

# Aplicação da Decomposição Variacional de Modos na avaliação da presença de Distúrbios da Qualidade da Energia Elétrica

Maísa L. F. Santos, Suzete E. N. Correia, Cleumar S. Moreira, Alvaro M. Maciel, Edgard L. L. Fabricio

**Resumo**—Este artigo aborda a utilização da Decomposição Variacional de Modos (*Variational Mode Decomposition*, VMD) e o algoritmo de classificação *Random Forest* (RF), aplicados à classificação de Distúrbios da Qualidade da Energia Elétrica (DQEE). Os distúrbios elétricos foram gerados e acrescidos de ruídos gaussianos. A VMD foi utilizada para decompor os sinais em Funções de Modo de Intrínseco (*Intrinsic Mode Function*, IMFs). Foram obtidas características de cada IMF, o modelo RF foi então parametrizado para classificar os DQEE com base nessas características. O método implementado atingiu acurácia de classificação de 99,49% para sinais sob ruído de 50 db, demonstrando a versatilidade e o grande potencial que este método proporciona.

**Palavras-Chave**—Distúrbios da Qualidade da Energia Elétrica, Decomposição variacional de Modos, Processamento de Sinais.

**Abstract**—This paper discusses the use of *Variational Mode Decomposition* (VMD) and the *Random Forest* (RF) classification algorithm, applied to the classification of *Electric Power Quality Disturbances* (PQD). Electrical disturbances were generated and with *Gaussian noise*. VMD has been used to decompose the signals into *Intrinsic Mode Functions* (IMFs). characteristics of each IMF were the RF model has been parameterized to classify the DQEEs based on these characteristics. The implemented method achieved classification accuracy of 99.49% under 50 db noise, demonstrating the versatility and great potential that this method provides.

**Keywords**—Power quality disturbances, Classification, Variational mode decomposition, Signal processing.

## I. INTRODUÇÃO

O monitoramento e controle da qualidade da energia elétrica são preocupações importantes, tanto para as concessionárias de energia quanto para os consumidores, no cenário atual do setor elétrico [1]. Nas últimas décadas, o número crescente de cargas não lineares, as operações de comutação de grandes cargas elétricas e o amplo uso de dispositivos com interfaces que usam eletrônica de potência tornaram-se as principais fontes de Distúrbios da Qualidade da Energia Elétrica (DQEE) [2].

Tecnologias que representam mudanças na sociedade e têm repercussão nos sistemas elétricos de potência, como a geração distribuída e os veículos elétricos, são tecnologias emergentes que tendem a crescer e a se sobrepor geograficamente. Ambos acessam a rede por meio de conversores eletrônicos de potência presentes em carregadores e inversores, e essa conexão

acentuada de cargas não lineares aumentam a complexidade dos problemas de qualidade da energia [3].

São amplos e diversos os impactos econômicos em virtude de DQEE em alguns casos, o impacto da perturbação pode ser imediatamente perceptível podendo citar danos aos equipamentos, custos de reinicialização de sistemas, perda de processo produtivo ou inatividade. Em outros casos, o impacto só é observado com o tempo, com o envelhecimento de equipamentos e a necessidade de substituições [4].

Assim, torna-se essencial identificar e classificar os DQEE, para que ações de mitigação possam ser tomadas para fornecer energia de boa qualidade aos clientes. Os métodos e procedimentos para identificação e classificação dos DQEE estão definidos em normas técnicas, dentre elas tem-se a IEEE-1159, a EN 50160 e a IEC 61000-4-30 [2].

No estado da arte, diversos estudos abordam técnicas de processamento de sinais combinadas com algoritmos de aprendizagem de máquina aplicadas na detecção de DQEE. Em Rodriguez [5], utilizou-se a Transformada de Hilbert-Huang e o modelo de rede neural *Multilayer Perceptron* (MLP) para detectar e classificar sinais afetados por distúrbios na qualidade de energia.

Na pesquisa apresentada em Sahani [6], realizou-se a aplicação da *Empirical Mode Decomposition* (EMD) e a transformada de Hilbert Huang em sinais afetados por DQEE, associado a sistema de classificação baseado em algoritmo *Random Florest*, para detectar e classificar os eventos de qualidade de energia em tempo real.

Por sua vez, Meena [7] aplicou-se a Transformação de *Stockwell* em sinais afetados por DQEE, em que extraiu-se uma série de atributos, nos quais foram utilizados por um sistema de classificação composto por uma árvore de decisão baseada em regras pré-definidas pelo autor a fim de realizar a detecção e classificação de distúrbios complexos de qualidade de energia.

