

Modelagem Granular Neuro-Fuzzy Evolutiva para Classificação de Distúrbios em Sistemas de Distribuição de Potência

Danielle Fortunato*, Márcio Santana*, Jader Gomes*, Daniel Leite °

* Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG, Nepomuceno, Brasil

° Departamento de Automática, Universidade Federal de Lavras – UFLA, Minas Gerais, Brasil

Emails: danielle.afortunato@gmail.com, marciosantana@cefetmg.br, jader@cefetmg.br, daniel.leite@ufla.br

Abstract: Power quality disturbances may occur in several parts of a power system and may cause financial losses to other systems connected to it. Therefore, automatic classification of disturbances, with a high level of accuracy and low computational cost, is of fundamental importance. Evolving granular neuro-fuzzy networks are considered. They are able to continuously update their structure and parameters driven by a data stream. Due to their recursive learning ability, evolving neuro-fuzzy networks can adapt to the nonstationarities that occur in a system, evolving continuously along their lifespan. The proposed neuro-fuzzy network is called eGNN (evolving Granular Neural Network). Pre-processing steps consist in extracting features from raw input data. The effective value of phase voltages and the Hodrick-Prescott filter are considered. This filter separates the input signal in trend and cyclic components – suppressing random noise from the trend component. Classification of 4 types of disturbances from the usual system behavior (a 5-class classification problem) is performed with an average accuracy of 98%.

Resumo: Distúrbios de qualidade de energia elétrica ocorrem em várias partes de um sistema de potência e podem causar prejuízos financeiros a todos que estão a ele conectado. Portanto, é de fundamental importância a classificação automática destes distúrbios, com alto nível de acurácia e baixo custo computacional. São consideradas as redes *neuro-fuzzy* granulares evolutivas as quais são capazes de adaptar continuamente sua estrutura e atualizar seus parâmetros de acordo com um fluxo de dados. Devido ao seu processo de aprendizagem recursivo, as redes *neuro-fuzzy* evolutivas podem adaptar-se às não-estacionariedades que ocorrem em um sistema, evoluindo continuamente ao longo da vida. A rede *neuro-fuzzy* proposta é a eGNN (*evolving Granular Neural Network*). Na etapa de pré-processamento dos dados para extração de atributos é considerado o valor eficaz das tensões de fase e o filtro de Hodrick-Prescott. Este separa o sinal de entrada em componente de tendência e componente cíclica –suprimindo o ruído presente no sinal de tendência. A classificação de quatro distúrbios e da operação normal do sistema (problema de cinco classes) foi alcançada com acurácia média de 98%.

Keywords: Evolving neuro-fuzzy network; machine learning; power quality.

Palavras-chaves: Redes neuro-fuzzy evolutiva; aprendizado de máquina; qualidade de energia.

1. INTRODUÇÃO

Atualmente a qualidade da energia elétrica é um requisito de grande importância para as concessionárias de energia, pois está diretamente relacionada à competitividade em praticamente todos os setores industriais e de serviços. Sobretudo nas últimas duas décadas onde ocorreram várias mudanças no setor elétrico, tais como a alteração da natureza das cargas, diversificação dos tipos de cargas, e o surgimento de novas tecnologias de geração e inserção de energia na rede elétrica. Assim, tais alterações afetaram de forma negativa a Qualidade da Energia Elétrica (QEE) promovendo o aumento dos estudos relacionados a essa área e a busca por qualidade passou a ser preocupação não apenas de órgão reguladores, mas também de consumidores e agentes diversificados do setor elétrico. Um exemplo que evidencia tais mudanças é o uso de Geração Distribuída (GD), onde a geração de energia elétrica se dá junto ou próxima dos consumidores,

independente da potência, tecnologia e fonte de energia (Deckmann; Pomilio, 2017; Santana, 2017; ANEEL, 2018).

É importante considerar o aumento das *smart grids* (redes inteligentes de energia) no sistema elétrico. Tais *grids* se tratam de uma nova arquitetura de distribuição de energia elétrica, mais segura e inteligente, que integra e possibilita ações a todos os usuários a ela conectados. Assim, a energia tradicionalmente gerada, transmitida e distribuída de forma radial, a partir de instalações das concessionárias pode, também, ser gerada e integrada às redes elétricas a partir de unidades usualmente classificadas como consumidoras. Com base neste novo conceito de geração e consumo de energia elétrica podem surgir distúrbios de QEE imprevisíveis.

Tendo em vista este cenário de grandes mudanças no setor elétrico, pesquisas na área de QEE tiveram um crescimento considerável nos últimos anos. Dentre os temas abordados, a detecção, segmentação e classificação dos distúrbios elétricos

são de grande importância. Dessa forma, a classificação e investigação de suas causas se tornam algo de grande necessidade para os sistemas de distribuição de potência (Nagata, 2018) e seus componentes (Alves et al., 2020).

