimento de padrões podem ser divididos da seguinte forma: representação das informações de entrada, extração de atributos e classificação. Na primeira etapa estimam-se os dados de entrada através de sensores específicos que possibilitam descrever as melhores informações sobre o objeto de estudo. Na segunda etapa ocorre a extração de atributos e pré-processamento destes dados, como, por exemplo, a utilização de filtros e técnicas de redução de dimensionalidade da matriz de dados que será apresentada ao classificador. Na terceira etapa tem-se o projeto do classificador do sistema, cuja formulação pode ser realizada independentemente das particularidades do objeto de pesquisa (MARQUES, 1999; THEODORIDIS; KOUTROUBAS, 1999; TOU, 2018; PAL; WANG, 2017).

Na área de sistemas de energia elétrica, o reconhecimento de padrões tem sido amplamente utilizado para diferentes fins. Para detecção e classificação, destacam-se os trabalhos de Ferreira, De Seixas e Cerqueira (2015), que usaram um método baseado na análise de componentes independentes de canal único, para classificação de múltiplos distúrbios de qualidade de energia elétrica (QEE); Behera e Nayak (2012) que usaram a transformada S para extrair parâmetros e sistemas *fuzzy* e *neuro-fuzzy* na etapa de classificação dos distúrbios de QEE; Ferreira *et al.* (2014) que usaram uma abordagem direta, baseada em *curvas principais*, para a detecção de distúrbios de qualidade de energia; Lazzaretti, Ferreira e Vieira Neto (2016) que usaram um método de clusterização não supervisionado para detectar e classificar novos eventos de QEE, entre outros. Portanto, rotinas de classificação de distúrbios devem ser projetadas para tratar novidades nos padrões dos dados. Estas novidades precisam ser detectadas e armazenadas em sistemas autoajustáveis em modo on-line (GARCIA *et al.*, 2019; SILVA *et al.*, 2018; SOARES *et al.*, 2019; LEITE *et al.*, 2016).

Neste contexto, ressalta-se a importância de sistemas de monitoramento da QEE visando detectar e classificar novos eventos e, posteriormente, determinar suas causas e consequências. Portanto, os objetivos desse trabalho são detectar e classificar distúrbios em sistemas elétricos de potência em modo on-line e em tempo real. Este processo deve apresentar alto desempenho e baixo custo computacional. Em particular, é considerado o sistema conexionista evolutivo eCF (*Evolving Classifier Function*) como classificador (GOH; SONG; KASABOV, 2004). Assim, como a base de regras do modelo eCF se modifica (evolui) de acordo com o fluxo de dados on-line, ele é capaz de identificar distúrbios não previstos que poderão ocorrer nas redes de energia elétrica, sendo esta uma clara contribuição ao estudo de distúrbios de QEE.

Estudos têm mostrado que algoritmos de clusterização evolutiva processam dados contendo dezenas de valores em cerca de 5 a 10 milissegundos (por amostra) em computadores comerciais (GARCIA *et al.*, 2019; SOARES *et al.*, 2019). Um artigo tipo *survey* recente aponta a área de sistemas inteligentes evolutivos como uma área bastante promissora para lidar com grandes bases de dados (*big data*) em ambientes dinâmicos e sujeitos a novidades (ŠKRJANC *et al.*, 2019). Neste trabalho são abordados os seguintes distúrbios de QEE: *spike*, *notch*, transitório oscilatório, harmônicos, inter-harmônicos, sub-harmônicos, *sag*, *swell*, e interrupção curta. Detalhes sobre cada tipo de distúrbio podem ser vistos em Dugan *et al.* (2012).

Após este breve item introdutório, no item 2 descreve-se o sistema evolutivo que é levado em consideração para tratar o problema de classificação de distúrbios, bem como os modelos que são considerados para a extração de parâmetros dos sinais elétricos com distúrbios de QEE. No item 3 é descrita a metodologia a partir de uma explanação sobre a composição da base de dados e detalhe sobre o fluxograma que conecta os métodos e abordagens de extração de atributos e classificação de padrões descritos nos itens anteriores. No item 4 relacionam-se os resultados obtidos com a aplicação da abordagem evolutiva eCF na classificação dos distúrbios elétricos. Este item apresenta, ainda, avaliações de desempenho e acurácia considerando o método apresentado e outros métodos da literatura da área. No item 5 está a conclusão do trabalho e propostas de trabalhos futuros.

2 Sistema Evolutivo

2.1 Filtro Hodrick-Prescott

O filtro Hodrick-Prescott, ou somente filtro HP, é um modelo matemático usado em economia para extrair a componente cíclica de uma série temporal. O objetivo principal é a obtenção de uma curva mais suavizada da série temporal em análise, que é mais sensível a longo prazo do que as oscilações de curto prazo. (HODRICK; PRESCOTT, 1997; FORTUNATO; SANTANA; GOMES, 2019). Com a aplicação do filtro Hodrick-Prescott, objetiva-se retirar a componente de tendência da série temporal, considerada estocástica, mas com variações suaves ao longo do tempo e não correlacionada com a componente cíclica, através da minimização de:

$$j = \min \sum_{t=1}^T c_t^2 + \lambda \sum_{t=3}^T (\Delta^2 \tau_t)^2, \quad (1)$$

onde $c_t \triangleq y_t - \tau_t$ e $\Delta^2 = (1 - L)^2$, e L o operador de defasagens $Lx_t = x_{t-1}$.

O primeiro termo da equação é a soma dos desvios quadrados, que penaliza a componente cíclica. O segundo termo é um múltiplo de lambda da soma dos quadrados das segundas diferenças da componente de tendência. Este segundo termo penaliza as variações na taxa de crescimento da componente de tendência. Quanto maior o valor de lambda, maior é a penalidade. Hodrick e Prescott sugerem 1600 como um valor para lambda para dados trimestrais (HODRICK; PRESCOTT, 1997). Ravn e Uhlig (2022) ressaltam que lambda deve variar pela quarta potência da razão de observação da frequência.

2.2 Raiz do Valor Quadrático Médio

A raiz do valor quadrático médio (valor RMS – *Root Mean Square*) é uma medida estatística da magnitude de uma quantidade variável no tempo. O cálculo do valor RMS pode ser realizado tanto para uma função discreta ou contínua. O valor eficaz ou RMS da tensão de um sinal elétrico é um parâmetro eficaz na detecção e classificação de distúrbios de qualidade de energia, especialmente aqueles que se caracterizam por gerarem grandes variações na amplitude do sinal, como subtensões, sobretensão e interrupções de curta duração (BALOUJI; SALOR, 2016; FORTUNATO; SANTANA; GOMES, 2019).

O valor RMS de um sinal x para N valores $[x_1, x_2, \dots, x_N]$ é:

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}, \quad (2)$$

onde N é o número de amostras.

Para uma função contínua, $f(t)$, com intervalo $T_1 \leq t \leq T_2$, o valor eficaz de um sinal é dado por:

$$x_{RMS} = \sqrt{\frac{1}{T_2 - T_1} \int_{T_1}^{T_2} [f(t)]^2 dt}. \quad (3)$$

2.3 Transformada Rápida de Fourier

A Transformada Rápida de Fourier (FFT – *Fast Fourier Transform*) é um modelo matemático bastante utilizado e eficiente na análise de sinais no domínio da frequência. Qualquer sinal periódico pode ser descrito por um somatório de senos e cossenos. Existem duas abordagens para análise do espectro de frequências de um sinal: (i) analisa-se uma função contínua no tempo; e (ii) dispõe-se de uma função discreta, ou seja, com dados mensurados. Para estes casos, pode-se utilizar a Transformada de Fourier Contínua e a Transformada de Fourier Discreta. As relações representam as definições da Transformada de Fourier Contínua e sua inversa; e concernem às definições da Transformada de Fourier Discreta e sua inversa (LATHI, 2006).

$$F(j\omega) = \int_0^{\infty} f(t)e^{-j\omega t} dt, \quad (4)$$

$$F(j\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(j\omega)e^{j\omega t} d\omega, \quad (5)$$

$$TFD(f_n) = \frac{1}{N} \sum_{k=0}^{N-1} x_k e^{-j2\pi f_n k \Delta t}, \quad (6)$$

$$x_k = \frac{1}{\Delta t} \sum_{f_n=0}^{(1-N)/T} TFD(f_n) e^{j2\pi f_n k \Delta t}, \quad (7)$$

onde ω representa a frequência angular; x_k representa o sinal discreto; T representa o intervalo de tempo total; ΔT são os intervalos discretos de tempo; $N=T/(\Delta T)$ representa o número de amostras; $cf_n = n/T$, $n=0,1,2,\dots, N-1$ e, representam as componentes discretas de frequência.

A Transformada Discreta de Fourier (DFT – *Discrete Fourier Transforms*) é muito utilizada, neste contexto, objetivando a determinação dos valores da amplitude e da fase da componente fundamental do sinal. A Transformada Rápida de Fourier é um algoritmo que calcula a Transformada discreta de Fourier (DFT) e a sua inversa (Teorema inverso de Fourier). A análise de Fourier converte um sinal do domínio original para uma representação no domínio da frequência e vice-versa. Desta forma, é possível calcular os valores da amplitude da componente fundamental e dos harmônicos de maneira precisa e rápida. O bom desempenho da Transformada Rápida de Fourier é observado no cálculo da amplitude, fase e resolução em frequência de sinais quando considerada uma janela de dados maior para a análise (LATHI, 2006; NYQUIST, 1928).