Outra técnica de decomposição de sinais foi proposta por Dragomiretskiy e Zosso, sendo esta denominada decomposição variacional de modos (VMD), na qual trata-se de uma técnica mais robusta desenvolvida para superar as desvantagens da EMD [8]. Cada modo possui uma frequência central que é gradualmente demodulada para a banda base correspondente. A largura de banda dos modos intrínsecos da VMD é estreita, extraindo com precisão as componentes de frequência próximas presentes no sinal 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 [8].

Nesta pesquisa propõe-se a utilização da decomposição variacional de modos (VMD) para decomposição dos sinais afetados por DQEE, a fim de obter uma série de IMFs para extração de atributos que representem a dinâmica do sinal. Tais atributos serão utilizados em sistema de classificação baseado em algoritmo Random Forest (RF), de modo a obter a identificação e classificação de sinais com a presença de DQEE sob efeitos de ruídos gaussianos em diferentes faixas de valores de relação sinal/ruído (SNR), sendo estas de 30 dB, 40 dB e 50 dB.

## II. DECOMPOSIÇÃO VARIACIONAL DE MODO

Dragomiretskiy e Zosso em 2014 propuseram uma decomposição inspirada na Decomposição de Modo Empírica, chamada de Decomposição Variacional de Modos. O método assume que o sinal original é composto por uma quantidade das chamadas Funções de Modo Intrínseco (IMFs),  $u_k$ , que são estabelecidas como componentes AM-FM [8]:

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

em que  $A(t)$  e  $\phi(t)$  representam, respectivamente, a amplitude instantânea e a fase instantânea de  $u_k(t)$ . A frequência central da IMF é considerada a frequência instantânea correspondente  $w(t) = \phi(t)$ . A largura de banda para cada modo  $u_k$  pode ser estimada através do seguinte procedimento:

O objetivo da VMD é decompor um sinal multicomponente em um número finito de sub-sinais de banda limitada (modos),  $u_k(t)$ , que se compactam em torno de uma frequência central  $w_k(t)$ . A técnica VMD primeiro utiliza a transformada de Hilbert para converter cada modo  $u_k(t)$  em uma expressão analítica  $u_k^+(t)$  em um domínio espectral unilateral para obter a largura de banda de cada função de modo:

$$u_k^+(t) = \left( \delta(t) + \frac{j}{\pi t} \right) u_k(t) \quad (2)$$

Após a transformação de Hilbert, o espectro de frequência de cada modo é deslocado para a banda base e a frequência central estimada  $w_k(t)$  correspondente ajustada usando um termo exponencial. Posteriormente, a largura de banda é estimada de acordo com a suavidade gaussiana do sinal demodulado, utilizando a norma  $L^2$  quadrada do gradiente. Assim, o processo VMD é realizado resolvendo um problema variacional restrito [8]:

$$\min_{\{u_k\}, \{w_k\}} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \quad (3)$$

$$\sum_k u_k = f$$

em que,  $\{u_k\} = \{u_1 \dots u_k\}$  correspondem aos conjuntos de IMFs,  $\{w_k\} = \{w_1 \dots w_k\}$  correspondem as frequências centrais a determinar. Para resolução do problema de otimização restrito apresentado na Equação 4 são adotados a penalidade quadrática  $\alpha$  e os multiplicadores Lagrangianos  $\lambda$  com o objetivo de tornar a otimização irrestrita [10].

$$L(\{u_k\}, \{w_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (4)$$

O método de direção alternativa de multiplicadores (ADMM) corresponde a uma sequência de otimização utilizada para obter a solução, atualizando a frequência central e a largura de banda de cada FMI. Os procedimentos de atualização de  $u_k$  podem ser expressos como:

$$\hat{u}_k^{n+1}(w) = \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i(w) + \frac{\hat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_k)^2} \quad (5)$$

em que,  $\hat{u}_k^{n+1}$ ,  $\hat{f}(w)$ ,  $\hat{\lambda}(w)$  representam as transformações de Fourier de  $u_k^{n+1}$ . A Equação 5 pode ser identificada como um filtro passa-baixa de Wiener centrado em torno da frequência  $w_k$ , com largura de banda definida por  $\alpha$ . Nos procedimentos iterativos, a frequência central de cada modo é re-estimada pelo espectro de potência. A equação de atualização de  $w_k^{n+1}$  é dada por[8]:

$$w_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(w)|^2 dw}{\int_0^\infty |\hat{u}_k(w)|^2 dw} \quad (6)$$

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

$$e = \frac{\sum_k \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2}{\left\| \hat{u}_k^n \right\|_2^2} < \varepsilon \quad (7)$$