Modelos de detecção e classificação evolutivos, isto é, modelos equipados com algoritmos incrementais online de aprendizado de máquina, são capazes de identificar novos distúrbios e condições de um sistema de potência de forma autônoma. Tais modelos têm sua base de regras, estrutura conexionista, clusters, folhas em árvores, ou grânulos de informação adaptados ao longo do tempo de acordo com o fluxo de dados (Santana, 2017; Silva et al., 2018; Soares et al., 2019; Leite, 2019; Leite et al., 2020).

O objetivo do presente trabalho é realizar a classificação automática de distúrbios de qualidade de energia elétrica presentes em um sistema elétrico de potência utilizando inteligência granular evolutiva. O estudo descreve a abordagem chamada rede granular *neuro-fuzzy* evolutiva, eGNN, e o procedimento de extração de atributos dos dados originais usando filtro. A abordagem granular evolutiva é proposta como solução para o problema de classificação de distúrbios em sinais de tensão. Em geral, tais sistemas *neuro-fuzzy* granulares têm sido utilizados com sucesso para resolver problemas de identificação, previsão e avaliação em diversas áreas, como medicina, agronomia e previsão meteorológica. Neste trabalho a classificação de distúrbios deve acontecer em modo *online* e em tempo real. São abordados os distúrbios: harmônicos, transitório oscilatório, interrupção-curta, e elevação de tensão (*swell*).

2. MÉTODOS DE EXTRAÇÃO DE ATRIBUTOS E APRENDIZADO DE MÁQUINA ONLINE

2.1 Filtro Hodrick e Prescott

Hodrick, D. e Prescott, E. (1997) propuseram um método, um filtro, conhecido pelas iniciais de seus nomes (HP). A proposta do filtro é decompor o sinal em duas componentes de tendência e cíclica/aleatória. Em essência, removem-se as flutuações de baixa frequência dos sinais ou séries. A hipótese é de que, nessa separação, a variabilidade de baixa frequência representa a tendência em prazo mais longo e a variabilidade de frequência mais alta representa os ciclos mais curtos e/ou aleatórios (Santana, 2017).

Atributos extraídos dos sinais decompostos são importantes na distinção entre diferentes tipos de distúrbios. Em um sinal temporal, a componente de tendência é a mudança gradual observada por meio da variação dos valores de amplitude ao longo do tempo. A tendência se mantém ao se remover os componentes de ciclos, sazonalidades e fatores aleatórios. O filtro HP busca extrair a tendência, que é considerada estocástica, mas com variações suaves ao longo do tempo e não correlacionadas com o ciclo, por meio da minimização com respeito a τ_t do funcional J conforme:

$$J = \sum_{t=1}^T C_t^2 + \lambda \sum_{t=2}^{T-1} (\Delta^2 \tau_t)^2 \quad (1)$$

em que $C_t \triangleq y_t - \tau_t$; y_t é o sinal em questão; e $\Delta^2 \triangleq (1-L)^2$, com L sendo o operador de defasagem, e.g., $Lx_t = x_{t-1}$. Em (1), T é a quantidade de amostras de dados em questão, e λ é um parâmetro que penaliza a variabilidade da tendência. O parâmetro λ é o parâmetro de suavidade com o qual se controla a aceleração da componente de tendência, isto é, as variações na taxa de crescimento da componente de tendência. O primeiro termo de (1) é a soma dos desvios da série com respeito à tendência ao quadrado, e é uma medida do grau de ajuste. O segundo termo é a soma de quadrados das segundas diferenças das componentes de tendência, e é uma medida do grau de suavidade.

2.2 Raiz do Valor Quadrático Médio

O valor RMS (*root mean square*) ou valor eficaz é uma medida da magnitude de uma quantidade variável. O valor pode ser calculado para uma série de valores discretos ou para uma função contínua. O valor eficaz da tensão de um sinal elétrico é um atributo eficiente para detecção de distúrbios, em especial daqueles distúrbios que geram variações consideráveis na amplitude, como afundamento e elevação de tensão, e interrupções.

