

Análise de Distúrbios da Qualidade da Energia Elétrica Empregando a Decomposição Variacional de Modos

Maísa L. F. Santos* Suzete E. N. Correia* Cleumar S. Moreira*
Álvaro de M. Maciel* Edgard L. L. Fabricio*

* Programa de Pós Graduação de Engenharia Elétrica, Instituto Federal da Paraíba, João Pessoa-PB, (e-mail: maisa.lauriane@academico.ifpb.edu.br, suzete@ifpb.edu.br, cleumar.moreira@ifpb.edu.br, alvaro.maciell@ifpb.edu.br, edgard.fabricio@ifpb.edu.br).

Abstract: This article proposes a computational approach applied to the classification of Electric Power Quality Disturbances (PQD), which are based on the Variational Mode Decomposition (VMD) and the Random Forest (RF) classifier algorithms. Firstly, nine parametric equations-based different signals were generated. Variational mode decomposition (VMD) has been used to decompose the signals into various intrinsic mode functions (IMFs). Seven statistical characteristics were extracted from the instantaneous amplitude (AI) of the decomposed IMFs. The RF model is then developed to classify PQD based on these characteristics. The proposed approach is validated by analytical results, where the classifier accuracy was 99,71%. It confirms that the proposed analysis is capable of providing necessary and accurate information for PQD.

Resumo: Este artigo propõe uma abordagem computacional aplicada à classificação de Distúrbios da Qualidade da Energia Elétrica (DQEE), que se baseia na Decomposição Variacional de Modos (VMD) e no algoritmo de classificação Floresta Randômica (RF). Nove classes de distúrbios elétricos foram gerados baseados em equações paramétricas. A VMD foi usada para decompor os sinais gerados em várias funções de modo de intrínseco (IMFs). Sete características estatísticas foram extraídas da amplitude instantânea (IA) das IMFs decompostas. O modelo RF foi então desenvolvido para classificar os DQEE com base nessas características. Os resultados obtidos apresentam 99,71% de acurácia de classificação, corroborando que a análise proposta é capaz de fornecer informações necessárias e precisas para distúrbios da QEE.

Keywords: Power quality disturbances, Classification, Variational mode decomposition, Signal processing, Feature extraction.

Palavras-chaves: Distúrbios da qualidade da energia elétrica, Classificação, Decomposição variacional de modos, Processamento de sinais, Extração de características.

1. INTRODUÇÃO

A crescente utilização de cargas não lineares, inversores de frequência, dispositivos de comutação e proteção de estado sólido são os principais responsáveis pelo surgimento de Distúrbios da Qualidade da Energia Elétrica (DQEE). Tais distúrbios provocam deformações no aspecto da forma de onda da tensão e/ou corrente elétrica no sistema elétrico, implicando em impactos diretos na eficiência, segurança e confiabilidade dos sistemas elétricos (Giacomini Junior, 2020).

Dessa forma, fatores como a qualidade da energia entregue aos consumidores e a continuidade do fornecimento da energia apresentam destaque no cenário atual, uma vez que os equipamentos modernos estão sucessivamente mais dependentes das condições de operação do sistema de energia elétrica e, portanto, são sensíveis à variações (Oliveira, 2019).

São amplos e diversos os efeitos econômicos em virtude dos DQEEs. Segundo Elphick et al. (2015), em alguns casos o impacto causado por DQEEs, como interrupções e transientes, tornam-se imediatamente perceptíveis devido aos danos provocados ao equipamento. Consequentemente, o impacto no rendimento funcional de tais equipamentos acarretam em custos de reinicialização de sistemas, perda de processo produtivo ou inatividade.

É importante analisar e identificar distúrbios de energia, pois a partir da sua detecção e classificação adequada é possível traçar estratégias eficazes de mitigação para melhoraria da qualidade dos sistemas de energia elétrica.

Vários estudos se concentraram em métodos de processamento de sinais como a transformada de Fourier de tempo curto (*Short Time Fourier Transform* - STFT) (Jamali et al. (2018)), transformada Wavelet (WT) (Hong et al. (2021)), transformada de Laplace (Zhong et al. (2019)), assim como a transformada de Hilbert e Huang (HHT) (Jena et al. (2018)) com o objetivo de evidenciar caracte-

rísticas dinâmicas (no domínio do tempo ou da frequência) dos efeitos provocados pelos DQEEs em sinais elétricos de sistemas reais ou emulados.