## III. METODOLOGIA

Neste trabalho, a metodologia adotada é realizada em três etapas. Inicialmente são adquiridos por meio das equações paramétricas os sinais de tensão com e sem distúrbios. Tais equações foram obtidas com base no modelo público disponibilizado por Igual [11]. A segunda etapa consiste em aplicar pré-processamento nos sinais da base, nos quais são decompostos por meio do algoritmo da VMD em funções de modo intrínseco IMFs. Na terceira etapa, realiza-se a extração de atributos obtidos por meio de métricas aplicadas a cada sinal. Na quarta etapa as métricas de cada uma das classes são submetidas a um sistema classificador multiclasse baseado em algoritmo *Random Forest* com o objetivo de realizar a detecção e discriminação entre os distúrbios em estudo.

### A. Base de dados

Com base nas equações paramétricas disponibilizado por [11], gerou-se a base de dados denominada de BD01. Tal base contém nove classes de sinais, sendo uma classe composta por sinais ideais e demais por: (S1) Sinal puro (S2) Afundamento de Tensão, (S3) Elevação de Tensão, (S4) Interrupção, (S5) Transitório Impulsivo, (S6) Transitório Oscilatório, (S7) Harmônico, (S8) Flicker, (S9) Notching.

A Figura 1 ilustra os distúrbios presentes na BD01. Para a BD01 foram gerados 9000 sinais distintos, sendo 1000 de sinais ideais sem perturbações e 1000 sinais para cada uma das oito classe de distúrbio. Cada sinal representa uma forma de

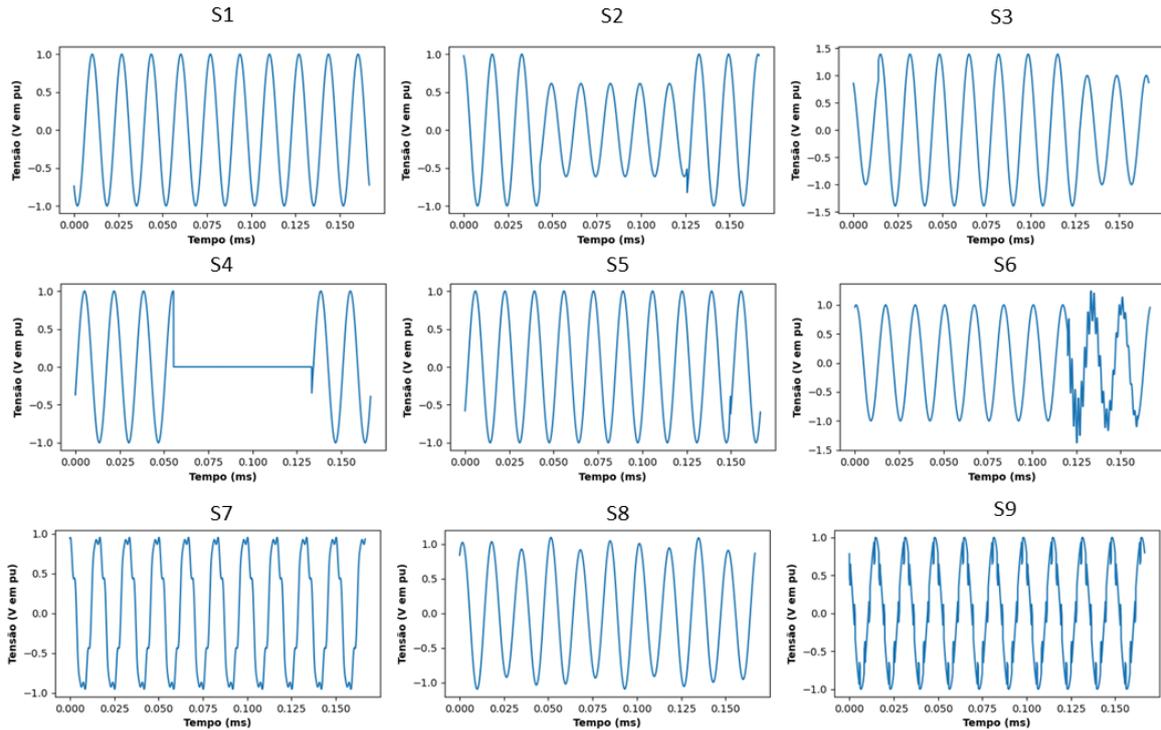


Fig. 1. Distúrbios de tensão em análise.

onda de tensão com duração de 10 ciclos. A frequência de amostragem foi definida em 15,6 kHz, em consonância com a frequência usual dos Registradores Digitais de Perturbação e a frequência fundamental foi definida em 60 Hz. As amplitudes dos sinais sintéticos foram normalizadas para 1 p.u, contendo 2560 amostras cada sinal.

