

## DETECÇÃO ADAPTATIVA DE NOVIDADES BASEADA EM MÉTRICA DE SIMILARIDADE APLICADA A SINAIS DE QUALIDADE DE ENERGIA

FABRÍCIO CARNEIRO TRAVASSOS\*, EDER BARBOZA KAPISCH\*, LEANDRO RODRIGUES MANSO SILVA\*, MARCELO ANTÔNIO ALVES LIMA\*, CARLOS AUGUSTO DUQUE\*

\*Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, Juiz de Fora, MG, Brasil

Emails: fabricio.travassos@engenharia.ufjf.br,  
eder.kapisch@engenharia.ufjf.br, leandro.manso@engenharia.ufjf.br,  
marcelo.lima@engenharia.ufjf.br, carlos.duque@engenharia.ufjf.br

**Abstract**— This article presents a method for detecting novelties related to electrical disturbances in power signals. The presented method uses a similarity metric as a detection parameter with an adaptive threshold that is adjusted to different waveforms. An adaptation to the detector to improve its performance is proposed. Simulation tests are performed, showing the effectiveness of the technique with different types of disturbances, and a comparison with another detection technique present in the literature is performed.

**Keywords**— Novelty Detection, Power Quality, Similarity Metric.

**Resumo**— O presente artigo apresenta um método de detecção de novidades relativas a distúrbios elétricos em sinais de potência. O método apresentado utiliza uma métrica de similaridade como parâmetro de detecção com um limiar adaptável que se ajusta a diferentes formas de onda. Uma adaptação ao detector é proposta, a fim de melhorar seu desempenho. São realizados testes de simulação, mostrando a eficácia do mesmo em detectar diferentes tipos de distúrbios e comparações do seu desempenho em relação a outra técnica de detecção presente na literatura são realizadas.

**Palavras-chave**— Detecção de Novidades, Qualidade de Energia Elétrica, Métrica de Similaridade.

### 1 Introdução

Com a significativa evolução dos Sistemas Elétricos de Potência (SEP) a partir de estruturas convencionais para sistemas inteligentes, diversos aspectos devem ser considerados. Dentre estes aspectos, um dos quais vêm ganhando crescente destaque é o conceito de Qualidade de Energia Elétrica (QEE) (Naderi et al., 2020). Esse cenário de expansão e adaptação tecnológica dos SEP faz parte do estabelecimento das chamadas Redes Elétricas Inteligentes (REI) (Rezkallah et al., 2019).

A importância que uma boa QEE possui na operação do SEP tem despertado a atenção e esforços tanto da academia quanto dos profissionais do campo técnico no desenvolvimento de produtos e soluções em conformidade com padrões e normas de QEE (IEEE, 2019).

A alta diversidade na geração e utilização da energia elétrica tem afetado a QEE nos diversos segmentos do SEP (San et al., 2020). Nos anos recentes, tanto nos ambientes industriais, quanto em comerciais bom como nos residenciais, a maior parte dos dispositivos elétricos e eletrônicos têm feito uso de alimentação através de inversores, os quais possuem características altamente não lineares, inserindo distorções harmônicas nos sinais de tensão e corrente (Jain, 2018).

Além das distorções harmônicas, outros distúrbios elétricos podem ocorrer. Quedas de tensão (*sags*), interrupções, elevações de tensão (*swells*) são exemplos de distúrbios que afetam a amplitude dos sinais. O desequilíbrio de cargas e um inadequado balanço geração/demanda podem causar desvios na frequência fundamental do sistema (Phadke e Thorp, 2017). Além disso, no cenário das REI, novos distúrbios elétricos ainda desconhecidos podem ocorrer (Kapisch et al., 2016).

A presença de distúrbios elétricos prejudica a QEE. Tal condição pode resultar em diversos problemas, como sobreaquecimento de cabos e transformadores, contribuindo para a redução da vida útil, variação na velocidade de máquinas rotativas, erros em equipamentos de medição, mau funcionamento de dispositivos de proteção, entre outros. Tais problemas, caso não tratados, podem resultar em instabilidade e, em casos extremos, no colapso do SEP (Johnson e Hassan, 2016).

A fim de contornar as situações indesejadas causadas pelos problemas de QEE, é necessário o desenvolvimento de sistemas que embarquem técnicas capazes de detectar qualquer evento relacionado a um distúrbio elétrico a partir da enorme quantidade de dados brutos de formas de onda provenientes dos medidores inteligentes (Kapisch et al., 2014). Para isso, técnicas de detecção de novidades podem ser úteis.