2.4 Evolving Classifier Function

Os sistemas conexionistas evolutivos (ECOS – *evolving Connectionist Systems*) são sistemas que evoluem sua estrutura e parâmetros ao longo do tempo a partir de fluxo de dados (KASABOV, 2003). O modelo eCF (*evolving Classifier Function*) (GOH; SONG; KASABOV, 2004), que é novidade para análise de distúrbios de QEE, é um sistema conexionista para tarefas de classificação que consiste em quatro camadas de neurônios. A primeira camada representa as variáveis de entrada; a segunda camada representa as funções de pertinência *fuzzy*; a terceira camada representa centros de *clusters* (nós) de dados no espaço de entrada; e a quarta camada representa as classes. O algoritmo de aprendizado do eCF é o seguinte:

Passo 1. Se todos os vetores foram inseridos, termine a iteração atual; caso contrário, insira um vetor do conjunto de dados e calcule as distâncias entre o vetor e todas as regras de nós já criadas usando a distância euclidiana por padrão.

Passo 2. Se todas as distâncias forem maiores que o parâmetro *max-radius*, uma nova regra de nó será criada. A posição da nova regra de nó é a mesma do vetor atual no espaço de dados de entrada e o raio de seu *cluster* receptivo é configurado para o parâmetro *min-radius*; o algoritmo vai para o passo 1; caso contrário, vai para o próximo passo;

Passo 3. Se houver uma regra de nó com uma distância do vetor de entrada atual menor ou igual ao seu raio e sua classe for a mesma que a classe do novo vetor, nada será alterado; vá para o passo 1; de outra forma;

Passo 4. Se houver uma regra de nó com uma distância do vetor de entrada menor ou igual ao seu raio e sua classe for diferente daquela do vetor de entrada, seu *cluster* de influência deverá ser reduzido. O raio do novo *cluster* é ajustado para o valor maior dos dois números: *distance minus the min-radius*; *min-radius*. Novo nó é criado como em (2) para representar o novo vetor de dados;

Passo 5. Se houver uma regra de nó com uma distância até o vetor de entrada menor ou igual ao raio máximo e sua classe for a mesma dos vetores de entrada, aumente o *cluster* de influência tomando a distância como um novo raio se somente esse *cluster* ampliado não cobre nenhuma outra regra de nó que pertença a uma classe diferente; caso contrário, crie uma regra de nó da mesma maneira que na etapa 2 e vá para a etapa 1.

O procedimento de *recall* (classificação de um novo vetor de entrada) no eCF treinado é realizado da seguinte maneira:

Passo 1. Se o novo vetor de entrada estiver dentro do *cluster* de uma ou mais regras de nós associadas a uma classe, o vetor será classificado nessa classe;

Passo 2. Se o vetor de entrada estiver nos *clusters* de duas ou mais regras de nós associadas a classes diferentes, o vetor pertencerá à classe correspondente à regra de nó mais próxima;

Passo 3. Se o vetor de entrada não estiver em nenhum *cluster*, haverá dois casos: (i) modo *one-of-n*: o vetor pertencerá à classe correspondente à regra de nó mais próxima; (ii) modo *m-of-n*: pegue *m* mais alto ativado pelas novas regras de nós de vetor e calcule as distâncias médias do vetor para os nós com a mesma classe; o vetor pertencerá à classe correspondente à menor distância média.

O modelo eCF usado neste trabalho possui os seguintes valores de parâmetros: MaxField = 1,0 ; MinField = 0,01; número de funções de associação MF = 2 (não é função de pertinência *fuzzy*); número de regras de nós de usadas para calcular o valor de saída do eCF quando um novo vetor de entrada é apresentado MofN = 3 (número de vizinhos a serem considerados ao avaliar o nó mais próximo); número de iterações para apresentar cada vetor de entrada *Épocas* = 4.

3 Metodologia

3.1 Base de Dados

Conforme no trabalho de Santana, Fortunato e Ferreira (2018), os sinais de tensão foram gerados de forma sintética e de acordo com a regulamentação do *Institute of Electrical and Electronics Engineers* (IEEE, 2009). Os sinais gerados apresentam frequência fundamental de 60Hz. A frequência de amostragem escolhida foi de 15360Hz. Portanto, 256 amostras por ciclo são obtidas. Essa taxa de amostragem foi escolhida por ser suficiente para caracterizar a maioria dos distúrbios presentes nos sistemas de energia elétrica (NYQUIST, 2002). Os sinais sintéticos foram gerados pelo *software* MatLab® 2014 (uso acadêmico-individual) e são contaminados por ruído branco gaussiano com média nula. O ruído branco foi definido de modo que atenda a relação sinal-ruído (SNR – *signal-to-noise ratio*) desejada:

$$SNR = 20 \log \frac{A}{\sqrt{2}\sigma} [dB], \quad (8)$$

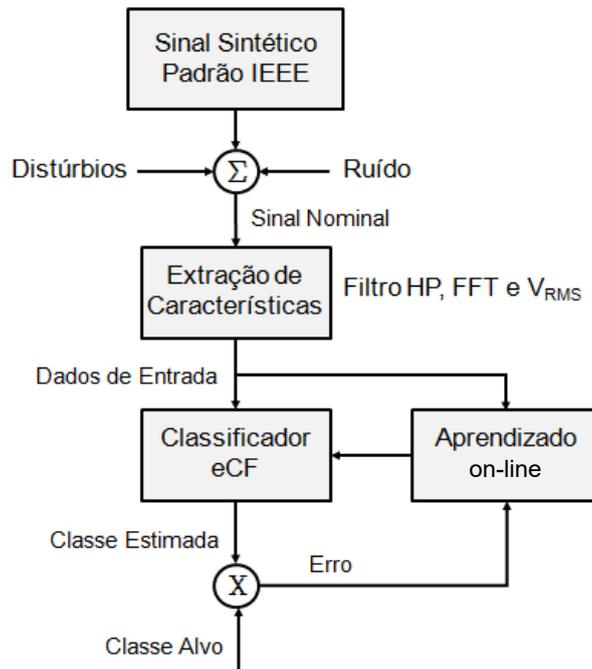
onde A é a amplitude do sinal fundamental e σ é o desvio padrão do ruído.

Ressalta-se que sinais de tensão reais dos sistemas elétricos possuem relação sinal-ruído entre 50 dB e 70 dB (TOMIC; KUSLJEVIC; VUJICIC, 2007). Neste artigo são utilizadas as seguintes relações sinal-ruído: 20dB, 30 dB, 40 dB, 50 dB e 60 dB. O objetivo de se utilizar esta ampla faixa de SNR é verificar o comportamento do modelo proposto com a presença de altos níveis de ruído no sinal sintético gerado. Quanto menor a SNR maior é a potência do ruído presente no sinal e mais difícil é a extração de características e, conseqüentemente, é mais desafiador realizar a classificação. Foram gerados 2000 sinais para cada valor de relação sinal-ruído, sendo 200 eventos para cada classe. Considerou-se 10 ciclos da senoide como janela de análise para todos os eventos. As características de cada evento de QEE – como amplitude, fase, frequência – são atribuídas de maneira aleatória em intervalos com distribuição uniforme. As amplitudes adotadas neste trabalho são normalizadas, ou seja, a tensão de pico nominal tem valor unitário. A fase é atribuída aleatoriamente, dentro do intervalo com distribuição uniforme (SANTANA; FORTUNATO; FERREIRA, 2018; FORTUNATO; SANTANA; GOMES, 2019).

3.2 Sistema de Reconhecimento de Padrões

Os sistemas de reconhecimento de padrões compreendem, de maneira genérica, a obtenção de características que evidenciam cada classe e a aplicação de uma rotina que realize a classificação baseada nos dados de entrada. Conforme abordado nos itens anteriores, a obtenção das variáveis indicadoras de distúrbios (extração de características) foi realizada a partir das seguintes ferramentas: filtro HP, FFT e valor eficaz. O projeto do classificador foi realizado em modo on-line e a partir de um fluxo de dados. O diagrama em blocos do modelo de monitoramento proposto é ilustrado pela Figura 1. O vetor a ser processado pelo classificador é chamado de “Dados de Entrada”, resultante do pré-processamento do sinal sintético acrescido de distúrbio e ruído, ou seja, o chamado “Sinal Nominal”. Os dados de entrada foram normalizados e embaralhados para melhor desempenho do classificador (SANTANA; FORTUNATO; FERREIRA, 2018; FORTUNATO; SANTANA; GOMES, 2019).