A decomposição empírica de modos (EMD), segundo Achlerkar et al. (2018), tem sido amplamente utilizada em sinais que apresentam perturbações na QEE, devido ao seu bom desempenho adaptativo e de não necessitar, a priori, de uma função base para a decomposição do sinal como a transformada de Fourier e a Wavelet. A EMD, entretanto, é sensível ao ruído, sofre com a detecção de dois ou mais componentes de frequência que estejam próximos, devido a utilização de método recursivo.

Outra técnica de decomposição de sinais foi proposta por Dragomiretskiy and Zosso (2014), denominada como decomposição variacional de modos (*Variational Decomposition of Modes - VMD*). Esta técnica foi desenvolvida para superar as desvantagens da decomposição empírica de modos (*Empirical Decomposition of Modes - EMD*). Este algoritmo é mais robusto ao ruído, possuindo um filtro Wiener embutido para atualização de modos a fim de proporcionar a filtragem em faixas em que o ruído apresenta-se de forma mais agressiva.

Cada modo tem uma frequência central que é gradualmente demodulada para a banda base correspondente. Diferentemente da EMD, a largura de banda dos modos intrínsecos da VMD é estreita, extraindo com precisão os componentes harmônicos presentes em sinais não estacionários, independentemente de quão próximos estão sem perder a informação no tempo. Ao destacar a VMD, muitos estudos têm tentado aprimorar sua aplicação na extração de características de diversos tipos de sinais.

Estes métodos possibilitam a extração de atributos que possam representar a dinâmica em diferentes faixas do sinal analisado. Tais atributos, unidos a algoritmos de aprendizagem de máquina (*Machine Learning - ML*), proporcionam o desenvolvimento de sistemas inteligentes aplicados a detecção de sinais afetados por DQEEs.

Dentre as técnicas de ML adotadas para identificar vários modos de distúrbio, pode-se citar: máquina de vetores de suporte (*support vector machine - SVM*) (Kubendran and Kumar (2020)); rede neural artificial; perceptron de multicamadas (MLP) (Rodriguez et al. (2019), Prasad et al. (2021)); árvore de decisão e floresta aleatória (*random forest - RF*) (Reddy and Sodhi (2017)).

Diante do exposto, foi proposto nesta pesquisa a detecção e distinção de DQEEs. O método consiste na extração de atributos em sinais decompostos pelos método VMD. Os atributos serão empregados no treinamento do algoritmo RF, no qual será aplicado nas etapas de detecção das DQEEs e avaliado de forma quantitativa por meio da métrica acurácia baseada em matriz de confusão.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Decomposição Variacional de Modos

A Decomposição Variacional de Modos foi proposta por Dragomiretskiy and Zosso (2014). Inspirada na EMD, é uma técnica adaptativa e não-recursiva. Tal método, assume que o sinal original é composto por uma quantidade

das chamadas Funções de Modo Intrínseco (IMFs), $u_k(t)$, que são definidas como componentes AM-FM:

$$u_k(t) = A(t)\cos[\phi(t)] \quad (1)$$

em que, $A(t)$ e $\phi(t)$ correspondem, respectivamente, a amplitude instantânea e a fase instantânea de $u_k(t)$. A frequência central da IMF é considerada a frequência instantânea correspondente $w(t) = \dot{\phi}(t)$. A busca por $u_k(t)$ e $w(k)$ resulta em um problema variacional restrito da seguinte forma:

$$\min_{\{u_k\}, \{w_k\}} \left\{ \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \quad (2)$$

$$\text{Sendo: } \sum_k u_k = f$$

em que, $\{u_k\} = \{u_1 \dots u_k\}$ representam os conjuntos das IMFs, $\{w_k\} = \{w_1 \dots w_k\}$ representam as frequências centrais a definir. Para resolver o problema de otimização restrito apresentado na Equação (2) são introduzidos a penalidade quadrática α e os multiplicadores Lagrangianos λ com a finalidade de tornar a otimização irrestrita (Wang et al., 2017).