Nos últimos anos, muitos algoritmos de processamento de sinais têm sido desenvolvidos a fim de detectar as novidades presentes nas formas de onda de sinais de potência. Tais algoritmos fazem uso de técnicas como *short-time Fourier transform* (STFT), Transformada de Stockwell (ST), Transformada Hilbert-Huang (THH), filtros de Kalman, morfologia matemática, além de outras técnicas de inteligência artificial como redes neurais artificiais e probabilísticas (RNA e RNP), máquina de vetor de suporte (SVM) (Sahani et al., 2020).

Muitas das técnicas de detecção de novidade dependem de parâmetros definidos pelo usuário, fazendo com que alguns eventos na forma de onda sejam ignoradas pelo detector, resultando em perda de eventos. A fim de melhorar o desempenho do detector, de forma a aumentar a capacidade de detecção e reduzir os falsos positivos, técnicas adaptativas baseadas em *wavelets*, variação de energia e morfologia do sinal têm sido pro-

postas (Bastos e Santoso, 2019), (Kapisch et al., 2016), (Han e Zhou, 2016), (Silva et al., 2017).

Uma forma de detectar os eventos que afetam a QEE pode ser feita através da inspeção de alguns ciclos que ocorrem antes e depois do distúrbio (Carnovale e Ellis, 2003). Neste método, a separação entre as partes das formas de onda que sofrem variação das que não sofrem (parte estacionária) é feita através de uma métrica de similaridade, não sendo necessário o conhecimento prévio da forma de onda esperada, podendo assim detectar variações genéricas na forma de onda.

O método de detecção de novidades abordado neste artigo utiliza o mesmo princípio. Uma métrica de similaridade é aplicada a fim de comparar *frames* ou segmentos de tamanho fixo do sinal analisado. Um limiar de detecção relativo a essa métrica é utilizado para detectar as novidades. Assim, a detecção de eventos se dá de forma adaptativa.

Dessa forma, o presente trabalho está dividido da seguinte forma. Na Seção 2, é apresentado o desenvolvimento do método apresentado. Na Seção 3, alguns testes e resultados de detecção de novidades são apresentados. Por fim, na Seção 4, algumas conclusões são feitas.

## 2 Desenvolvimento do método

Nesta seção, é apresentado o desenvolvimento do método apresentado. Inicia-se com a descrição do pré-processamento, sendo seguida por algumas propriedades das métricas de similaridade. Em seguida, o limiar de detecção é mostrado.

### 2.1 Pré-processamento dos Dados

Os sinais tratados aqui são discretos no tempo, obtidos a partir da discretização dos sinais contínuos de tensão ou corrente. Considerando o sinal  $v(t)$  contínuo no tempo, sua forma discreta  $v[n]$  pode ser obtida coletando-se amostras igualmente espaçadas com período de amostragem  $T_s$ :

$$v[n] = v(nT_s) \text{ para } n \in \mathbb{N}, \quad (1)$$

onde  $n$  é o índice das amostras do sinal discreto  $x(n)$ .

Conforme dito na seção introdutória deste artigo, caso haja um desequilíbrio da potência gerada e a consumida, a frequência do sinal apresentar pequenas variações (Phadke e Thorp, 2017). Como a taxa de amostragem do sinal é fixa, se a frequência fundamental variar, diferentes ciclos do sinal não conterão a mesma quantidade de amostras. Nesse caso, não há amostragem síncrona e pode-se dizer que os ciclos não estão alinhados no tempo, mesmo que seus formatos sejam idênticos (J. Cordova et al., 2018). Assim, uma comparação entre ciclos realizada nesta condição pode gerar muitas detecções de novidade desnecessárias.

Uma possível representação de consecutivos ciclos de um sinal senoidal pode ser realizada plotando-se os módulos dos ciclos sobrepostos num mesmo gráfico.

Esse tipo de visualização possibilita a identificação de novidades no sinal. Caso o sinal não possua variações, as linhas dos ciclos consecutivos apresentam baixa ou quase nenhuma dispersão. Caso as linhas sejam dispersas, há indícios de novidades presentes no sinal.

A Figura 1 apresenta os módulos sobrepostos de vários ciclos de uma senoide cuja frequência fundamental do sinal sofre variação. A amplitude do sinal está normalizada. Um detector baseado na morfologia do sinal, isto é, no seu formato, poderia detectar diversas novidades desnecessárias.