Figura 1 – Modelo de monitoramento proposto

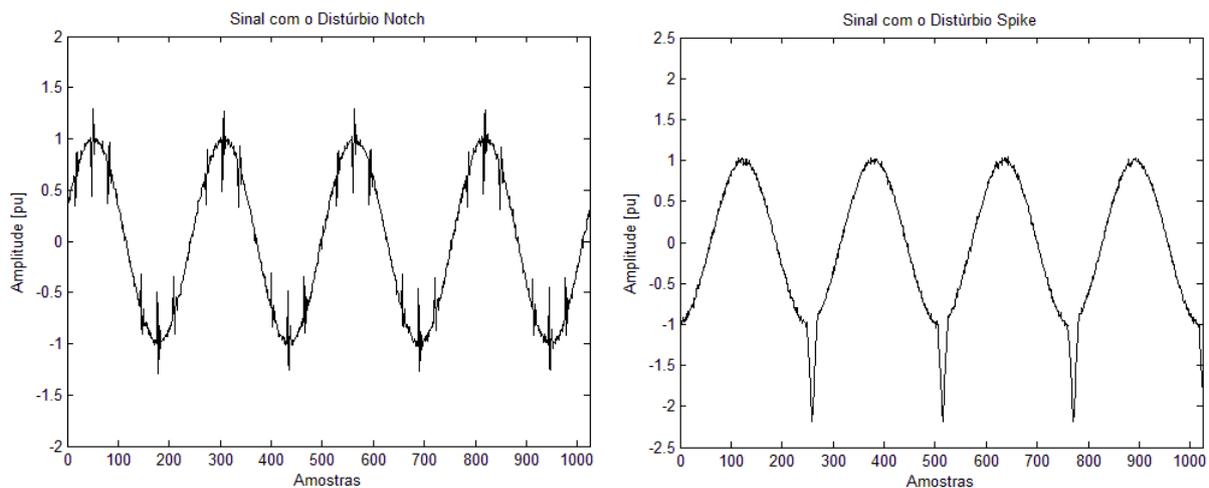


Fonte: Elaborado pelos autores, 2020.

3.3 Aplicação do Filtro HP

A Figura 2 apresenta dois sinais elétricos típicos com frequência fundamental de 60 Hz, amplitude de 1 pu e SNR de 30 dB. Porém, os sinais estão contaminados com os distúrbios *notch* e *spike*, respectivamente, a se ver. Conforme Dugan (2012), o *notch* é um distúrbio de tensão causado pela operação normal de equipamentos de eletrônica de potência quando a corrente é comutada de uma fase para outra. Este fenômeno pode ser detectado por meio do conteúdo harmônico da tensão afetada. O *spike* é um transitório formado por uma rápida elevação da tensão, seguida de uma diminuição da tensão, ambos da ordem de micro ou milissegundos. A elevação de tensão atinge amplitudes que vão de uma e meia a quatro vezes a tensão nominal e a diminuição da tensão pode atingir até metade da tensão nominal, podendo ser esporádico ou periódico. Assim, o chaveamento de cargas indutivas é a sua principal causa (DUGAN *et al.*, 2012).

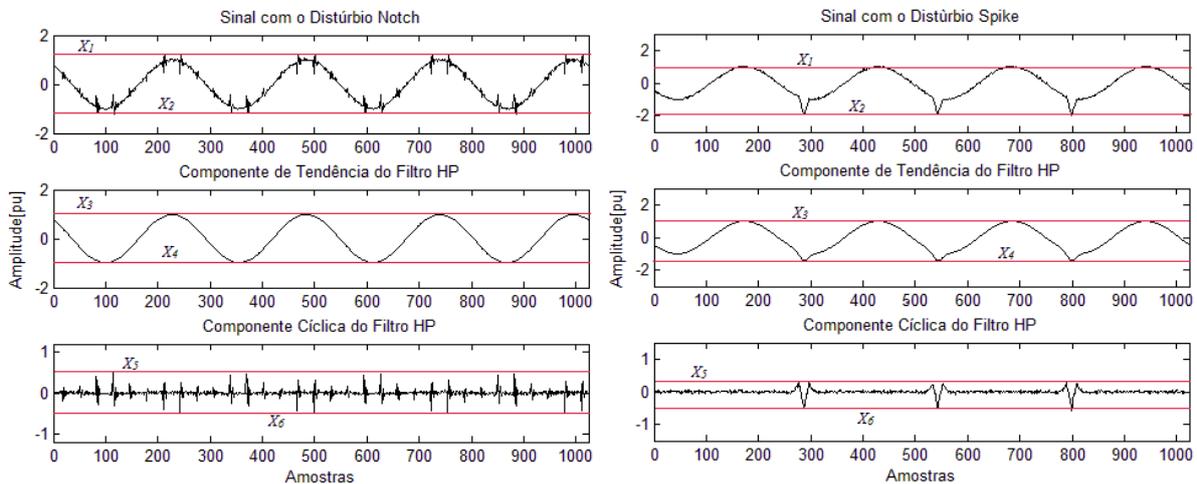
Figura 2 – Sinais contaminados com os distúrbios *notch* e *spike*



Fonte: Elaborado pelos autores, 2020.

A Figura 3 apresenta a aplicação do filtro HP para os distúrbios *notch* e *spike*. O filtro decompõe o sinal nominal em duas componentes: tendência e cíclica. Os parâmetros (características) que foram extraídos são: amplitudes máxima e mínima do sinal nominal; amplitudes máxima e mínima da componente de tendência do filtro HP; e amplitudes máxima e mínima da componente cíclica do filtro HP. São os seis primeiros parâmetros do vetor de entrada ($X_1, X_2, X_3, X_4, X_5, X_6$).

Figura 3 – Filtro HP aplicado aos distúrbios *notch* e *spike*



Fonte: Elaborado pelos autores, 2020.

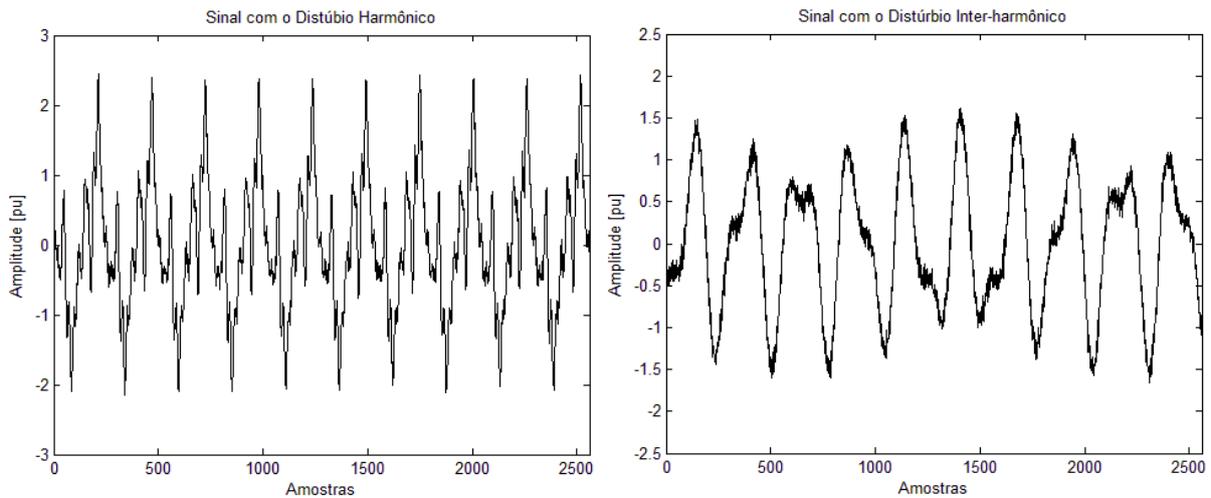
Nota-se pela Figura 3 que o ruído (componente de alta frequência) apresentou-se na componente cíclica, assim como os *notchs* e os *spikes*, que também são componentes de alta frequência (geralmente entre 3,0 kHz e 5,0 kHz). Na componente de tendência, apresentou-se o sinal de frequência fundamental em 60 Hz sem distúrbio e sem ruído também. Para exemplificar e comparar a aplicação do filtro HP, considerou-se os dois distúrbios nas mesmas condições de relação sinal-ruído e amplitude. Percebe-se na Figura 3, na componente cíclica do filtro HP, que os padrões extraídos nos dados são diferentes, ou seja, os parâmetros (X_5, X_6) de cada distúrbio são distintos (FORTUNATO; SANTANA; GOMES, 2019).

3.4 Aplicação do Valor Eficaz

Neste trabalho os valores eficazes do sinal nominal, da componente de tendência do filtro HP e da componente cíclica do filtro HP foram utilizados como parâmetros analisados pelo detector/classificador proposto. São os próximos três parâmetros do vetor de entrada (X_7, X_8, X_9). Nos sinais com deformação da forma de onda (harmônicos, inter-harmônicos e sub-harmônicos) ou com variação da amplitude (*sag*, *swell* e interrupção curta) o valor eficaz da tensão se altera, justificando-se, assim, sua aplicação.

A Figura 4 apresenta dois sinais elétricos com frequência fundamental de 60 Hz, amplitude de 1 pu e SNR de 20 dB. Porém, os sinais estão contaminados com os distúrbios harmônico e inter-harmônico, respectivamente. De acordo com Dugan (2012), os harmônicos são componentes de tensões ou correntes senoidais, com frequências que são múltiplos inteiros da frequência na qual o sistema de energia elétrica é projetado para operar, denominada frequência fundamental. Formas de onda periodicamente distorcidas podem ser decompostas em uma soma da frequência fundamental e dos harmônicos. Tensões ou correntes – tendo componentes de frequência que não são múltiplos inteiros da frequência na qual o sistema de fornecimento – são projetados para operar, bem como são chamados inter-harmônicos. As principais fontes de distorção da forma de onda inter-harmônica são *conversores de frequência estáticos*, fornos de indução e dispositivos a arco. Os sinais comunicação via rede elétrica (PLC – *Power Line Communication*) também podem ser considerados como inter-harmônicos. Inter-harmônicos com frequência abaixo da frequência fundamental do sistema de energia são chamados, também, de sub-harmônicos (DUGAN *et al.*, 2012).