Com o intuito de avaliar a robustez do método proposto, criou-se as bases de dados BD02, BD03 e BD04 compostas pelos mesmos sinais da BD01, acrescidos de a ruídos com valores de SNR iguais a, respectivamente, 30 dB, 40 dB e 50 dB.

### B. Decomposição VMD

Os sinais presentes na base de dados são decompostos pela VMD em IMFs. As IMFs decompostas representam partes estacionárias separadas (DC, fundamentais, harmônicas, inter-harmônicas.) em torno de sua frequência central, nas quais apresentam características na amplitude, tempo e frequência que mostram-se relevantes para classificação das DQEEs.

A Figura 2 ilustra a decomposição em 4 IMFs utilizando VMD, de um sinal de tensão elétrica puro (S1) e outro com a presença de harmônicos (S7) com ruído associado de 30dB em ambos. A primeira IMF apresenta o sinal com frequência central de 60Hz. As IMFs posteriores estão centradas nas frequências das componentes harmônicas do sinal e do ruído associado.

### C. Extração de atributos

Para a identificação de diferentes DQEE, a extração de atributos apresenta uma função importante no processo de

reconhecimento de padrões. As principais vantagens de representar um sinal usando atributos para análise são robustez e simplicidade [12]. Para esta pesquisa, 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 I.

 TABELA I  
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	$\frac{1}{N} \sum_{i=1}^N \left( \frac{x_i - \bar{x}}{\sigma} \right)^4$
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	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$

### D. Classificação e validação

O algoritmo RF se trata de uma combinação de árvores de decisão (*Decision Trees - DT*), no qual sob presença de *outliers* demonstra ser um algoritmo robusto para modelagem de dados, também é utilizado em espaços de parâmetros dimensionais elevados. Embasado na metodologia do subespaço



TABELA IV

MATRIZ DE CONFUSÃO BD03 RÚIDO SNR DE 40 DB.

	S1	S2	S3	S4	S5	S6	S7	S8	S9
S1	953	0	0	0	47	0	0	0	0
S2	0	989	0	10	1	0	0	0	0
S3	0	0	998	0	0	0	0	2	0
S4	0	12	0	988	0	0	0	0	0
S5	120	0	0	0	879	1	0	0	0
S6	0	0	0	0	2	992	3	0	0
S7	0	0	0	0	0	0	1000	0	0
S8	0	0	0	0	0	0	0	1000	0
S9	0	0	0	0	3	0	0	0	997

TABELA V

MATRIZ DE CONFUSÃO BD04 RÚIDO SNR DE 50 DB.

	S1	S2	S3	S4	S5	S6	S7	S8	S9
S1	997	0	0	0	3	0	0	0	0
S2	0	994	0	5	1	0	0	0	0
S3	0	0	999	0	0	0	0	1	0
S4	0	16	0	984	0	0	0	0	0
S5	17	0	0	0	983	1	0	0	0
S6	1	0	0	0	3	996	2	0	0
S7	0	0	0	0	0	4	996	0	0
S8	0	0	0	0	0	0	0	1000	0
S9	0	0	0	0	0	0	0	0	1000

Algumas classes de distúrbios apresentam uma semelhança dinâmica com isso, é possível Observar alguns erros de discriminação provocados por essa similaridade, como por exemplo a confusão presente entre sinais afetados pelo distúrbio do tipo Afundamento de Tensão (S2) e Interrupção (S4), este fenômeno acontece devido ao fato de ambos os distúrbios ocasionarem uma atenuação nos níveis de tensão presentes no sinal. Desta maneira, os atributos extraídos após a aplicação da decomposição VMD dos sinais que apresentam tais distúrbios podem ficar em uma faixa de valores similares entre si, o que os tornam mais difíceis de serem separáveis linearmente.

Para diferentes tipos de perturbações simuladas de DQEE, as taxas de classificação do método proposto são apresentadas na Tabela VI. Os melhores resultados apresentaram acurácia de 99,7% para a base sem ruído, e 99,4% para ruído de 50dB. A taxa de classificação diminui conforme o nível de ruído aumenta, mas ainda acima de 93% para SNR de 30 dB. Isso se deve à estreita relação da equação de atualização da IMFs com a filtragem Wiener, consequentemente afetando os atributos de tal forma que a dinâmica aleatória do ruído não correspondam uma dinâmica padrão, interferindo na qualidade da representação destes sinais e dificultando a classificação.