A variação na frequência fundamental pode ser corrigida através da reamostragem do sinal, de forma que todos os ciclos possuam o mesmo número de amostras. Para realizar a amostragem do sinal, o primeiro passo é a estimação da frequência.

No presente trabalho, utiliza-se o método de cruzamento por zeros (Rodrigues et al., 2018) para a estimação da frequência fundamental do sinal. Uma vez estimada a frequência, o sinal é reamostrado em tempo real utilizando a metodologia descrita em (Ribeiro et al., 2013). Deste modo, após a reamostragem todos os ciclos apresentam o mesmo número de amostras e, portanto, métricas de similaridade podem ser empregadas de modo adequado.

Além disso, as métricas de similaridade utilizadas aqui são aplicadas na comparação de *frames* de tamanho fixo do sinal analisado. Cada *frame* é composto por uma sequência de  $N$  ciclos consecutivos, onde  $N$  é um número inteiro.

### 2.2 Métricas de Similaridade

Definindo-se um par de *frames* sucessivos que passaram por todas as etapas de pré-processamento como sendo  $x$  e  $y$ , onde  $x$  é o *frame* anterior à  $y$ , é possível determinar uma métrica de similaridade entre esses dois *frames*. Essa métrica  $\mathcal{S}$  determina o quão similar os *frames*  $x$  e  $y$  são entre si (Tan et al., 2016). Geralmente, a similaridade adquire valor unitário quando dois objetos sob comparação são idênticos e valor nulo quando os mesmos são completamente diferentes.

Dados três *frames*  $x$ ,  $y$  e  $z$  cujos elementos  $x_n$ ,  $y_n$  e  $z_n \in \mathbb{R}$ , as métricas de similaridade possuem algumas propriedades. Dentre elas, pode-se citar (Chen et al., 2009):

1.  $\mathcal{S}(x, y) = \mathcal{S}(y, x)$




Figura 1: Módulos sobrepostos de ciclos consecutivos de um sinal senoidal puro com variação na frequência fundamental.

2.  $\mathcal{S}(x, x) = 1$
3.  $\mathcal{S}(x, x) \geq \mathcal{S}(x, y)$
4.  $\mathcal{S}(x, y) + \mathcal{S}(y, z) \leq \mathcal{S}(x, z) + \mathcal{S}(y, y)$
5.  $\mathcal{S}(x, x) = \mathcal{S}(y, y) = \mathcal{S}(x, y) \Leftrightarrow x = y$

Neste trabalho, a métrica de similaridade Ruzicka é utilizada (Deza e Deza, 2009). Esta métrica pode ser expressa por:

$$\mathcal{S}(x_n, y_n) = \frac{\sum_{n=1}^{N_s} \min\{x_n, y_n\}}{\sum_{n=1}^{N_s} \max\{x_n, y_n\}} \quad (2)$$

onde  $x_n$  e  $y_n$  são as amostras de índice  $n$  dos *frames*  $x$  e  $y$  e  $N_s$  é o número total de amostras contidas em cada *frame*.

Um conceito complementar à métrica de similaridade é o conceito de dissimilaridade  $\mathcal{D}$ , o qual expressa a diferença entre os *frames* comparados. Uma métrica de dissimilaridade  $\mathcal{D}(x_n, y_n)$  relativa a métrica de similaridade Ruzicka adotada pode ser expressa por:

$$\mathcal{D}(x_n, y_n) = 1 - \mathcal{S}(x_n, y_n). \quad (3)$$

### 2.3 Limiar de detecção

São definidas pelo usuário uma constante de sensibilidade  $\gamma$  e uma da janela de referência  $l_r$ , a qual pode conter um ou mais *frames*. Supondo que estamos analisando o  $i$ -ésimo *frame* do sinal, o limiar de detecção  $\eta_i$  é definido como (Bastos e Santoso, 2019):

$$\eta_i = 1 - \gamma \times \text{mediana}(\mathcal{D}_{ref}), \quad (4)$$

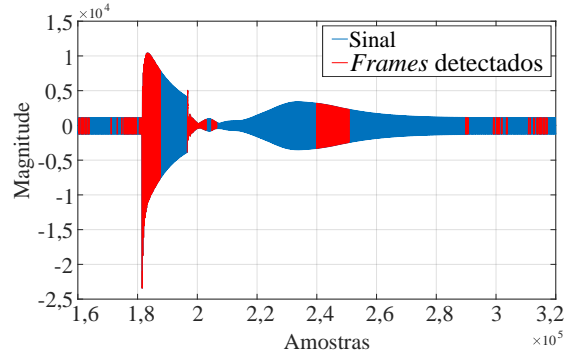
onde  $\mathcal{D}_{ref}$  é um vetor que armazena os valores de dissimilaridade dos *frames*  $i - l_r$  ao *frame*  $n$ . Cada elemento desse vetor é calculado de acordo com (3). Apesar do usuário definir o valor de  $\gamma$ , o valor do limiar  $\eta_i$  ainda é adaptativo de acordo com a métrica de similaridade adotada.