$$L(\{u_k\}, \{w_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (3)$$

A solução é alcançada atualizando a frequência central e a largura de banda de cada IMF em uma sequência de otimização chamada de método de direção alternativa de multiplicadores (ADMM). Os procedimentos de atualização de u_k podem ser expressos como:

$$\hat{u}_k^{n+1}(w) = \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i(w) + \frac{\hat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_k)^2} \quad (4)$$

onde \hat{u}_k^{n+1} , $\hat{f}(w)$, $\hat{\lambda}(w)$ representam as transformações de Fourier de u_k^{n+1} . A Equação 4 pode ser identificada como um filtro passa-baixa de Wiener centrado em torno da frequência u_k , com largura de banda definida por α . Nos procedimentos iterativos, a frequência central de cada modo é reestimada pelo espectro de potência. A Equação de atualização de w_k^{n+1} é (Dragomiretskiy and Zosso, 2014):

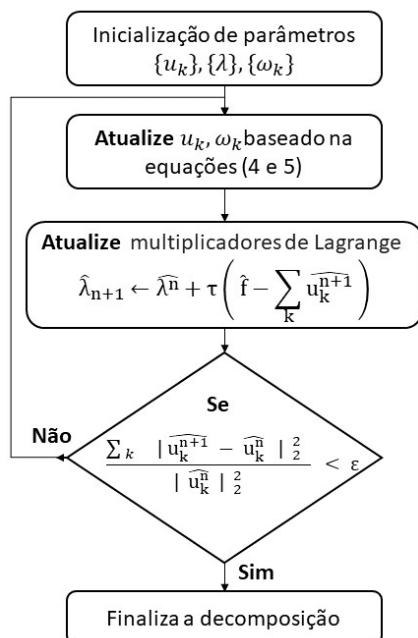
$$w_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(w)|^2 dw}{\int_0^\infty |\hat{u}_k(w)|^2 dw} \quad (5)$$

O processo da VMD continua até que o erro relativo seja menor que uma tolerância de convergência ε :

$$e = \frac{\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (6)$$

Segundo Dragomiretskiy and Zosso (2014), a VMD apresenta desempenho superior a EMD no que diz respeito a separação de frequências e robustez ao ruído. De acordo com os conceitos apresentados, as etapas do algoritmo da VMD na forma irrestrita são ilustradas no fluxograma na Figura 1.

Figura 1. Fluxograma do algoritmo da VMD.

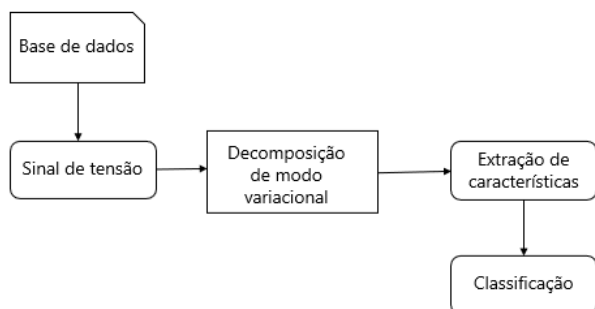


Fonte: Elaborado pelos autores.

3. METODOLOGIA

Nesta pesquisa, a metodologia proposta segue, em linhas gerais, o Diagrama em blocos apresentado na Figura 2.

Figura 2. Metodologia proposta.



Fonte: Elaborado pelos autores.

Os sinais de tensão com e sem distúrbios são obtidos por meio das equações paramétricas sintetizadas obtidas com base no modelo público disponibilizado por Igual et al. (2018), formando uma base de dados com nove distúrbios. Os sinais passam por uma etapa de pré-processamento, que consiste na decomposição do sinal através da VMD em funções de modo intrínseco IMFs. Na etapa de extração de características serão obtidos os atributos representativos de cada sinal. Os atributos de cada uma das classes em estudo serão submetidos a um classificador multiclasse que fará a detecção e discriminação entre os distúrbios.

3.1 Base de dados

A base de dados foi gerada a partir de equações paramétricas sintetizadas, conforme o modelo público disponibilizado por Igual et al (2018). A base contém nove classes de sinais, na qual possui uma classe composta por sinais ideais e oito classes de sinais com perturbações de tensão, sendo esta: Afundamento de tensão, Elevação de tensão, Interrupção, Transitório impulsivo, Transitório oscilatório, Harmônico, Flicker, Notching.

A Figura 3 ilustra os distúrbios em análise. Cada sinal desta base representa uma forma de onda de tensão com duração de 10 ciclos. As amplitudes dos sinais sintéticos foram normalizadas para 1 p.u. A frequência fundamental foi definida em 60 Hz e a frequência de amostragem em 15,6 kHz, em consonância com a frequência usual dos Registradores Digitais de Perturbação. Existem 2560 amostras em cada sinal sintético e foram gerados no total 9000 sinais distintos, sendo 1000 sinais para cada classe de distúrbio e 1000 de sinais ideais sem perturbações.