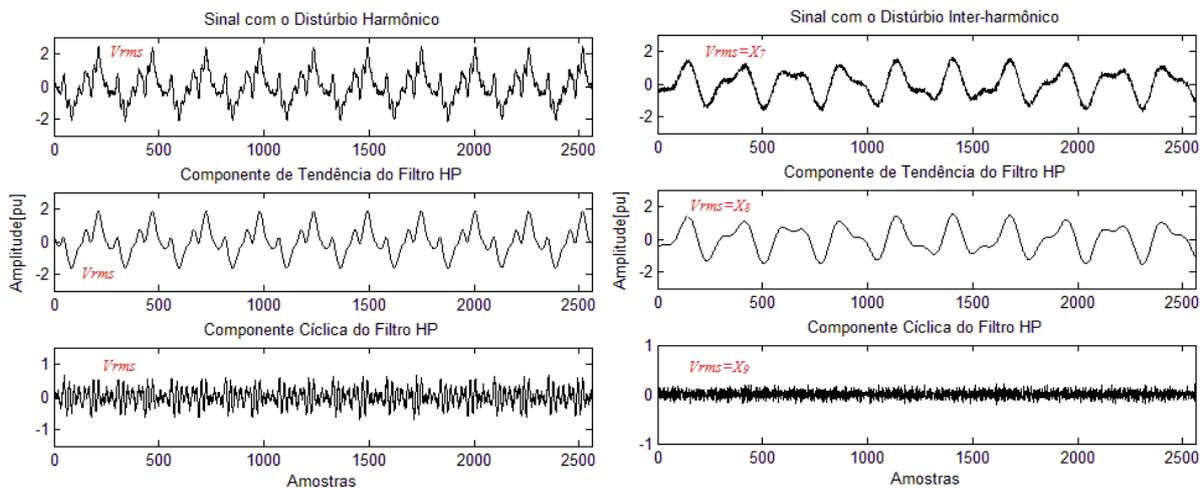
Figura 4 – Sinais contaminados com os distúrbios harmônico e inter-harmônico



Fonte: Elaborado pelos autores, 2020.

Na Figura 5 têm-se os distúrbios harmônico e inter-harmônico vistos a partir do filtro HP. Para o distúrbio harmônico são consideradas as tensões harmônicas até a 13ª ordem, com fase e amplitude distribuídas de maneira aleatória. Os valores eficazes do distúrbio harmônico são: sinal nominal 0,92 pu; componente de tendência 0,85 pu e componente cíclica 0,25 pu. O inter-harmônico possui frequência de 110 Hz e amplitude de 0,52 pu. Os valores eficazes do inter-harmônico são: sinal nominal 0,77 pu; componente de tendência de 0,78 pu e componente cíclica 0,069 pu. Para o sinal sem distúrbio de 1 pu de amplitude o valor eficaz do sinal nominal é de 0,71 pu.

Figura 5 – Valor eficaz aplicado aos distúrbios harmônico e inter-harmônico.



Fonte: Elaborado pelos autores, 2020.

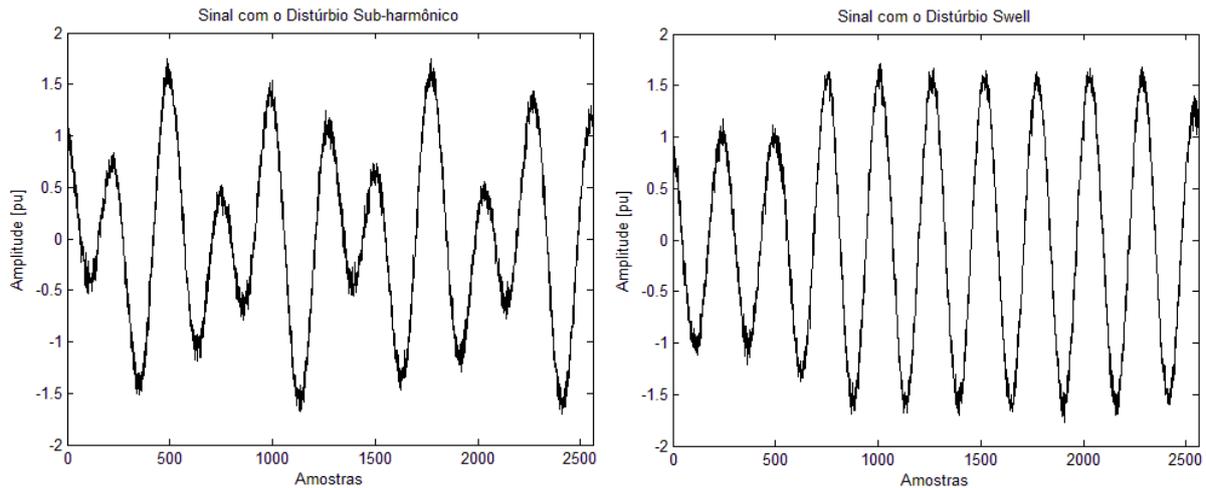
Nota-se na Figura 5 que o ruído presente no sinal original apresentou-se na componente cíclica do filtro HP. Isto é muito relevante para a análise que foi proposta, pois altos níveis de ruído foram considerados.

3.5 Aplicação da Transformada Rápida de Fourier

A transformada de Fourier foi empregada para obter o valor máximo da componente fundamental do sinal nominal, que é o décimo parâmetro do vetor de entrada. Este parâmetro apresenta valor máximo alterado conforme alguns tipos de distúrbios, justificando-se, dessa forma, sua utilização como característica indicadora da presença de distúrbio.

A Figura 6 apresenta dois sinais elétricos com frequência fundamental de 60 Hz, amplitude de 1 pu e SNR de 20 dB. Porém, os sinais estão contaminados com os distúrbios sub-harmônico e *swell*, respectivamente. O sub-harmônico é um tipo de inter-harmônico, porém sua frequência se encontra abaixo da frequência fundamental de operação do SEP (sistema elétrico de potência). Conforme Dugan (2012), uma elevação de tensão de curta duração (*swell*) pode ser definida como um aumento entre 1,1 e 1,8 pu, na tensão eficaz, na frequência fundamental do SEP, com duração entre 0,5 ciclo a 1 minuto. As elevações de tensão estão, geralmente, associadas a condições de falta no SEP, principalmente no que diz respeito à *falta* fase-terra (FORTUNATO; SANTANA; GOMES, 2019).

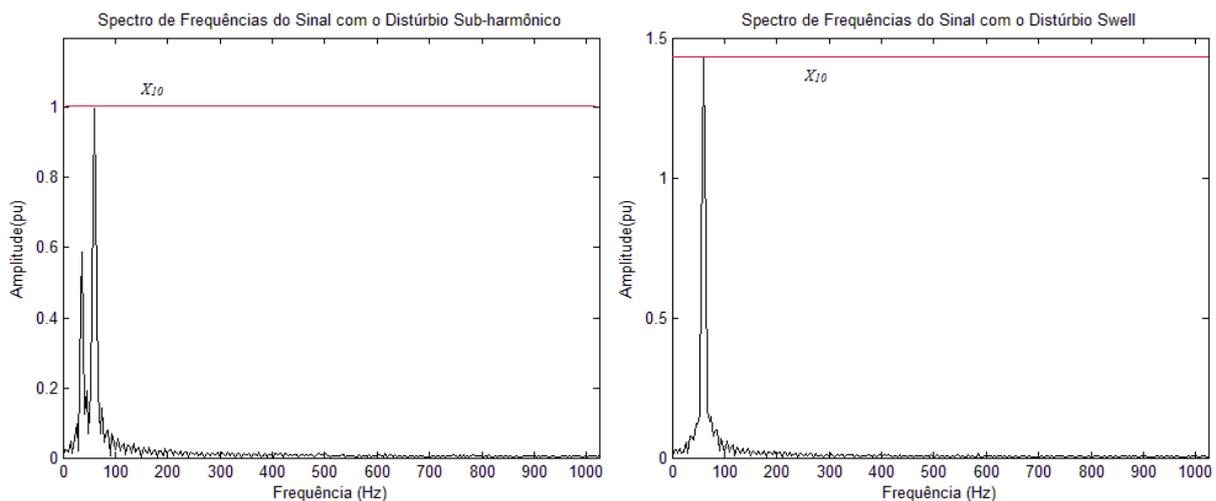
Figura 6 – Sinais contaminados com os distúrbios sub-harmônico e *swell*



Fonte: Elaborado pelos autores, 2020.

Para evidenciar a variação dos valores máximos da FFT na componente fundamental do sinal nominal utiliza-se a Figura 7.

Figura 7 – Transformada Rápida de Fourier para os distúrbios sub-harmônico e *swell*



Fonte: Elaborado pelos autores, 2020.

Na Figura 7 apresenta-se o distúrbio sub-harmônico 36 Hz e amplitude de 0,59 pu e um sinal com a presença do distúrbio elevação de tensão, respectivamente. Percebe-se que o valor máximo da componente fundamental do sub-harmônico é de 1 pu e que o valor máximo da componente fundamental do *swell* é 1,43 pu. Desta forma, é possível extrair características diferentes para diferentes classes de distúrbios.

Portanto, o vetor de entrada do classificador é composto por 10 parâmetros:

- X_1 : valor máximo do sinal nominal;
- X_2 : valor mínimo do sinal nominal;
- X_3 : valor máximo da componente de tendência do filtro HP;
- X_4 : valor mínimo da componente de tendência do filtro HP;
- X_5 : valor máximo da componente cíclica do filtro HP;
- X_6 : valor mínimo da componente cíclica do filtro HP;
- X_7 : valor eficaz do sinal nominal;
- X_8 : valor eficaz da componente de tendência do filtro HP;
- X_9 : valor eficaz da componente cíclica do filtro HP;
- X_{10} : valor máximo da FFT na componente fundamental do sinal nominal.