Uma detecção de novidade é identificada no momento em que o grau de similaridade é menor que o limiar de detecção, conforme descrito em (5):

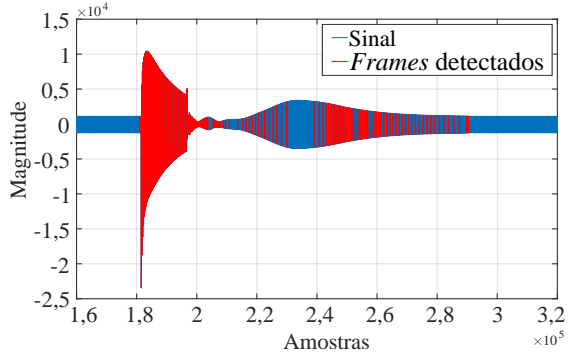
$$\mathcal{S}_i < \eta_i. \quad (5)$$

Diferente da estratégia apresentada em (Bastos e Santoso, 2019), onde a métrica de similaridade é sempre calculada entre dois *frames* consecutivos, este trabalho propõe uma adaptação, na qual cálculo da similaridade é realizado considerando-se o *frame* atual e um *frame* de referência, que só é atualizado quando uma nova detecção de novidade ocorre. O *frame* de referência considerado é o último *frame* detectado. Esta estratégia adaptada é mais adequada quando o sinal sob análise possui variações lentas, conforme apresentado na Figura 2.

Note que na Figura 2(a), onde utiliza-se a técnica de (Bastos e Santoso, 2019) com *frames* consecutivos, variações importantes que caracterizam o formato do sinal são perdidas, ao passo que utilizando a adaptação



(a)



(b)

Figura 2: Detecção de novidades em sinal de corrente com parâmetros  $\gamma = 1,2$  e  $l_r = 50$ : (a) Estratégia original com *frames* consecutivos (Bastos e Santoso, 2019). (b) Adaptação proposta utilizando o último *frame* de detecção como referência de comparação.

proposta neste trabalho, mais novidades são detectadas, levando a uma representação com maior fidelidade das partes que o sinal sofre variação, conforme mostrado na Figura 2(b). Pode-se ver que as partes não detectadas são trechos estacionários do sinal. Neste exemplo, cada *frame* contém  $N = 1$  ciclo do componente fundamental.

### 3 Testes e resultados

Para analisar a eficiência do detector, foram utilizadas curvas *Receiver Operating Characteristic* (ROC) (Van Trees, 2004), que relacionam a probabilidade de detecção ( $P_D$ ) no eixo das ordenadas com a probabilidade de falso alarme ( $P_{FA}$ ) no eixo das abscissas, calculados conforme:

$$P_D = \frac{PV}{TP}, \quad P_{FA} = \frac{NV}{TN}, \quad (6)$$

onde  $PV$  é o número de *frames* positivos verdadeiros detectados pelo método,  $TP$  é o total de *frames* positivos que contêm novidade no sinal,  $NV$  é o número de *frames* negativos verdadeiros não detectados pelo método e  $TN$  é o total de *frames* que não contêm novidades do sinal. Quanto mais próximo de 1 for  $P_D$  e quanto mais próximo de 0 for  $P_{FA}$ , melhor é o detector.

A curva ROC é gerada através da variação da constante de sensibilidade do detector. Através da curva

ROC é possível obter informações sobre a eficácia do detector. Uma delas é a área abaixo da curva (AUC), que em um detector ideal possui o valor igual a 1.