3.2 Decomposição VMD

Os sinais presentes na base de dados são decompostos pela VMD em IMFs, nas quais apresentam características na amplitude, tempo e frequência que mostram-se relevantes para classificação das DQEEs.

A Figura 4 mostra o resultado final da decomposição em 4 IMFs utilizando VMD em um sinal de tensão elétrica ideal e outro com a presença de harmônicos. Cada IMF apresenta uma frequência central.

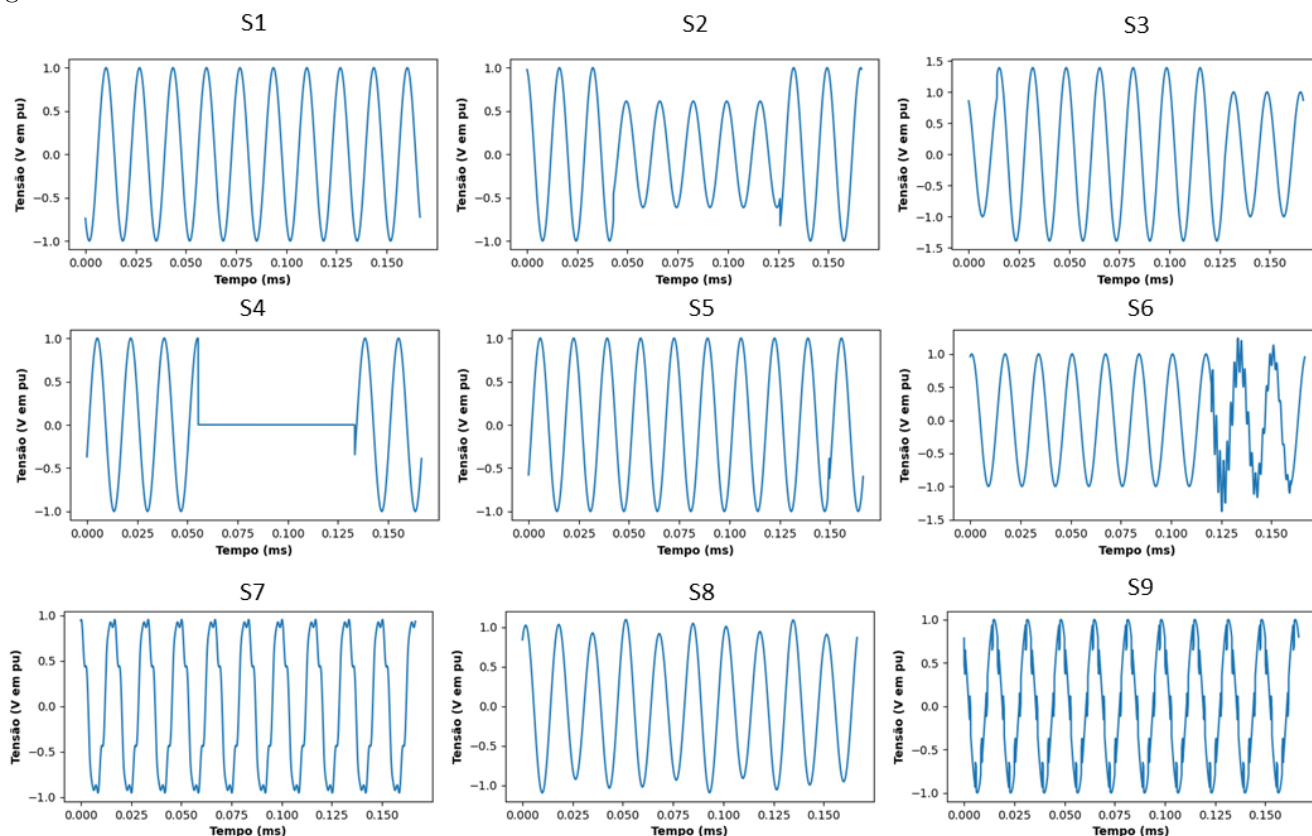
3.3 Extração de atributos

Para o reconhecimento de diferentes distúrbios de QEE, a extração de características desempenha um papel importante nos esquemas de reconhecimento de padrões. As vantagens de representar um sinal usando estatísticas para análise são robustez e simplicidade (Jena et al. (2018)). Para este trabalho, os atributos foram extraídos das IMFs, sendo estes: Valor máximo, valor mínimo, Taxa de cruzamento por zeros (TCZ), Energia, Curtose, distorção e RMS, sendo estas matematicamente apresentadas na Tabela 1.