4 Resultados e Discussão

Nesta seção, apresenta-se a avaliação do modelo de classificação proposto, comparação com outros métodos e a matriz de confusão de todos os modelos considerados na comparação. Os classificadores foram implementados através do *software* livre *Neu Com Student v0.919* (KASABOV, 2003).

4.1 Classificação de Distúrbios

O desempenho de classificação do modelo eCF é avaliado neste item. Os distúrbios foram apresentados ao modelo evolutivo de forma aleatória, simulando como o fluxo de dados ocorreria em um caso real, onde os distúrbios surgem no decorrer do tempo, ou seja, os dados são fornecidos gradualmente ao classificador. As classes foram nomeadas da seguinte maneira:

- Classe 1: distúrbio harmônico;
- Classe 2: distúrbio inter-harmônico;
- Classe 3: distúrbio interrupção curta;
- Classe 4: distúrbio *notch*;
- Classe 5: distúrbio *sag*;
- Classe 6: sinal sem distúrbio;
- Classe 7: distúrbio *spike*;
- Classe 8: distúrbio sub-harmônico;
- Classe 9: distúrbio *swell*;
- Classe 10: distúrbio transitório oscilatório.

O algoritmo eCF realiza a classificação dos eventos de forma recursiva. Se nova amostra é diferente do conhecimento atual, então se cria um *cluster* novo e uma nova regra de nó para representá-lo; senão, adapta-se um *cluster* ou regra no sentido de incluir a amostra e reconhecer amostras semelhantes que possam surgir. Desta forma, o modelo vai evoluindo e adaptando-se continuamente e observando novos padrões de distúrbios e condições. Foi simulado o fluxo de dados contendo informações dos nove distúrbios e do sinal sem distúrbio. O propósito foi verificar a eficiência do modelo eCF considerando um problema multiclases, ou seja, complexo. Portanto, foram apresentadas ao modelo evolutivo 10 classes diferentes. O índice de desempenho utilizado para avaliar o modelo proposto é dado por:

$$Acc = \frac{VP + VN}{VP + VN + FP + FN} \cdot 100\%, \quad (9)$$

onde, Acc é a acurácia; VP são os verdadeiros positivos; VN são os verdadeiros negativos; FP são os falsos positivos e FN são falsos negativos.

A Tabela 1 apresenta o desempenho de classificação do modelo eCF para as classes consideradas em função da relação sinal-ruído, mostrando a acurácia, o tempo computacional requerido em segundos e o número de regras *fuzzy* criadas. O computador utilizado contém processador Intel Pentium, Dual CPU T2390 1.86GHz, memória RAM 2,00 GB, e sistema operacional de 32 *bits*. A partir da Tabela 1 nota-se que os resultados foram promissores apesar de considerarem-se altos níveis de ruído. Estes resultados também evidenciam que os parâmetros utilizados no modelo de reconhecimento de padrões são eficazes, pois o algoritmo eCF foram capazes de reconhecer padrões nos dados com alta acurácia e baixo custo computacional.

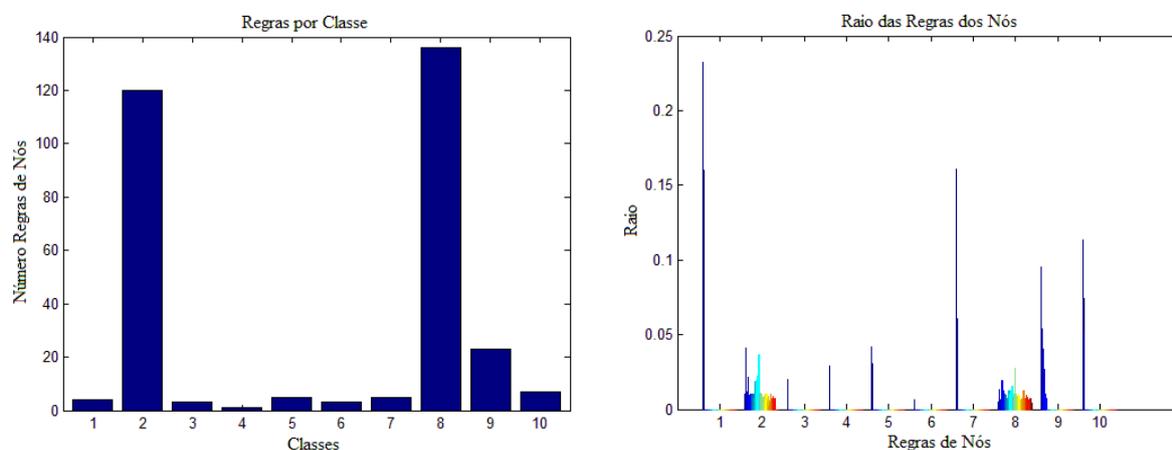
Tabela 1 – Desempenho de classificação e tempo computacional requerido pelo modelo eCF

Base de Dados	SNR (dB)	Acurácia (%)	Tempo (s)	Número de regras
As dez classes consideradas	20	100	111	414
	30	100	103	357
	40	100	97	342
	50	100	88	323
	60	100	83	307

Fonte: Elaborado pelos autores, 2020.

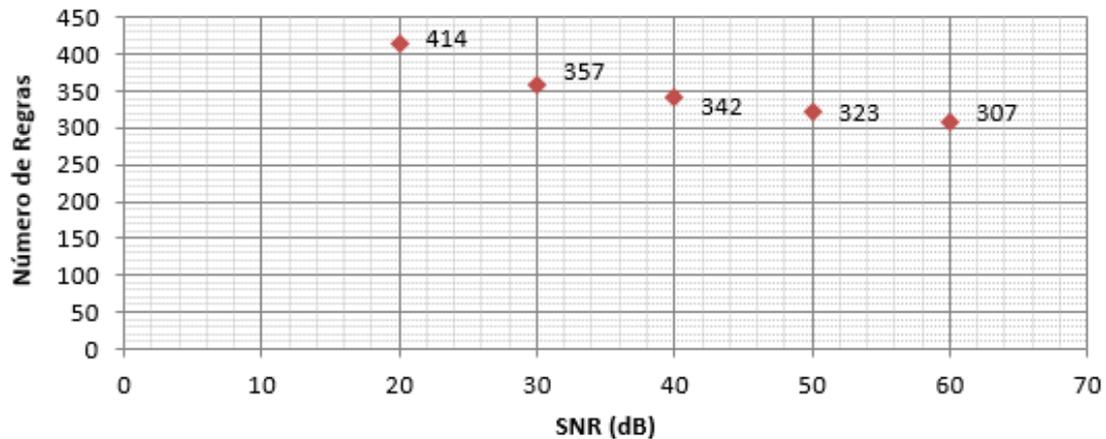
A Figura 8 apresenta os gráficos das regras *fuzzy* de nós por classe e do raio das regras dos nós, respectivamente, do modelo eCF, considerando a relação sinal-ruído em 60 dB. O gráfico das regras por classe mostra quantas regras *fuzzy* foram criadas para cada classe. Cada regra *fuzzy* representa um *nó/cluster*. Os sub-harmônicos (classe 8) seguidos pelos inter-harmônicos (classe 2), por serem classes bastante parecidas, mostraram ser mais desafiadores de serem distinguidos em comparação com os outros distúrbios, por isso a maior quantidade de regras criadas para estas duas classes. O gráfico do raio das regras dos nós mostra o tamanho do raio do *cluster* que é criado por cada regra. É uma medida da dispersão dos dados de cada classe em um espaço deca dimensional (10 parâmetros). A classe seis, sinal sem distúrbio, é a que apresenta menor dispersão nos dados e a classe um, harmônico, a que apresenta maior dispersão.

Figura 8 – Gráficos das regras por classe e raio das regras dos nós do modelo eCF



Fonte: Elaborado pelos autores, 2020.

A Figura 9 mostra o gráfico das regras totais criadas pelo modelo eCF para cada valor de relação sinal-ruído. Ressalta-se que quanto menor a relação sinal-ruído maior o número de regras criadas pelo modelo eCF, ou seja, quanto mais difícil é a classificação (alto nível de ruído) o modelo se molda (evolui), criando regras para classificar os eventos com desempenho elevado. Se o problema se torna mais fácil, o modelo se molda excluindo regras para esta nova realidade, ganhando em tempo computacional. Esta é uma das vantagens dos modelos evolutivos sobre os modelos estatísticos e adaptativos convencionais, a evolução e adaptação do modelo em tempo real.

Figura 9 – Gráfico das regras *fuzzy* criadas pelo modelo e CF

Fonte: Elaborado pelos autores, 2020.

4.2 Comparação com outros métodos

Neste item, apresenta-se a comparação da acurácia e tempo computacional do modelo eCF com os modelos e CMC (*evolving Clustering Method for Classification*), rede neural MLP (*Multilayer Perceptron*), SVM (*Support Vector Machine*) e MLR (*Multiple Linear Regression*). O e CMC também é um sistema conexionista evolutivo, assim como o eCF; sendo considerada a mesma base de dados e condições utilizadas para o modelo eCF foram consideradas na comparação dos resultados.