Para definir o limiar ótimo é utilizado o ponto em que o índice Soma-Produto ( $SP$ ) (de Simas Filho et al., 2009) tem seu valor máximo. O índice  $SP$  é calculado de acordo com (7), onde  $P_D$  é a probabilidade de detecção e  $P_{FA}$  é a probabilidade de falso alarme.

$$SP = \sqrt{\sqrt{P_D \times (1 - P_{FA})} \times \frac{P_D + (1 - P_{FA})}{2}} \quad (7)$$

Os testes foram realizados com uma janela  $l_r$  de tamanho fixo, contendo 4 ciclos inteiros. Portanto, foi escolhido  $\gamma$  como parâmetro variável para gerar as curvas ROC.

Foram gerados 200 sinais de 40 ciclos, para cada um dos seguintes distúrbios: transientes oscilatórios, *sags*, *swells*, harmônicos variantes no tempo, *notches*, *spikes*, interrupções, saltos de fase, inter-harmônicos e níveis DC. Os testes foram realizados considerando dois valores de Relação Sinal-Ruído (SNR): sinais mais ruidosos com 30 dB e sinais menos ruidosos com 60 dB. A frequência de amostragem  $F_s$  adotada foi de 256 amostras por ciclo da fundamental (60 Hz), resultando em  $F_s = 15360$  Hz, o que é equivalente a um período de amostragem  $T_s \approx 65,1 \mu s$ , conforme (1).

Os resultados das simulações podem ser observados da Figura 3 à Figura 12. Para cada uma dessas figuras, (a) corresponde às curvas ROC referentes aos sinais com SNR = 30 dB (em linha vermelha) e SNR = 60 dB (em linha azul), e (b) mostra uma visualização de um sinal contendo cada distúrbio com SNR = 30 dB. Nos gráficos das curvas ROC, também são destacados os pontos de limiar ótimo para cada curva. Quanto mais próximo do canto superior esquerdo do gráfico estiverem localizados os pontos de limiar ótimo, mais próximo do ideal está a detecção.

Através das curvas ROC, pode-se observar que o método de detecção apresentado neste trabalho possui bom desempenho na maior parte dos distúrbios testados, para os quais as curvas não apresentam expressiva diferença para os dois níveis de SNR. Entretanto, dois casos excepcionais chamam a atenção. Estes são *notches* e *spikes*. Para estes casos, as curvas ROC com SNR = 30 dB apresentam baixas probabilidades de detecção no limiar ótimo quando comparadas às curvas com SNR = 60 dB. Isso acontece, pois esses tipos de distúrbios podem ser "camuflados" pelo ruído quando este é de maior nível, como no caso de 30 dB. Tal fenômeno pode ser melhor compreendido ao serem visualizadas as Figuras 7(b) e 8(b), nas quais são mostrados os sinais com os distúrbios citados, juntamente com um ruído a 30 dB.

Os parâmetros das curvas ROC foram extraídos e organizados como mostrado na Tabela 1. Estes parâmetros são  $P_D$ ,  $P_{FA}$  no limiar ótimo e AUC para todos os distúrbios testados nos dois níveis de ruído utilizados. Além disso, os mesmos testes foram realizados com o detector de novidades baseado na energia do *frame*,

proposto em (Silva et al., 2016) e utilizado em (Silva et al., 2017). A fim de referir-se ao método apresentado

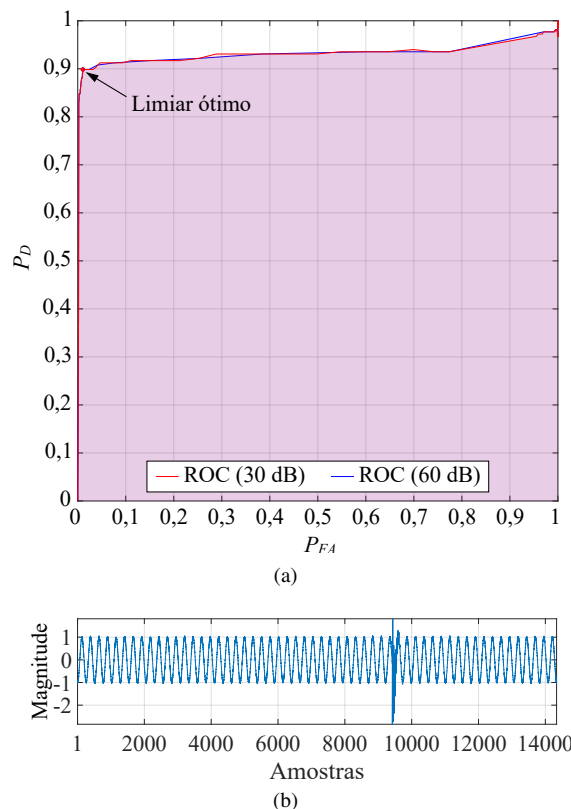


Figura 3: Distúrbios do tipo transiente oscilatório: (a) Curvas ROC. (b) Exemplo de sinal gerado.