Tabela 1. Atributos.

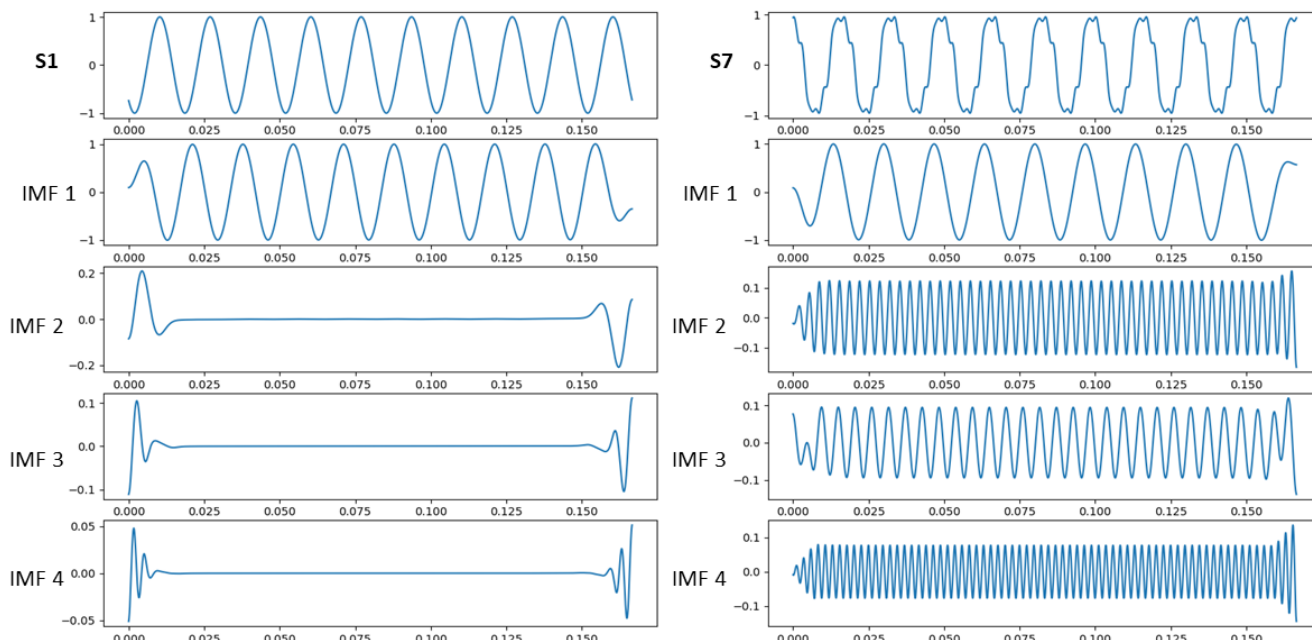
Num	Atributos	Equação
1	Energia	$\frac{1}{N} \sum_{i=1}^N x_i^2$
2	TCZ	$\frac{1}{N} \sum_{i=1}^N \frac{\text{sgn}[s(n)] - \text{sgn}[s(n-1)]}{2}$
3	Curtose	$\frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{\sigma} \right)^3$
4	Distorção	$\frac{N \sum_{i=1}^N (x_i - \bar{x})^3}{(N-1)(N-2)\sigma^3}$
5	Valor máximo	$\max(x_i)$
6	RMS	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$

Figura 3. Distúrbios de tensão.



Fonte: Elaborado pelos autores.

Figura 4. VMD do sinal de tensão sem distúrbios e VMD do sinal de tensão com harmônicos.



Fonte: Elaborado pelos autores.

3.4 Classificação e validação

O algoritmo RF se trata de uma associação de árvores de decisão (*Decision Trees - DT*), no qual apresenta-se como um algoritmo robusto para modelagem de dados

sob presença de outliers e em espaços de parâmetros dimensionais muito altos. Baseado na metodologia do subespaço aleatório, o algoritmo RF utiliza do critério de impureza de Gini para avaliar o poder de predição durante

a etapa de treinamento, em que a convergência tem como princípio a redução da impureza (Sarica et al., 2017).