A Regressão Linear Múltipla é um modelo de análise utilizado para modelar a relação linear entre uma variável de desfecho contínua e múltiplas variáveis preditoras que podem ser contínuas ou não (BRAGA, 20199). A rede neural do tipo MLP é uma rede neural composta por vários neurônios do tipo *perceptron*. São redes multicamadas não recorrentes que utilizam um algoritmo de retropropagação do erro para ajuste dos pesos sinápticos, como, por exemplo, o *backpropagation* (BARBOSA *et al.*, 2017). O SVM é uma técnica de aprendizado supervisionado que pode ser aplicada tanto à classificação quanto à regressão. Quando usado para reconhecimento de padrões, implementa um mapeamento não linear dos vetores de entrada para um espaço de características de alta dimensão, onde uma superfície de decisão linear é construída (HAYKIN, 1999). O eCMC é um algoritmo rápido para agrupamento incremental a partir de fluxo de dados. É um método de agrupamento baseado em distância, onde os centros de grupos são representados por nós, evoluindo em modo on-line (KASABOV, 2007). A Tabela 2 apresenta a comparação da acurácia entre os modelos.

Tabela 2 – Resultado comparativo da acurácia entre os modelos

Base de Dados	SNR (dB)	eCF	eCMC	MLP	SVM	MLR
As dez classes consideradas	20	100	97	89	88	70
	30	100	96	90	90	71
	40	100	96	96	93	75
	50	100	96	95	94	76
	60	100	97	96	94	77

Fonte: Elaborado pelos autores, 2020.

Percebe-se pela Tabela 2 que eCF obteve um desempenho acima dos outros classificadores utilizados na comparação. Estes resultados evidenciam a grande capacidade dos algoritmos evolutivos, especificamente o eCF, na *clusterização* de eventos de forma incremental, obtendo, assim, excelentes resultados na classificação de distúrbios de qualidade de energia elétrica. Nota-se, também, que os modelos evolutivos apresentaram desempenho constante independente da relação sinal-ruído, sendo esta uma vantagem em relação aos outros modelos, que a partir de 30 dB apresentaram um decréscimo considerável no valor da acurácia. Para os modelos não evolutivos (MLP, SVM e MLR) os piores resultados foram para relação sinal-ruído de 20dB, tanto

em acurácia quanto em tempo computacional requerido, mostrando que a baixa relação sinal-ruído interfere na extração de características dos sinais e, conseqüentemente, no desempenho destes classificadores que não se adaptam a este novo padrão nos dados, pois suas estruturas são fixas.

A Tabela 3 apresenta o resultado comparativo entre os modelos, considerando o tempo computacional requerido em segundos.

Tabela 3 – Resultado comparativo do tempo computacional requerido entre os modelos classificadores

Base de Dados	SNR (dB)	eCF	eCMC	MLP	SVM	MLR
As dez classes consideradas	20	111	843	83	373	2
	30	103	818	68	340	2
	40	97	739	49	321	2
	50	88	770	51	319	2
	60	83	695	47	318	2

Fonte: Elaborado pelos autores, 2020.

Pela Tabela 3 percebe-se que MLR é muito rápido, porém pouco eficiente no processo de classificação proposto. O modelo MLR é ideal para casos menos complexos e com poucas classes envolvidas. O modelo SVM e principalmente o eCMC apresentaram tempo de processamento bem acima dos outros métodos. Os tempos aferidos dos modelos MLP e eCF ficaram bem próximos, com ligeira vantagem para a rede neural MLP. Entretanto, eCF foi mais eficiente no reconhecimento de padrões nos dados.

4.3 Matriz de Confusão

Conforme Rezende *et al.* (2003), a matriz de confusão de uma hipótese h apresenta uma medida efetiva do classificador, ao evidenciar o número de classificações corretas versus as classificações incorretas para cada classe, considerando um conjunto de exemplos N . Cada coluna da matriz de confusão representa os dados de uma classe desejada, enquanto as linhas representam os dados de uma classe estimada pelo modelo. As entradas da matriz são representadas por $M(C_i, C_j)$, indicando o número de exemplos de N que são da classe C_i , mas que foram classificados pela hipótese h como sendo da classe C_j .

$$M(C_i, C_j) = \sum_{\{x,y \in N: y=C_i\}} \|h(x) = C_j\| \quad (10)$$

O número de acertos, para cada classe, localiza-se na diagonal principal da matriz $M(C_i, C_j)$; os demais elementos $M(C_i, C_j)$, para $i \neq j$, representam erros na classificação. A matriz de confusão de um classificador ideal possui todos os elementos fora da diagonal iguais a zero, uma vez que ele não comete erros. A matriz de confusão possibilita analisar a porcentagem de assiduidade das diversas amostras associadas a uma classe, assim como é possível verificar quais as classes que o classificador confunde mais e tomar decisões que otimizem seu desempenho (REZENDE *et al.*, 2003; TAN *et al.*, 2006).

A seguir são apresentadas as matrizes de confusão considerando a relação sinal-ruído em 60 dB para todos os modelos abordados neste trabalho. A Figura 10 apresenta as matrizes de confusão dos modelos eCF e eCMC.

Figura 10 – Matrizes de confusão dos sistemas conexionistas evolutivos

		Modelo eCF										Modelo eCMC									
Saída Estimada	200	0	0	0	0	0	0	0	0	0	0	200	0	0	0	0	0	0	0	0	0
	0	199	0	0	0	0	0	0	0	0	0	0	186	0	0	0	0	28	2	0	0
	0	0	200	0	0	0	0	0	0	0	0	0	0	200	0	1	0	0	0	0	0
	0	0	0	200	0	0	0	0	0	0	0	0	0	0	200	0	0	0	0	0	0
	0	0	0	0	200	0	0	0	0	0	0	0	0	0	191	0	0	0	0	0	0
	0	0	0	0	0	200	0	0	0	0	0	0	0	0	8	200	0	0	0	0	0
	0	0	0	0	0	0	200	0	0	0	0	0	0	0	0	188	0	0	0	0	0
	0	1	0	0	0	0	0	0	200	0	0	0	0	0	0	0	172	0	0	0	0
	0	0	0	0	0	0	0	0	0	200	0	0	0	0	0	0	0	198	0	0	0
	0	0	0	0	0	0	0	0	0	0	200	0	0	0	0	0	12	0	0	0	200
		Saída Desejada										Saída Desejada									

Fonte: Elaborado pelos autores, 2020.

Percebe-se, pela matriz de confusão do modelo eCF, que apenas um evento entre dois mil foi classificado de modo errado. Um evento do distúrbio inter-harmônico foi confundido com o distúrbio sub-harmônico. Para as demais classes a acurácia foi de 100%. Para o modelo eCMC, a confusão na classificação foi maior, a se ver. Somente cinco classes obtiveram acurácia de 100%. Os maiores erros de classificação aconteceram entre as classes dois e oito, inter-harmônico e sub-harmônico, respectivamente, corroborando com as informações apresentadas na Figura 8.

A Figura 11 apresenta a matriz de confusão para o método adaptativo convencional considerado na comparação dos resultados, a rede neural artificial do tipo MLP.

Figura 11– Matriz de confusão da rede neural artificial MLP

		1	2	3	4	5	6	7	8	9	10
Saída Estimada	1	200	0	0	0	0	0	0	0	0	0
	2	0	133	0	0	0	0	0	12	0	0
	3	0	0	200	0	0	0	0	0	0	0
	4	0	0	0	200	0	0	0	0	0	0
	5	0	2	0	0	200	0	0	0	0	0
	6	0	0	0	0	0	200	0	0	0	0
	7	0	17	0	0	0	0	200	0	0	0
	8	0	48	0	0	0	0	0	188	0	0
	9	0	0	0	0	0	0	0	0	200	0
	10	0	0	0	0	0	0	0	0	0	200
		Saída Desejada									

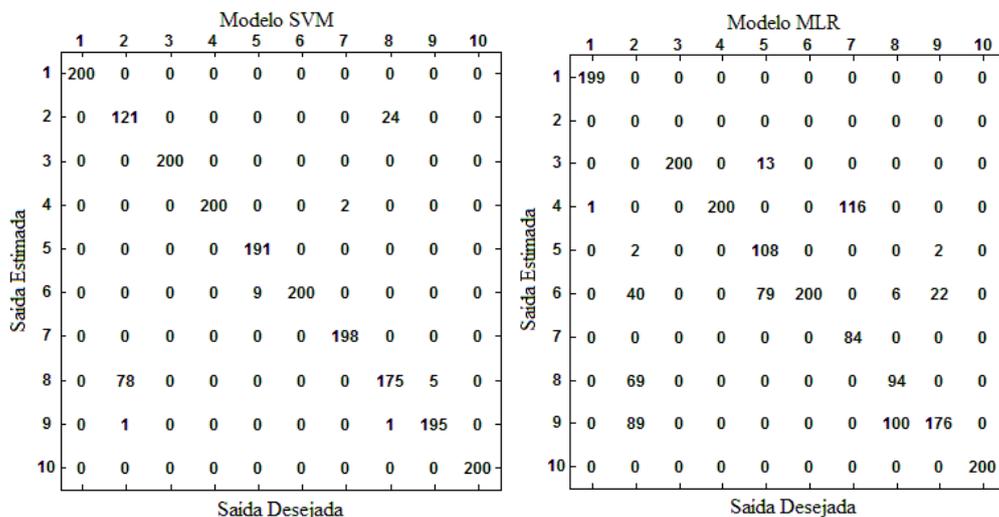
Fonte: Elaborado pelos autores, 2020.