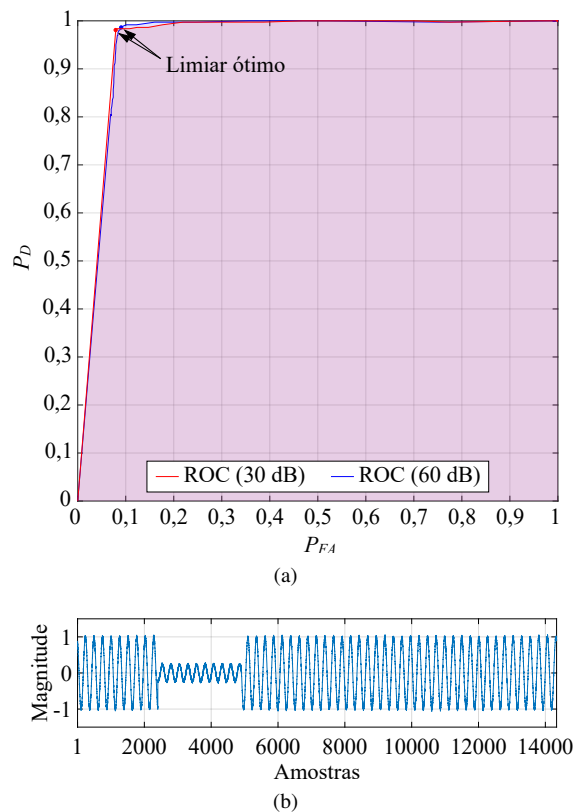




Figura 4: Distúrbios do tipo *sag*: (a) Curvas ROC. (b) Exemplo de sinal gerado.

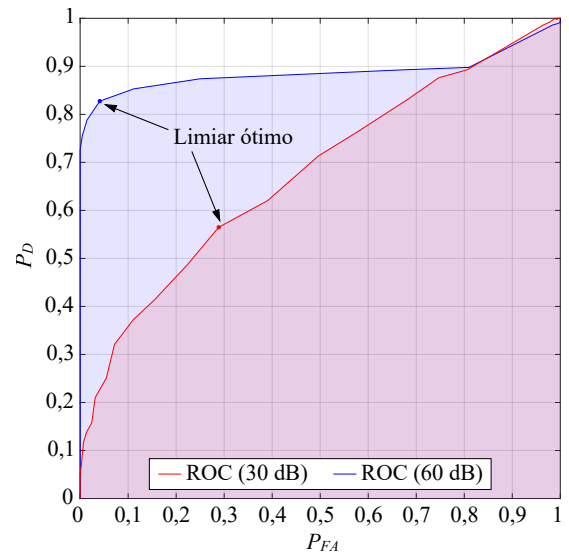


(a)




(b)

Figura 5: Distúrbios do tipo *swell*: (a) Curvas ROC. (b) Exemplo de sinal gerado.

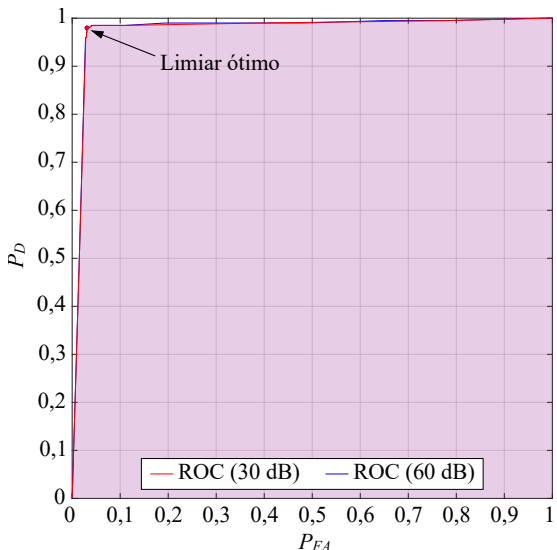


(a)




(b)

Figura 7: Distúrbios do tipo *notch*: (a) Curvas ROC. (b) Exemplo de sinal gerado.




(a)




(b)

Figura 6: Distúrbios do tipo harmônico variante no tempo: (a) Curvas ROC. (b) Exemplo de sinal gerado.