Para uma função variável contínua $f(t)$, definida no intervalo $T_1 \leq t \leq T_2$, o valor RMS de um sinal y é dado por:

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

2.3 Redes Neurais Granulares Evolutivas

O conceito de redes neurais granulares (GNN) foi inicialmente estabelecido por Pedrycz, W. e Vukovich, W. (2001) para designar redes neurais com algum aspecto que envolve incerteza. Por exemplo: (i) os dados processados por uma rede granular não precisam ser necessariamente numéricos, mas podem ser intervalos, números fuzzy, intervalos fuzzy, distribuições de probabilidade, palavras; (ii) as operações das conexões entre neurônios ou do corpo neural podem não ser pontuais, mas levar em conta incerteza; (iii) as estimativas providas pela rede podem ser invólucros em torno do valor alvo; e/ou (iv) a representação dos dados no modelo neural é feita de forma modular, a partir do desenvolvimento de modelos locais (grânulos de informação encontrados no fluxo de dados *online*). A partir do ambiente GNN original, foram propostas várias outras abordagens neurais granulares. Dentre elas, se destaca a rede *evolving* GNN, eGNN (Leite; Costa Jr.; Gomide, 2009; Leite, 2019), pois ela foi equipada com algoritmo de aprendizado de máquina incremental online e capacidade de adaptação estrutural do modelo, além da capacidade de atualização paramétrica usual. Além disso, eGNN contempla os quatro aspectos, (i)-(iv) mencionados.

O aprendizado em GNN e eGNN segue um princípio comum que, geralmente, envolve dois estágios, conforme mostra a Fig. 1. Primeiro, grânulos de informação – intervalos ou conjuntos *fuzzy* – são construídos a partir de uma base de representação numérica. Note que, algumas vezes, os dados

são originalmente granulares. Em seguida, a aprendizagem – construção e refinamento – da rede neural é baseada nos grânulos de informação ao invés de ser baseada nos dados originais. Assim, a rede eGNN não é exposta a todos os dados de treinamento, muito mais numerosos que os grânulos formados. Por exemplo, quando amostras de dados não transportam novas informações, os exemplos são incorporados pelo grânulos já conhecidos (Leite, 2019).

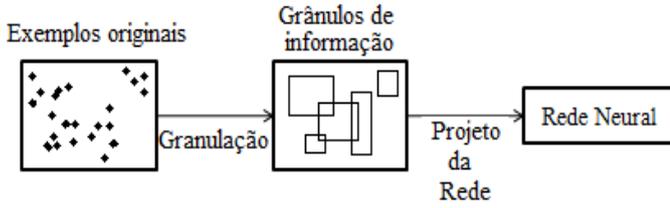


Fig. 1 Projeto de rede neural granular, GNN ou eGNN

Fundamentalmente, modelos eGNN processam dados observando um fluxo somente uma vez. eGNN começa a aprender a partir de uma base de regras vazia, sem neurônios e sem conhecimento prévio das propriedades estatísticas dos dados e classes (para o caso de problema de classificação). A abordagem consiste em formar limites discriminantes entre classes a partir da granulação do espaço dos dados usando hiper-caixas *fuzzy* (Leite, 2019). A escolha dos hiper-parâmetros iniciais de algoritmos é crucial para a obtenção de boas soluções. Esta questão é de certa forma facilitada se os algoritmos de aprendizagem contemplam mecanismos que adaptam continuamente os hiper-parâmetros iniciais. O tamanho máximo, ρ , que um grânulo pode assumir no espaço dos dados define a capacidade não-linear (flexibilidade) do modelo em capturar limites discriminantes entre classes. Portanto, ρ é o hiper-parâmetro chave do algoritmo.

Um procedimento para adaptar ρ continuamente é proposto. Primeiro, considere que $\{\gamma^1, \dots, \gamma^\Theta\}$ sejam os grânulos criados em um certo número de passos de tempo, h_g . Se a quantidade de grânulos Θ cresce a uma taxa maior que um limiar η , então ρ é aumentado conforme,

$$\rho(\text{novo}) = \left(1 + \frac{\Theta}{h_g}\right) \rho(\text{velho}). \quad (3)$$

Ao contrário, se Θ cresce a uma taxa menor que η , então, ρ é reduzido a partir de

$$\rho(\text{novo}) = \left(1 + \frac{\eta - \Theta}{HG}\right) \rho(\text{velho}). \quad (4)$$

Redes eGNN aprendem a partir de um fluxo de dados $x^{[h]}$, $h = 1, 2, \dots$. Os exemplos de treinamento podem ou não ser acompanhados de um rótulo de classe $C^{[h]}$. Cada grânulo de informação γ^i da coleção finita dos grânulos existentes em um dado momento, $\gamma = \{\gamma^1, \dots, \gamma^c\}$, definido no espaço de atributos $X \subseteq R^n$, é associado a uma classe C_k da coleção finita de classes $C = \{C_1, \dots, C_m\}$ no espaço de saída $Y \subseteq N$. eGNN associa os espaços de atributos e de saída usando

grânulos extraídos do fluxo de dados, e duas camadas de neurônios T-S (T-norma, S-norma, null-norma, unimorma, ou qualquer outra família de normas a escolher). A rede neural tem uma estrutura em 5 camadas, como mostra a Fig. 2.