Nota-se, pela Figura 11, que ocorreu a confusão de classificação somente entre três classes de distúrbio. Para o inter-harmônico, 17 eventos foram classificados como o distúrbio *Spike* (classe 7) e 48 eventos foram classificados como o distúrbio sub-harmônico (classe 8). Para o sub-harmônico, 12 eventos foram classificados como inter-harmônico (classe 2). Para oito classes a acurácia foi de 100%. Uma informação importante que é mostrada pela matriz de confusão é a acurácia por classe. Comparando-se a acurácia total dos modelos eCMC e rede neural MLP, percebe-se que o modelo eCMC obteve melhor desempenho que a rede neural MLP, ou

seja, 97% contra 96%, conforme Tabela 2. Porém, ao analisar as matrizes de confusão nota-se que a rede neural MLP conseguiu identificar melhor as classes, obtendo 100% de acurácia em oito classes contra cinco do eCMC, evidenciando, assim, a grande capacidade de generalização das redes neurais artificiais. Porém, uma das vantagens do modelo eCMC é que este processa os dados de maneira on-line considerando os dados em fluxo contínuo, enquanto a rede neural processa os dados em modo off-line a partir de uma base fixa.

A Figura 12 apresenta as matrizes de confusão para a relação sinal-ruído de 60dB dos métodos estatísticos SVM e MLR, respectivamente. Percebe-se que o desempenho do SVM foi semelhante ao do eCMC (Figura 10), com as mesmas cinco classes obtendo acurácia de 100%, porém com maior quantidade de erros de classificação para as outras classes. O modelo MLR foi o que apresentou maior confusão na classificação dos eventos e consequentemente menor acurácia total, sendo o único a errar a classificação de todos os eventos de uma única classe (classe 2, inter-harmônico), apesar de ser o mais rápido no processamento dos dados. A partir de todas as matrizes de confusão, fica evidente que as classes mais fáceis de classificar foram interrupção curta, harmônico, *notch*, sinal sem distúrbio e transitório oscilatório. As mais difíceis foram o inter-harmônico e o sub-harmônico.

Figura 12 – Matrizes de confusão dos métodos estatísticos



Fonte: Elaborado pelos autores, 2020.

5 Conclusão

Algoritmos evolutivos são extremamente eficazes para resolver problemas de classificação onde os dados são fornecidos gradualmente ao longo do tempo. Neste contexto, este trabalho propôs o sistema conexionista evolutivo eCF para a classificação de distúrbios de qualidade de energia elétrica. O eCF é um sistema conexionista para tarefas de classificação que consiste em quatro camadas de neurônios. Para extração de características foi considerado um método híbrido composto pelo filtro Hodrick-Prescott, modelo matemático FFT e valor RMS.

A abordagem proposta, eCF, mostrou-se eficaz para a classificação on-line e acima dos resultados apresentados por outros modelos de classificadores, a saber eCMC, MLR, MLP e SVM, mesmo considerando baixa relação sinal-ruído e múltiplas classes de distúrbios em um mesmo fluxo de dados. A adaptação contínua do modelo mostrou-se essencial para lidar com variáveis de sistemas que variam no tempo, como sistemas de energia elétrica, sujeitos a diversos padrões de distúrbios. Comparado com outros classificadores, eCF mostrou-se superior tanto para caso mais fácil (SNR a 60dB), com acurácia em 100%, quanto para o caso mais difícil (SNR a 20dB), com acurácia também em 100%, evidenciando, também, a eficácia do método híbrido de extração de características e que o alto índice de ruído no sinal não interfere no desempenho do classificador proposto.

Para trabalhos futuros serão investigados efeitos ainda mais complexos da inserção de cargas no sistema elétrico, buscando, assim, identificar padrões até mesmo incipientes ou de maior variabilidade. Além disso, será considerado um menor número de ciclos de senoides por janela para a extração de variáveis a fim de verificar a robustez do método híbrido de seleção de características, pois quanto menor o número de ciclos

mais complexa se torna esta seleção. A nova formulação do problema naturalmente levará à necessidade de empregar métodos de aprendizado não supervisionados e incrementais mais recentes e utilização de novas técnicas de extração de características, visando, desta forma, abordar metodologias de seleção incremental de variáveis para tornar o sistema evolutivo.

Referências

- BALOUJI, E.; SALOR, O. Digital realisation of the IEC flickermeter using root mean square of the voltage waveform. **IET Generation, Transmission & Distribution**, [s.l.], v. 10, n. 7, p. 1663-1670, may 2016. Disponível em: <https://doi.org/10.1049/iet-gtd.2015.0952>. Acesso em: 08 dez. 2022.
- BARBOSA, E. *et al.* Aplicação de redes neurais artificiais para o reconhecimento de assinaturas harmônicas de equipamentos eletrodomésticos. **Revista de Sistemas e Computação - RSC**, Salvador, v. 7, n. 1, p. 67-75, jan./jun. 2017. Disponível em: <https://revistas.unifacs.br/index.php/rsc/article/download/4952/3177>. Acesso em: 08 dez. 2022.
- BEHERA, L.; NAYAK, M. Pattern recognition of power quality events using Fuzzy neural network based rule generation. *In*: IEEE-INTERNATIONAL CONFERENCE ON ADVANCES IN ENGINEERING, SCIENCE AND MANAGEMENT (ICAESM-2012), 2012, Nagapattinam. **Anais [...]**. Nagapattinam: IEEE, 2012. p. 73-78. Disponível em: <https://ieeexplore.ieee.org/document/6215576/authors#authors>. Acesso em: 08 dez. 2022.
- BRAGA, F. D. **Uso de redes neurais de funções de base radial e regressão linear múltipla para a previsão de propriedades mecânicas de vergalhões de aço**. 2019. 64 f. Trabalho de conclusão de curso (Graduação em Engenharia Metalúrgica) - Departamento de Engenharia Metalúrgica e de Materiais, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2019. Disponível em: https://repositorio.ufc.br/bitstream/riufc/49234/3/2019_tcc_fdbraga.pdf. Acesso em: 08 dez. 2022.
- DUGAN, R. C. *et al.* **Electrical power systems quality**. 3. ed. New York: McGraw-Hill, 2012. 577 p.
- FERREIRA, D. D.; SEIXAS, J. M.; CERQUEIRA, A. S. A method based on independent component analysis for single and multiple power quality disturbance classification. **Electric Power Systems Research**, Lausanne, v. 119, p. 425-431, Feb. 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S037877961400399X>. Acesso em: 08 dez. 2022.
- FERREIRA, D. *et al.* A direct approach for disturbance detection based on principal curves. *In*: INTERNATIONAL CONFERENCE ON HARMONICS AND QUALITY OF POWER (ICHQP), 16., 2014, Bucharest. **Anais [...]**. Bucharest: IEEE, 2014. p. 747-751. Disponível em: <https://ieeexplore.ieee.org/document/6842747>. Acesso em: 08 dez. 2022.
- FORTUNATO, D.; SANTANA, M.; GOMES, J. Filtro Hodrick-Prescott Aplicado à Análise de Sinais Elétricos com Distúrbios de Qualidade de Energia Elétrica. SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 14., 2019, Ouro Preto. **Anais [...]**. Ouro Preto: SBAI, 2019. ISSN: 2358-4483. Disponível: <https://proceedings.science/sbai-2019/papers/filtro-hodrick-prescott-aplicado-a-analise-de-sinais-eletricos-com-disturbios-de?lang=en>. Acesso em: 08 dez. 2022.
- GARCIA, C. *et al.* Evolvable fuzzy systems from data streams with missing values: With application to temporal pattern recognition and cryptocurrency prediction. **Pattern Recognition Letters**, [s.l.], v. 128, p. 278-282, Dec. 2019. Disponível em: <https://doi.org/10.1016/j.patrec.2019.09.012>. Acesso em: 08 dez. 2022.
- GOH, L.; SONG, Q.; KASABOV, N. A novel feature selection method to improve classification of gene expression data. *In*: CONFERENCE ASIA-PACIFIC BIOINFORMATICS, 2., 2004, Dunedin. **Anais [...]**. Dunedin: APBC, v. 29, 2004. p. 161-166. Disponível em: <https://dl.acm.org/doi/10.5555/976520.976542>. Acesso em: 08 dez. 2022.
- HAYKIN, S. **Neuronal Networks: A Comprehensive Foundation**. 2nd Edition. Hoboken: Prentice Hall, 1999.
- HODRICK, R.; PRESCOTT, E. C. Postwar U.S. business cycles: an empirical investigation. **Journal of Money**, Ohio, v. 29, n. 1, p. 1-16, Feb. 1997. Disponível em: <https://www0.gsb.columbia.edu/faculty/rhodrick/prescott-hodrick1997.pdf>. Acesso em: 08 dez. 2022.

INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS - IEEE. **IEEE recommended practice for monitoring electric power quality**. New York: IEEE, 2009. 91 p. DOI: 10.1109/IEEESTD.2019.8796486. Acesso em: 08 dez. 2022.

KASABOV, N. **Evolving connectionist systems, methods and applications in Bioinformatics, Brain study and Intelligent machines**. London: Springer - Verlag, 2003. DOI: <https://doi.org/10.1007/978-1-4471-3740-5>. Acesso em: 08 dez. 2022.

KASABOV, N. **Evolving connectionist systems: the knowledge engineering approach**. London: Springer - Verlag, 2007. DOI: <https://doi.org/10.1007/978-1-84628-347-5>. Acesso em: 08 dez. 2022.