(a)




(b)

Figura 8: Distúrbios do tipo *spike*: (a) Curvas ROC. (b) Exemplo de sinal gerado.




(a)




(b)

Figura 9: Distúrbios do tipo interrupção: (a) Curvas ROC. (b) Exemplo de sinal gerado.




(a)




(b)

Figura 11: Distúrbios do tipo nível DC: (a) Curvas ROC. (b) Exemplo de sinal gerado.

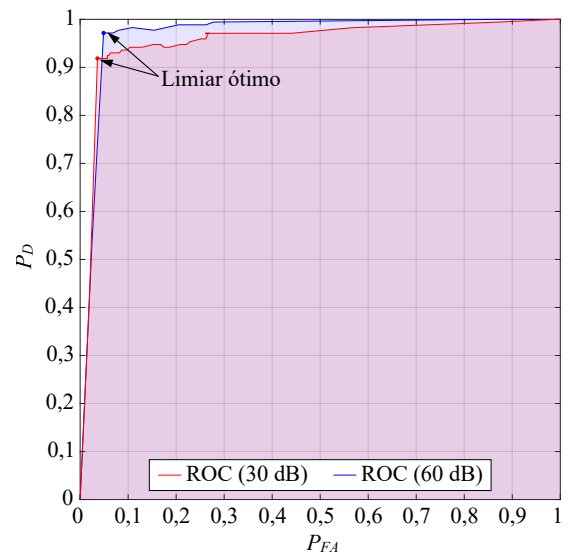


(a)




(b)

Figura 10: Distúrbios do tipo salto de fase: (a) Curvas ROC. (b) Exemplo de sinal gerado.



(a)



(b)

Figura 12: Distúrbios do tipo inter-harmônico: (a) Curvas ROC. (b) Exemplo de sinal gerado.

Tabela 1: Tabela com os parâmetros das curvas ROC para os detectores comparados.

Detector →	Similaridade						Energia					
	30 dB			60 dB			30 dB			60 dB		
SNR →	$P_D$	$P_{FA}$	AUC	$P_D$	$P_{FA}$	AUC	$P_D$	$P_{FA}$	AUC	$P_D$	$P_{FA}$	AUC
Distúrbio ↓												
Trans.	0,8986	0,01066	0,93622	0,8986	0,01066	0,93194	0,9183	0,07478	0,9183	0,9412	0,04844	0,9519
Sags	0,9809	0,07895	0,9608	0,9863	0,09046	0,96936	0,9318	0,1672	0,85245	0,9288	0,1666	0,87723
Swells	0,9808	0,08007	0,95513	0,9837	0,1053	0,95109	0,9377	0,1684	0,86423	0,9435	0,1725	0,886283
Harm. var.	0,98	0,03056	0,95513	0,98	0,03056	0,9777	0,898	0,09701	0,92142	0,898	0,09479	0,91202
Notches	0,5649	0,2886	0,67671	0,8276	0,04093	0,88738	0,6044	0,3804	0,66245	0,9219	0,1658	0,87035
Spikes	0,4917	0,1672	0,70504	0,9645	0,04831	0,95748	0,5201	0,3907	0,57971	0,8034	0,2023	0,81308
Interrup.	0,8034	0,09642	0,88406	0,8775	0,08672	0,92317	0,9116	0,1591	0,84745	0,9069	0,165	0,85689
S. Fase	0,9377	0,06194	0,95456	0,9565	0,07211	0,99128	0,7197	0,1391	0,81417	0,9158	0,2003	0,89165
Niv. DC	0,9474	0,04599	0,95866	0,9502	0,06552	0,96064	0,8477	0,1382	0,85277	0,869	0,1216	0,89363
Inter-h.	0,9186	0,03611	0,9738	0,9773	0,08004	0,94861	0,7542	0,1428	0,78713	0,8315	0,1625	0,84944