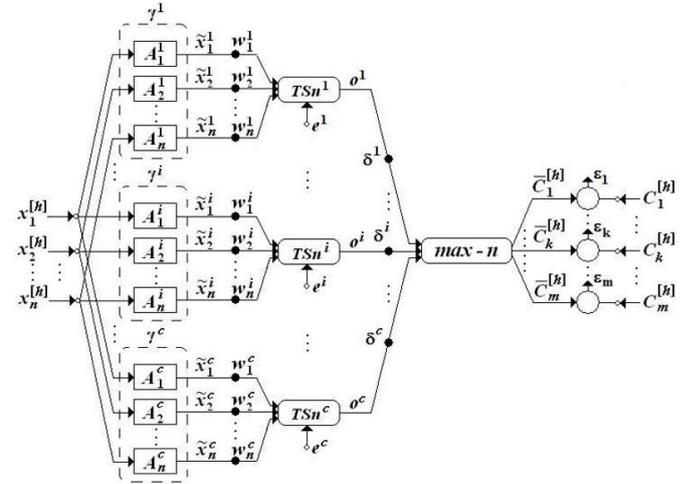


Fig. 2 Rede neuro-fuzzy granular evolutiva (eGNN)

A camada de entrada apresenta vetores característicos $x^{[h]} = (x_1, \dots, x_j, \dots, x_n)^{[h]}$, $h = 1, \dots$, à rede neural; a camada granular consiste de um conjunto de grânulos $\gamma^i \forall i$ formado como um escopo do fluxo de dados. Sobreposição parcial de grânulos (fuzzy) são permitidas; a camada de agregação contém neurônios T-S, $TSn^i \forall i$. Estes agregam graus de pertinência para gerar medidas de compatibilidade $o^i \forall i$ entre exemplo e grânulos; na camada de decisão, as medidas de compatibilidade são comparadas, e a classe C_k associada ao grânulo γ^i que apresentou a maior compatibilidade para um dado exemplo é induzida na saída da rede; a camada de saída compreende indicadores de rótulos de classe. Todas as camadas, exceto a camada de entrada, evoluem dado o fluxo $x^{[h]}$, $h = 1, 2, \dots$. A adaptação paramétrica e estrutural do classificador eGNN pode ser realizada de diferentes maneiras dependendo da aplicação, isto é, o número de classes pode ser automaticamente controlado quando tem-se tal informação *a priori*. O número de grânulos na estrutura do modelo pode também ser limitado se memória e tempo de processamento são restrições do problema. Em ambientes desconhecidos, ambos, o número de grânulos e classes, podem ser automaticamente gerenciados pelo algoritmo de aprendizagem (Leite, Costa, Gomide, 2010; Leite, 2019).

O algoritmo de aprendizado é omitido neste artigo. Ele está reportado em detalhes em (Leite, 2019). Em essência, o algoritmo compreende procedimentos de criação de grânulos, arraste de grânulos no espaço dos dados, expansão e encolhimento de seus limites, mesclagem por similaridade, e deleção de grânulos e neurônios inativos por um certo número de passos de processamento. A rede eGNN é de propósito geral, independe da natureza da aplicação, e também pode ser empregada em problemas de regressão e previsão. Um modelo é gerado autonomamente tal que dados não precisam ser armazenados para posterior análise.

3. METODOLOGIA

3.1 Geração de Sinais para Análise

A rede *neuro-fuzzy* foi implementada no software MatLab® 2014. As amostras de dados de sistemas de potência foram geradas de acordo com a regulamentação do IEEE (IEEE, 2009). Os padrões de distúrbios nos sinais de tensão são compatíveis com a norma adotada no sistema elétrico brasileiro. Ver detalhes dos distúrbios em (Leite et al., 2020). A frequência de amostragem é 15360 Hz. A taxa de amostragem de 256 amostras por ciclo de tensão foi considerada baseando-se no teorema da amostragem de Nyquist-Shannon (Nyquist, 2002).

Ruído branco foi definido de modo a atender a relação sinal-ruído (SNR - *signal-to-noise ratio*) conforme:

$$SNR = 20 \log \frac{A}{\sqrt{2\sigma}} [dB]. \quad (5)$$

Na prática, sinais de tensão medidos nos sistemas elétricos possuem relação sinal ruído entre 50 dB e 70 dB (Tomic; Kusljevic; Vujicic, 2007). Com a finalidade de analisar diferentes níveis de ruído no sinal, são utilizadas as relações 20 dB, 30 dB, 40 dB, 50 dB, 60 dB.

As características de cada evento de QEE, como amplitude e fase, 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 $[-\pi; \pi]$ com distribuição uniforme. Foram gerados 2000 vetores de dados para cada valor de SNR, sendo 400 eventos para cada classe (dados balanceados), e considerou-se 10 ciclos da senóide como janela deslizante.