Nesta pesquisa, foi implementado o algoritmo RF por meio da biblioteca de computação científica *Sklearn* disponibilizada em linguagem *Python*. O classificador foi composto por 200 árvores de decisão. O treino e validação do modelo RF foi realizado por meio de validação cruzada do tipo *k-fold*. Esta técnica consiste em dividir aleatoriamente os dados em *k* subconjuntos. Dessa forma, *k* - 1 conjuntos são utilizados para o treinamento do classificador e o conjunto restante será empregado na etapa de validação. O processo ocorre até que todos os conjuntos sejam aplicados na etapa de validação. Neste trabalho, o número de *folders* foi definido como *k* = 10.

A avaliação de desempenho de um algoritmo de classificação consiste em verificar se a classe prevista corresponde, de fato, à classe da amostra de entrada. Dessa forma os valores são classificados em quatro possíveis opções:

VP: verdadeiro positivo, para valores de eventos previstos corretamente.

FP: Falso positivo, para valores de eventos previstos incorretamente.

FN: Falso negativo, para valores sem eventos previstos incorretamente.

VN: verdadeiro negativo, para valores sem eventos previstos corretamente.

A métrica de desempenho utilizada foi a acurácia para a avaliação do desempenho do RF. Ela indica a capacidade do algoritmo de classificar as amostras corretamente. É matematicamente expressa pela Equação 7.

$$\text{Acurácia} = \frac{\text{VP} + \text{VN}}{\text{VP} + \text{VN} + \text{FP} + \text{FN}} \quad (7)$$

4. RESULTADOS

O desempenho do método proposto pode ser observado na Tabela 2 que indica a matriz de confusão da classificação de DQEEs para os conjuntos de dados na etapa de validação. É possível observar a quantidade de sinais que foram classificados corretamente ou erroneamente.

Tabela 2. Matriz de confusão.

	S1	S2	S3	S4	S5	S6	S7	S8	S9
S1	1000	0	0	0	0	0	0	0	0
S2	1	990	0	8	0	1	0	0	0
S3	0	0	1000	0	0	0	0	0	0
S4	0	13	0	987	0	0	0	0	0
S5	0	0	0	0	999	1	0	0	0
S6	0	0	0	0	3	995	2	0	0
S7	0	0	0	0	0	7	993	0	0
S8	0	0	0	0	0	0	0	1000	0
S9	0	0	0	0	0	0	0	0	1000

A partir da Tabela 2 calcula-se que o método proposto obteve uma acurácia em torno de 99,71% na etapa de classificação. Observa-se alguns erros de discriminação de distúrbios provocados pela semelhança dinâmica de algumas classes.

A exemplo, cita-se a confusão presente entre sinais afetados pelo distúrbio do tipo Interrupção (S4) e Afundamento de Tensão (S2), fenômeno este ocorrente pelo fato de ambos os distúrbios provocarem uma diminuição nos níveis de tensão presentes no sinal. Deste modo, os atributos extraídos após a decomposição dos sinais afetados por tais distúrbios podem ficar em uma faixa de valores semelhantes entre si, o que os torna mais difíceis de serem linearmente separáveis.

A Tabela 3 apresenta uma análise comparativa com outras pesquisas que tiveram como objetivo realizar a correta detecção de sinais afetados por DQEE utilizando outras técnicas de processamento de sinais e ML.

Tabela 3. Acurácia da classificação .

Autores	Acurácia
Jena et al. (2018)	94,4
Chakravorti and Satyanarayana (2019)	98,75%
Rodriguez et al. (2019)	81%
Samal et al. (2020)	99%
Método proposto	99,71%

5. CONCLUSÃO

A utilização de medidas que possam mitigar a ocorrência de distúrbios da qualidade da energia elétrica depende de um contínuo monitoramento da rede e de uma análise computacional, capaz de identificar e classificar tais distúrbios de forma automática. Este trabalho aborda esta temática e destaca a metodologia de decomposição variacional de modos.

Os resultados demonstraram que a metodologia proposta possui alta precisão de classificação e é adequada para a detecção de vários sinais de perturbação. A simplicidade e eficácia possibilitam a aplicação à tecnologia de monitoramento on-line por meio de sistemas que possam executar aplicações em linguagem *Python*. A pesquisa abre espaço para que em trabalhos futuros um sistema embarcado baseado no algoritmo seja implementado para detectar efetivamente distúrbios de qualidade de energia em aplicações de tempo real.