TABELA VI

ACURÁCIA DA CLASSIFICAÇÃO .

BD01	BD02	BD03	BD04
99,7% ± 0,3%	93,5% ± 0,6%	97,7% ± 0,5%	99,4% ± 0,3%

## V. CONCLUSÕES

A aplicação de estratégias que possam mitigar a ocorrência de distúrbios da qualidade da energia elétrica, necessita de um monitoramento contínuo da rede elétrica e de uma análise

computacional de dados, capazes de identificar e classificar tais distúrbios de forma precisa e automática.

Os resultados da pesquisa, revelaram que a metodologia proposta é eficaz para a detecção de vários sinais de perturbação e possui elevada precisão de classificação. A robustez e precisão do método proposto é verificada com diferentes valores de relação sinal/ruído (SNR). A praticidade e eficiência propiciam a aplicação à tecnologia de monitoramento *in real time* por meio de sistemas que possam executar aplicações em linguagem *Python*, a exemplo da *raspberrypi*. Para trabalhos futuros deseja-se implementar o algoritmo em um sistema embarcado para detectar efetivamente distúrbios de qualidade de energia em aplicações de tempo real.

## AGRADECIMENTOS

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

## REFERÊNCIAS

- [1] A. A. P. Biscaro, R. A. F. Pereira, M. Kezunovic, and J. R. S. Mantovani, "Integrated fault location and power-quality analysis in electric power distribution systems," *IEEE Trans. Power Del.*, vol. 31, no. 2, pp. 428–436, Apr. 2016.
- [2] Y. Yu, W. Zhao, S. Li and S. Huang, "A Two-Stage Wavelet Decomposition Method for Instantaneous Power Quality Indices Estimation Considering Interharmonics and Transient Disturbances," in *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 1-13, 2021, Art no. 9001813.
- [3] T. T. Oliveira, "Estudo da distorção harmônica em redes de distribuição de baixa tensão com sistemas fotovoltaicos e veículos elétricos," 2019.
- [4] S. Elphick, P. Ciuffo, V. Smith, and S. Perera, "Summary of the economic impacts of power quality on consumers," in *2015 Australasian Universities Power Engineering Conference (AUPEC)*, pp. 1–6, IEEE, 2015.
- [5] M. A. Rodriguez, J. F. Sotomonte, J. Cifuentes and M. Bueno-López, "Classification of Power Quality Disturbances using Hilbert Huang Transform and a Multilayer Perceptron Neural Network Model," *2019 International Conference on Smart Energy Systems and Technologies (SEST)*, 2019, pp. 1-6.
- [6] M. Sahani, S. Choudhury, S. Kumar Rout and D. Amaresh Gadanayak, "DSP Based Online Power Quality Events Detection and Classification Using Hilbert Huang Transform and Random Forest Method," *2020 International Conference on Computational Intelligence for Smart Power System and Sustainable Energy (CISPSSE)*, 2020, pp. 1-6.
- [7] M. Meena, O. P. Mahela, M. Kumar and N. Kumar, "Detection and Classification of Complex Power Quality Disturbances Using Stockwell Transform and Rule Based Decision Tree," *2018 International Conference on Smart Electric Drives and Power System (ICSEDPS)*, 2018, pp. 220-226, doi: 10.1109/ICSEDPS.2018.8536028.
- [8] K. Dragomiretskiy and D. Zosso, "Variational Mode Decomposition," in *IEEE Transactions on Signal Processing*, vol. 62, no. 3, pp. 531-544, Feb.1, 2014.
- [9] S. R. Moreno, "Modelo híbrido de decomposição multiestágio aplicado à previsão de séries temporais de velocidades de vento," 2019.
- [10] Y. WANG, et al. "Complex variational mode decomposition for signal processing applications," *Mechanical systems and signal processing*, v. 86, p. 75-85, 2017.
- [11] R. Igual, C. Medrano, F. J. Arcega and G. Mantescu, "Integral mathematical model of power quality disturbances," *2018 18th International Conference on Harmonics and Quality of Power (ICHQP)*, 2018, pp. 1-6.
- [12] S. K. Jena, P. Ray and M. K. Babu, "Assessment of Power Quality Events by EMD based HILBERT Transform and S-Transform using Different Classifiers," *2018 International Conference on Recent Innovations in Electrical, Electronics Communication Engineering (ICRIECE)*, 2018, pp. 354-359.
- [13] A. Sarica, A. Cerasa, A. QuattroneE, "Random forest algorithm for the classification of neuroimaging data in Alzheimer's disease: a systematic review. *Frontiers in aging neuroscience*", 2017, v. 9, p. 329.