3.2 Sistema de Monitoramento

O monitoramento de distúrbios em sistemas de potência, em geral, compreende basicamente a extração de atributos interessantes dos sinais originais, e a alimentação dos dados extraídos em um modelo gerado por um algoritmo de aprendizado. O modelo realiza classificação baseado nos padrões observados no espaço transformado, i.e., no espaço cujos eixos são os atributos escolhidos. Neste trabalho a obtenção de atributos indicadores de distúrbios foi feita a partir do resultado obtido com o emprego do filtro HP e do valor eficaz da tensão. A construção do modelo classificador foi realizada em modo online a partir de um fluxo de dados do espaço transformado.

O esquema geral do sistema de monitoramento evolutivo proposto é ilustrado no fluxograma da Fig. 3. O sinal a ser processado pelo classificador é o vetor *dados de entrada*, resultante do pré-processamento do sinal com distúrbio através filtro HP e do valor RMS da tensão. Note na figura que é inserido um tipo de distúrbio de acordo com o padrão IEEE e ajustada uma relação SNR.

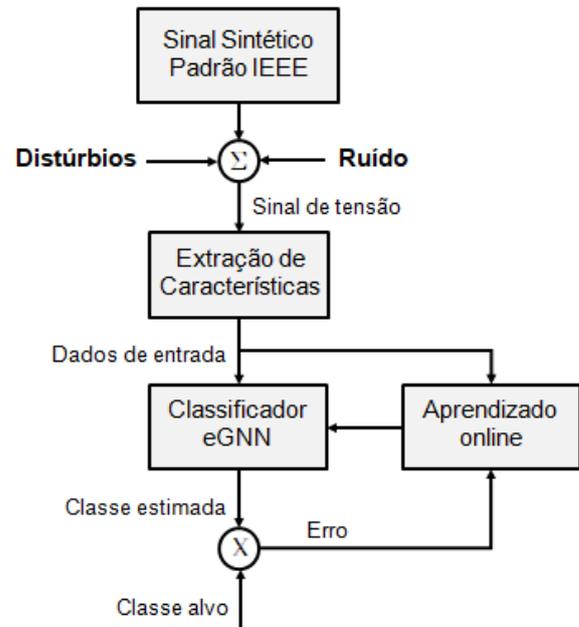


Fig. 3 Sistema de monitoramento evolutivo proposto

3.3 Atributos Extraídos

O filtro HP extrai a tendência do sinal de tensão. Assim, o ruído presente no sinal (componente de alta frequência) é apresentado na componente cíclica resultante. Isto proporciona análise livre de interferência de ruído. A Fig. 4 apresenta um sinal elétrico como exemplo. Este possui frequência fundamental de 60 Hz, relação sinal-ruído de 20 dB e amplitude de 1pu (por unidade). Percebe-se que o sinal está acrescido com um distúrbio do tipo transitório oscilatório, proveniente de chaveamento de banco de capacitores. O filtro HP decompôs o sinal original, em duas componentes: componente de tendência e cíclica. O ruído presente no sinal e o distúrbio transitório oscilatório, ambos componentes de alta frequência, são apresentados na componente cíclica. O sinal livre de ruído foi apresentado na componente tendência, ou seja, o sinal de frequência fundamental, 60 Hz.

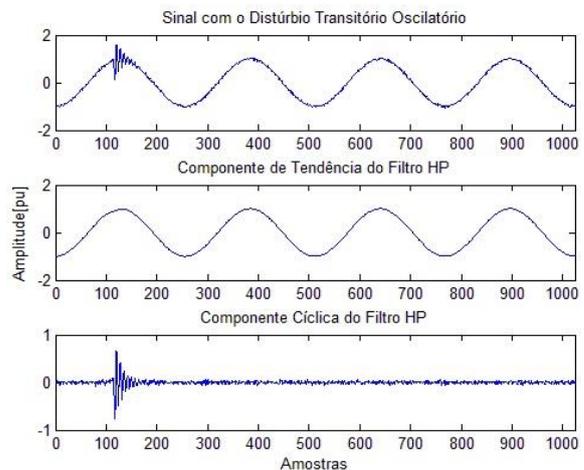


Fig. 4 Exemplo de filtragem HP atuando em um sinal de tensão com distúrbio transitório oscilatório e SNR de 20 dB

A partir da decomposição do sinal de tensão, realizada em (Fortunato et al., 2019) foi possível selecionar os três melhores atributos que evidenciam de maneira mais clara os efeitos dos distúrbios abordados neste trabalho. Os 3 atributos são: valor eficaz da componente HP de tendência; valor mínimo da componente HP de tendência, e valor eficaz da componente HP cíclica.

4. RESULTADO E DISCUSSÃO

Essa seção mostra os resultados do sistema de monitoramento baseado em eGNN. O Classificador é comparado com classificadores projetados por outros algoritmos em termos de acurácia e matriz de confusão. Assume-se que não há conhecimento prévio dos dados.