AGRADECIMENTOS

Os autores agradecem ao Instituto Federal da Paraíba e ao apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

REFERÊNCIAS

- Achlerkar, P.D., Samantaray, S.R., and Sabarimalai Manikandan, M. (2018). Variational mode decomposition and decision tree based detection and classification of power quality disturbances in grid-connected distributed generation system. *IEEE Transactions on Smart Grid*, 9(4), 3122–3132.
- Chakravorti, T. and Satyanarayana, P. (2019). Classification of power quality disturbances using adaptive variational mode decomposition based random vector functional link network. In *2019 IEEE Region 10 Symposium (TENSYP)*, 721–726.

- Dragomiretskiy, K. and Zosso, D. (2014). Variational mode decomposition. *IEEE transactions on signal processing*, 62(3), 531–544.
- Elphick, S., Ciufu, P., Smith, V., and Perera, S. (2015). Summary of the economic impacts of power quality on consumers. In *2015 Australasian Universities Power Engineering Conference (AUPEC)*, 1–6. IEEE.
- Giacomini Junior, J. (2020). Alocação inteligente de geração fotovoltaica em redes elétricas de distribuição para redução de perdas financeiras em consumidores industriais sensíveis a afundamentos de tensão.
- Hong, W., Liu, Z., and Wu, X. (2021). Power quality disturbance recognition based on wavelet transform and convolutional neural network. In *2021 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA)*, 193–197. IEEE.
- Igual, R., Medrano, C., Arcega, F.J., and Mantescu, G. (2018). Integral mathematical model of power quality disturbances. In *2018 18th International Conference on Harmonics and Quality of Power (ICHQP)*, 1–6.
- Jamali, S., Farsa, A.R., and Ghaffarzadeh, N. (2018). Identification of optimal features for fast and accurate classification of power quality disturbances. *Measurement*, 116, 565–574.
- Jena, S.K., Ray, P., and Babu, M.K. (2018). Assessment of power quality events by emd based hilbert transform and s-transform using different classifiers. In *2018 International Conference on Recent Innovations in Electrical, Electronics Communication Engineering (ICRIEECE)*, 354–359.
- Kubendran, A.K.P. and Kumar, L.A. (2020). Detection and classification of power quality events using wavelet energy difference and support vector machine. In *Proceedings of International Conference on Artificial Intelligence, Smart Grid and Smart City Applications: AISGSC 2019*, 21. Springer Nature.
- Oliveira, T.T.d. (2019). Estudo da distorção harmônica em redes de distribuição de baixa tensão com sistemas fotovoltaicos e veículos elétricos.
- Prasad, D.D., Chandini, B.L., Mahesh, S., Naveen, S.S., and Babu, S.M. (2021). Power quality improvement in wecs using ann-statcom. *Science and Technology*, 7(0707059), 160–165.
- Reddy, M.V. and Sodhi, R. (2017). A modified s-transform and random forests-based power quality assessment framework. *IEEE Transactions on Instrumentation and Measurement*, 67(1), 78–89.
- Rodriguez, M.A., Sotomonte, J.F., Cifuentes, J., and Bueno-López, M. (2019). Classification of power quality disturbances using hilbert huang transform and a multilayer perceptron neural network model. In *2019 International Conference on Smart Energy Systems and Technologies (SEST)*, 1–6.
- Samal, L., Palo, H.K., and Sahu, B.N. (2020). Comparison of classifiers for power quality disturbances with wavelet statistical analysis. In *2020 International Conference on Computational Intelligence for Smart Power System and Sustainable Energy (CISPSSE)*, 1–5.
- Sarica, A., Cerasa, A., and Quattrone, A. (2017). Random forest algorithm for the classification of neuroimaging data in alzheimer’s disease: a systematic review. *Frontiers in aging neuroscience*, 9, 329.
- Wang, Y., Liu, F., Jiang, Z., He, S., and Mo, Q. (2017). Complex variational mode decomposition for signal processing applications. *Mechanical systems and signal processing*, 86, 75–85.
- Zhong, T., Zhang, S., Cai, G., Li, Y., Yang, B., and Chen, Y. (2019). Power quality disturbance recognition based on multiresolution s-transform and decision tree. *IEEE Access*, 7, 88380–88392.