LATHI, B. **Linear systems and signals**. 2nd ed. International edition. Oxford: Oxford University Press, 2006.

LAZZARETTI, A.; FERREIRA, V.; VIEIRA NETO, H. New trends in power quality event analysis: novelty detection and unsupervised classification. **Journal of Control, Automation and Electrical Systems**, Amsterdam, v. 27, p. 718-727, 2016. Disponível em: <https://doi.org/10.1007/s40313-016-0265-z>. Acesso em: 08 dez. 2022.

LEITE, D. *et al.* Fuzzy granular neural network for incremental modeling of nonlinear chaotic systems. *In: IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 2016, Vancouver. **Anais [...]**. Vancouver: IEEE, 2016. p. 64-71. Disponível em: <https://ieeexplore.ieee.org/document/7737669>. Acesso em: 08 dez. 2022.

MARQUES, J. **Reconhecimento de Padrões Métodos Estatísticos e Neurais**. [s.l.]: IST Press, 1999.

NYQUIST, H. Certain topics in telegraph transmission theory. **Transactions of the American Institute of Electrical Engineers**, [s.l.], v. 47, n. 2, p. 617-644, April 1928. DOI: 10.1109/T-AIEE.1928.5055024. Acesso em: 08 dez. 2022.

PAL, K.; WANG, P. **Genetic algorithms for pattern recognition**. Bota Raton: CRC press, 2017.

RAVN, M; UHLIG, H. On adjusting the Hodrick-Prescott filter for the frequency of observations. **The Review of Economics and Statistics**, Cambridge, v. 84, n. 2, p.371-375, May 2002. Disponível em: <https://home.uchicago.edu/~huhlig/papers/uhlig.ravn.res.2002.pdf>. Acesso em: 08 dez. 2022.

REZENDE, S. O. *et al.* Mineração de dados. *In: REZENDE, S. O. (Org.). Sistemas inteligentes: fundamentos e aplicações*. Barueri: Manole, 2003. p. 307-335.

SANTANA, M.; FORTUNATO, D.; FERREIRA, D. Modelo Fuzzy Evolutivo para detecção e classificação em tempo real de distúrbios na qualidade de energia elétrica. **e-Xacta**, Belo Horizonte, v. 11, n. 2, p. 63-79, 2018. DOI: <http://dx.doi.org/10.18674/exacta.v11i2.2581>. Acesso em: 08 dez. 2022.

SILVA, S. *et al.* Evolving neuro-fuzzy network for real-time high impedance fault detection and classification. **Neural Computing and Applications**, v. 32, p. 7597-7610, 2018. DOI: <https://doi.org/10.1007/s00521-018-3789-2>. Acesso em: 08 dez. 2022.

ŠKRJANC, I. *et al.* Evolving fuzzy and neuro-fuzzy approaches in clustering, regression, identification, and classification: A survey. **Information Sciences**, [s.l.], v. 490, p. 344-368, Jul. 2019. DOI: <https://doi.org/10.1016/j.ins.2019.03.060>. Acesso em: 08 dez. 2022.

SOARES, E. *et al.* Evolving Fuzzy Set-based and Cloud-based Unsupervised Classifiers for Spam Detection. **IEEE Latin America Transactions**, [s.l.], v. 17, n. 09, p. 1449 - 1457, Sep. 2019. DOI: 10.1109/TLA.2019.8931138. Acesso em: 08 dez. 2022.

TAN, P.-N. *et al.* **Introduction to data mining**. Noida: Pearson Education India, 2006. 165 p.

THEODORIDIS, S.; KOUTROUBAS, K. Feature generation II. *In: THEODORIDIS, S.; KOUTROUBAS, K. Pattern recognition*. 4th Edition. [S.l.]: Academic Press, 2009. (Cap. 7, p. 411-479). DOI: <https://doi.org/10.1016/B978-1-59749-272-0.X0001-2>. Acesso em: 08 dez. 2022.

TOMIC, J.; KUSLJEVIC, M.; VUJICIC, V. A new power system digital harmonic analyzer. **IEEE Transactions on Power Delivery**, New York, v. 22, n. 2, p. 772–780, Apr. 2007. DOI: 10.1109/TPWRD.2007.893372. Acesso em: 08 dez. 2022.

TOU, J.T. Computer- Based Particle Shape Analysis for Classification, Recognition, Utilization. **Advanced Particulate Morphology**, eBook ISBN 9781351069540. 2018. p. 165.

Sobre os autores

Márcio Wladimir Santana

Graduado em Engenharia Elétrica pelo Instituto Nacional de Telecomunicações (Inatel) e Mestre em Engenharia de Sistemas e Automação pela Universidade Federal de Lavras (UFLA). Doutorando em Engenharia Agrícola pela Universidade Federal de Lavras (UFLA). Atualmente é Professor Efetivo no Cefet-MG Unidade IX Nepomuceno-MG, lotado no Departamento de Elétrica (Denep). Atualmente é Coordenador do Curso Técnico em Eletrotécnica, Coordenador do Eixo Conversão de Energia do Curso de Graduação em Engenharia Elétrica. Atuou como Coordenador do Curso Técnico em Eletrotécnica e Professor na Uniten – Unidade Integrada e Técnica de Ensino de Lavras-MG. Atuou como engenheiro eletricista na Comau do BRASIL Ind. e Com. LTDA prestando serviços na Magneti Marelli Cofap de Lavras-MG, na área de Engenharia de Manutenção Elétrica. Principais atividades exercidas na Comau: responsável pela adequação à NR-10 das instalações elétricas da MM Cofap, responsável pelos projetos de eficiência energética da MM Cofap e colíder do pilar de Energia do WCM (*World Class Manufacturing*).

Stella Marys Dornelas Lamounier

Mestre em Engenharia de Sistemas e Automação (UFLA – MG), Especialista em Engenharia de *Software* pela Universidade Gama Filho, graduada em Análise e Desenvolvimento de Sistemas pelo Instituto Federal Minas Gerais (2011), onde também possui certificação de Curso Técnico em Informática. Foi professora substituta no IFMG Campus Bambuí e supervisora de Curso Técnico em Informática pelo convênio entre IFMG/Pronatec. Atualmente é professora adjunta do Centro Universitário UNA – Campus Bom Despacho e no IFMG Campus Bambuí como Professora Visitante no Departamento de Engenharia e Computação. Tem experiência na área de Ciência da Computação, com ênfase em Ciência da Computação, atuando principalmente nas áreas de Inteligência Computacional, Sistemas Inteligentes Evolutivos, Sistemas Fuzzy e Neuro-Fuzzy, Engenharia de *Software* e de Requisitos, Gerência de Projetos, Qualidade de *Software*, Análise e Projeto de Sistemas, Banco de Dados e Programação Web.

Danielle Abreu Fortunato

Graduanda do Curso de Engenharia Elétrica, Bacharelado pelo Centro Federal de Educação Tecnológica de Minas Gerais/Campus IX. Técnica em Eletrotécnica pelo Centro Federal de Educação Tecnológica de Minas Gerais/Campus IX (2013). Atuou como estagiária no setor administrativo de apoio à Coordenação de Administração e Diretoria do Cefet-MG Nepomuceno/Campus IX no período de 2015-2017. Atuou como estagiária na empresa Aviário Santo Antônio Ltda. (ASA), no período de 2018-2019, auxiliando no gerenciamento da manutenção industrial, desenvolvendo habilidades para garantir os indicadores de desempenho dos equipamentos e na melhoria de boas práticas de fabricação. Atua como estagiária na empresa RS Serviços Elétricos, auxiliando nos processos de elaboração, execução e orientação de projetos elétricos residenciais, prediais e de geração fotovoltaica.

Jader Bôsko Gomes

Doutor em Engenharia Agrícola em Instrumentação e Controle (2017) pela Universidade Federal de Lavras (UFLA), Mestre em Engenharia Agrícola em Construções e Ambiente (2007) pela Universidade Federal de Lavras (UFLA), Graduado em Engenharia Mecânica (1997) pela Universidade do Estado de Minas Gerais (UEMG), atualmente professor efetivo do Centro Federal de Educação Tecnológica de Minas Gerais (Cefet-MG), do Campus IX – Nepomuceno – MG, lotado no DCMEP na área da Mecânica. Atuou nas indústrias: Cia Industrial Fluminense – SJDel-Rei (1977 a 2008) no departamento técnico; Magneti Marelli Cofap – Lavras (1988 a 2006) nas áreas de Instalações industriais, processos e Engenharia da Qualidade nos novos produtos; Cooper Standard – Varginha (2008) Engenharia da Qualidade e Metalúrgica Mardel – Lavras (2008) como Coordenador Processo e Qualidade.

Israel Teodoro Mendes

Graduado em Engenharia Eletrônica e de Telecomunicações (2009) pelo Instituto Politécnico da Pontifícia Universidade Católica de Minas Gerais (PUC-MG), e Mestre em Engenharia Elétrica (2013) pelo mesmo instituto. Doutor em Engenharia Agrícola / Instrumentação (2018) pelo Programa de Pós-Graduação em Engenharia Agrícola no Centre for Development of Instrumentation Applied to Agriculture da Universidade Federal de Lavras (UFLA), desenvolvendo sua pesquisa na área de Sensores Inteligentes. Atualmente é professor efetivo no Cefet-MG Unidade IX Nepomuceno-MG, lotado no Departamento de Elétrica (Denep).

Avaliado em: 11.05.2022

Aceito em: 01.12.2022