4.1 Classificação eGNN de Distúrbios

Considere a acurácia como índice de desempenho,

$$A_{cc} = \frac{VP+VN}{VP+VN+FP+FN} \times 100\%. \quad (6)$$

em que Acc é a acurácia; VP e VN são os verdadeiros positivos e verdadeiros negativos, respectivamente; FP e FN são os falsos positivos e falsos negativos, respectivamente. A classes positivas são todas aquelas relativas a distúrbio. A classe negativa é a operação normal do sistema. O modelo eGNN realiza a detecção e a classificação dos distúrbios na tensão de maneira *online*.

A Tabela 1 resume o desempenho de classificação de eGNN para os distúrbios considerados em função da relação SNR.

Tabela 1. Desempenho de classificação do modelo eGNN

Classes	SNR (dB)	Acc (%)	Tempo (s)
As cinco classes consideradas	20	94,25	2,26
	30	97,50	2,40
	40	98,55	2,49
	50	98,20	2,22
	60	98,20	2,40

Nota-se na Tabela 1 que os resultados do classificador eGNN são interessantes mesmo considerando valores baixos de relação sinal-ruído. Este resultado também evidencia que os atributos utilizados a partir do filtro HP e do valor eficaz da tensão de linha são eficientes, pois o modelo evolutivo foi capaz de reconhecer padrões nos dados. O pior resultado para acurácia foi considerando a SNR de 20 dB, evidenciando que a baixa relação sinal-ruído interfere no desempenho global. O tempo computacional requerido foi em média de 2,35 s. Isto é considerado muito rápido, pois 2 mil amostras foram processadas. O algoritmo de eGNN é bastante recomendado para fluxos de dados de grande volume (*Big data*).

4.2 Comparação de Classificadores

O modelo eGNN é comparado com os modelos MLR (*Multiple Linear Regression*), e a rede neural MLP (*Multi-*

Layer Perceptron). É utilizada a mesma base de dados que foi considerada para o modelo eGNN. Ela contém 2 mil amostras, sendo 400 amostras de cada classe (operação normal, e 4 classes de distúrbios).

A Regressão Linear Múltipla é uma coleção de técnicas estatísticas para construir modelos que descrevem de maneira razoável relações entre várias variáveis explicativas de um determinado processo (Hoffmann, 2016). Redes Neurais Artificiais (RNA) são modelos inspirados na forma de processamento de informação dos neurônios biológicos. Foi escolhida a RNA *feed-forward* convencional, chamada MLP (Silva, 2016).

A Tabela 2 apresenta o resultado comparativo entre os modelos eGNN, MLR e MLP, considerando a acurácia.

Tabela 2. Resultado comparativo entre classificadores

Classes	SNR (dB)	eGNN	MLP	MLR
As cinco classes consideradas	20	94,25	81,75	76,00
	30	97,50	92,30	86,50
	40	98,55	96,90	97,10
	50	98,20	97,00	96,40
	60	98,20	95,70	96,30

Observa-se na Tabela 2 que o modelo eGNN obteve um desempenho superior aos demais modelos utilizados na comparação, com média de 96%. Os modelos MLP e MLR obtiveram uma média de resultados de 92,73% e 90,46%, respectivamente, evidenciando a eficácia do sistema evolutivo eGNN e sua capacidade de aprendizado ao longo da operação em tempo real. eGNN é indicado como ferramenta para classificação de distúrbios de QEE, especialmente por se tratar de um sistema variante no tempo e que sugere que a adaptação do modelo ao longo do tempo é uma abordagem efetiva.

4.3 Matriz de Confusão

A matriz de confusão é um método que detalha a análise de classificadores. O nome deriva do fato de que ela torna mais fácil ver quais classes estão sendo confundidas. As classes que compõem a matriz são representadas por $M(C_i, C_j)$, indicando o número de exemplos de N que são da classe C_j , mas que foram classificados pela hipótese h conforme,

$$M(C_i, C_j) = \sum_{\{v(x,y) \in N : y=C_j\}} \|h(x) = C_j\| \quad (7)$$

em que o número de acertos para cada classe localiza-se na diagonal principal $M(C_i, C_i)$ da matriz. Os demais elementos $M(C_i, C_j)$, para $i \neq j$, representam erros de classificação.

A matriz de confusão de um classificador ideal possui todos os elementos fora da diagonal principal iguais à zero, uma vez que o classificador não comete erros. A matriz de confusão possibilita analisar a porcentagem de assiduidade das diversas amostras associadas a uma classe, assim como permite o entendimento e a quantificação das amostras classificadas de forma errada (Tan, et al. 2006).

Para as matrizes de confusão a seguir as classes são distribuídas da seguinte forma:

Classe 1: sinal sem distúrbio;

Classe 2: distúrbio harmônico;

Classe 3: distúrbio transitório oscilatório;

Classe 4: distúrbio interrupção curta;

Classe 5: distúrbio *swell*.

A Fig. 5 apresenta a matriz de confusão de eGNN para a relação SNR de 20dB – o caso mais complicado.

1	373	0	28	2	11
2	0	369	0	0	0
3	25	0	371	4	9
4	0	0	0	393	0
5	2	31	1	1	380
	1	2	3	4	5

Fig. 5 Matriz de confusão para o modelo eGNN

Percebe-se pela Fig. 5 que os acertos estão na diagonal principal da matriz, em cor cinza. Os erros estão identificados pela cor branca. As classes 4 e 5 foram as que tiveram melhor desempenho. A classe 4 teve 7 amostras classificadas incorretamente, sendo que destas, duas foram classificadas como classe 1; 4 como classe 3; e uma como classe 5. Já a classe 5 obteve 20 amostras classificadas de maneira errada, sendo que destas, 11 foram classificadas como classe 1; e 9 classificadas como classe 3. A classe 2 teve o pior desempenho com 92,30% de acurácia, e trinta e uma amostras classificadas erradas. Destas, todas foram atribuídas à classe 5. Outra análise importante é que das amostras da classe 1, 27 foram classificadas incorretamente. Destas, 25 foram classificadas como classe 3; e duas como classe 5. Dessa forma, o modelo eGNN obteve um percentual de 94,30% de classificação das situações.

A Fig. 6 apresenta a matriz de confusão para a relação SNR de 20 dB do modelo MLR. Nota-se que as classes 1 e 3 tiveram melhor desempenho, em relação as demais. A classe 1 teve 25 amostras classificadas de maneira errada, como classe 5. A classe 3 teve uma amostra classificada de maneira errada, como classe 5. A classe 5 foi aquela que obteve o pior desempenho, com 374 amostras classificadas erradas, como classe 3; e apenas 26 amostras classificadas de forma correta, em um total de 400 amostras. A classe 2 possui 28 amostras classificadas de maneira errada. Sendo 13 classificadas como classe 3; e 15 amostras classificadas como classe 5.

1	375	0	0	45	0
2	0	372	0	0	0
3	0	13	399	7	394
4	0	0	0	348	0
5	25	15	1	0	26
	1	2	3	4	5

Fig. 6 Matriz de confusão para o modelo MLR

Percebe-se na Fig. 6 que a classe 4 possui 52 amostras classificadas de maneira incorreta. Destas, 45 foram classificadas como condição de operação normal; e 7 como transitório oscilatório. Dessa forma, o modelo MLR obteve um percentual de 76,00% de classificação dos distúrbios neste caso.

A Fig. 7 apresenta a matriz de confusão do modelo MLP para a relação SNR de 20 dB.

1	393	0	0	0	0
2	0	346	0	0	0
3	0	52	397	0	301
4	0	0	0	400	0
5	7	2	3	0	99
	1	2	3	4	5

Fig. 7 Matriz de confusão para o modelo MLP

Nota-se que as classes 3 e 4 tiveram melhor desempenho, em relação as demais. A classe 3 teve 3 amostras classificadas de maneira errada, como classe 5. A classe 4 não teve nenhuma amostra classificada de maneira errada. A classe 5 foi aquela que obteve o pior desempenho, com 301 amostras classificadas erradas, como classe 3; e apenas 99 amostras classificadas de forma correta, em um total de 400 amostras. A classe 2 possui 54 amostras classificadas de maneira errada. Sendo 52 classificadas como classe 3; e 2 amostras classificadas como classe 5. Totalizando um percentual de 81,75% de classificação dos distúrbios neste para o modelo MLP.

5. CONCLUSÃO

Os distúrbios que surgem nos sistemas de potência podem ser responsáveis por danos à equipamentos industriais e eletrônicos domésticos, com consequente prejuízo financeiro. Dessa forma, é de suma importância que tais distúrbios, independente do fator causador ou grau de efeito, sejam identificados e classificados para que medidas de correção sejam tomadas. Tais medidas são as ferramentas para melhoria contínua da qualidade de energia em um sistema.

A rede *neuro-fuzzy* granular evolutiva faz a detecção e classificação de dados em modo *online* e lida com mudanças eficientemente. O modelo eGNN proposto apresentou alto desempenho para baixos valores SNR, possibilitando a análise eficiente do sistema a partir de poucos ciclos da senóide de tensão e baixo custo computacional, ou seja, pouco tempo de processamento. Esse resultado também enfatiza a eficiência da etapa de pré-processamento, isto é, de extração dos atributos mais apropriados.

Em trabalhos futuros, estudos para a melhoria da acurácia na classificação dos distúrbios serão considerados. Outros tipos de distúrbios serão incorporados, assim como a possibilidade de ocorrência de múltiplos distúrbios simultaneamente.

AGRADECIMENTOS

Os três primeiros autores agradecem ao CEFET-MG pelo apoio financeiro e por nos oferecer um ambiente agradável de estudos. O último autor agradece o apoio do Instituto Serrapilheira, processo Serra – 1812-26777.

REFERÊNCIAS

- Agência Nacional de Energia Elétrica – ANEEL, (2018). “Geração Distribuída”. Relatório Técnico. RJ, Brasil.
- Alves, K.; Hell, M.; Oliveira, F.; Aguiar, E. (2020). “An enhanced set-membership evolving participatory learning with kernel recursive least squares applied to thermal modeling of power transformers”. *Electric Power Systems Research*, v. 184, p. 106334.
- Deckmann, S. M.; Pomilio, J. A. (2017). “Avaliação da Qualidade da Energia Elétrica”. Departamento de Sistemas e Energia. Universidade de Campinas.
- Fortunato, D.; Santana, M.; Gomes, J. (2019). “Filtro Hodrick-Prescott Aplicado à Análise de Sinais Elétricos com Distúrbios de Qualidade de Energia Elétrica”. *Simpósio Brasileiro de Automação Inteligente*, 6p.
- Hodrick, R.; Prescott, E. (1997). “Postwar U.S. Business Cycles: An Empirical Investigation.” *Journal of Money, Credit, and Banking*, v. 29, n. 1, p. 1-16.
- Hoffmann, R. (2016). “Análise Estatística de Relações lineares e não lineares”. 1ª Edição Digital. ISBN: 978-85-921057-1-6. 259 p – Universidade de São Paulo.
- Institute of Electrical and Electronics Engineers – IEEE, (2009). “Recommended Practice for Monitoring Electric Power Quality”. New York: IEEE, 91 p.
- Leite, D.; Costa, P.; Gomide, F. (2009). “Evolving Granular Classification Neural Networks”. *Int. Joint Conference on Neural Networks (IJCNN 2009)*, p. 1736-1743.
- Leite, D.; Costa, P.; Gomide, F. (2010). “Granular Approach for Evolving System Modeling”. In: Hullermeier, E.; Kruse, R.; Hoffmann, F. (Eds.) *Lecture Notes in Computer Science*, 6178, Springer: Berlin, Heidelberg.
- Leite, D. (2019). “Comparison of Genetic and Incremental Learning Methods for Neural Network-based Electrical Machine Fault Detection”. In: Lughofer, E.; Sayed-Mouchaweh, M. (Eds.) *Predictive Maintenance in Dynamic Systems*, p. 231-268. Springer: Cham.
- Leite, D.; Decker, L.; Santana, M.; Souza, P. (2020). “EGFC: Evolving Gaussian Fuzzy Classifier from Never-Ending Semi-Supervised Data Streams – With Application to Power Quality Disturbance Detection and Classification”. *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE’20)*, 9p. arXiv:2004.09986.
- Nagata, E. (2018). “Detecção, Segmentação e Classificação de Afundamentos de Tensão em Sistemas Elétricos de Potência”. 92p. Dissertação (Mestrado em Engenharia de Sistemas e Automação) – U. Federal de Lavras.
- Nyquist, H. (2002). “Certain Topics in Telegraph Transmission Theory”. *Proc. of the IEEE*, v. 90, n 2, p. 280-305.
- Pedrycz, W.; Vukovich, W. (2001). “Granular Neural Networks”. *Neurocomputing*, v. 36, p. 205-224.
- Santana, M. (2017). *Agrupamento Incremental de Fluxo de Dados para Análise e Monitoramento da Qualidade de Energia*. 98p. Dissertação (Mestrado em Engenharia de Sistemas e Automação) – U. Federal de Lavras.
- Silva, I. N. et al, (2016). *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Fundamentos Teóricos e Aspectos Práticos*. ISBN 9788588098879. 431p.
- Silva, S.; Costa, P.; Santana, M.; Leite, D. (2018). “Evolving Neuro-Fuzzy Network for Real-Time High Impedance Fault Detection and Classification”. *Neural Computing and Applications*. p. 14p. DOI: doi.org/10.1007/s00521-018-3789-2.
- Soares, E.; Garcia, C.; Poucas, R.; Camargo, H.; Leite, D. (2019). “Evolving Fuzzy Set-based and Cloud-based Unsupervised Classifiers for Spam Detection”. *IEEE Latin America Transactions*, v. 17, n. 9, p. 1449-1457.
- Pang-Ning, T.; Steinbach, M.; Karpapne, A. (2006). *Introduction to Data Mining*. Pearson. India, 165p.
- Tomic, J.; Kusljevic, M.; Vujicic, V. (2007). “A New Power System Digital Harmonic Analyser”. *IEEE Transactions on Power Delivery*, v. 22, n. 2, p. 772–780.