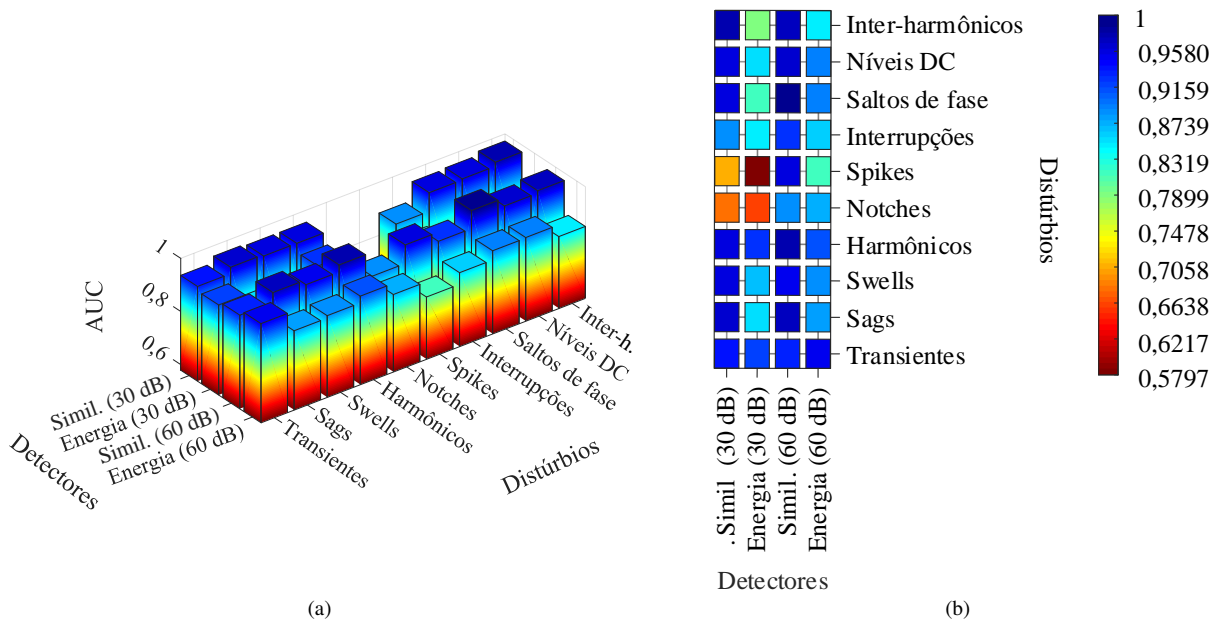


Figura 13: Gráfico de barras com os valores de AUC para ambos os detectores: (a) Vista tridimensional. (b) Vista superior.

no presente trabalho, o termo "Similaridade" é utilizado, enquanto que para o detector sob comparação, utiliza-se o termo "Energia".

Para melhor visualização e interpretação dos resultados, o parâmetro AUC foi extraído da Tabela 1 e representado através do gráfico de barras mostrado na Figura 13(a). Este parâmetro foi escolhido por ter relação com ambos  $P_D$  e  $P_{FA}$  simultaneamente.

A Figura 13(a) mostra o gráfico de barras em uma vista tridimensional, onde é possível ver que as barras mais altas estão mais próximas a 1. Isso indica os melhores resultados de detecção, nos quais AUC se aproxima de 1. A Figura 13(b) mostra a vista superior da Figura 13(a), onde é possível ver mais facilmente os melhores resultados, pois estes são representados pelos quadrados em cor mais próxima ao azul escuro. Através da Figura 13(b), pode-se observar que o detector de novidades por similaridade apresentado neste trabalho apresentou mais casos próximos ao azul escuro, representa (primeira e terceira colunas da matriz de quadrados), indicando que o mesmo possui melhor

de quadrados), indicando que o mesmo possui melhor desempenho de detecção em todos os casos testados.

Claramente, os casos excepcionais mencionados anteriormente, ou seja, *spikes* e *notches*, aparecem em cores mais distantes do azul escuro. Entretanto, mesmos nestes casos o desempenho do detector de similaridade apresenta melhor desempenho em comparação ao detector de energia. Os testes de simulação descritos foram realizados no ambiente MATLAB®.

#### 4 Conclusões

Este artigo apresenta um detector de novidades aplicado a sinais de qualidade de energia, o qual é baseado em uma métrica de similaridade e um limiar de detecção adaptativo. Uma adaptação a este detector é proposta, mostrando significativa melhoria na preservação das variações das formas de onda. Uma comparação com um detector baseado em energia já presente na literatura é realizada. Os resultados mostram que o detector proposto apresenta melhor desempenho em todos os casos testados.

## Agradecimentos

Os autores agradecem ao CNPq, CAPES e INERGE que financiaram este trabalho.

## Referências

- Bastos, A. F. e Santoso, S. (2019). Universal waveshape-based disturbance detection in power quality data using similarity metrics, *IEEE Transactions on Power Delivery*.
- Carnovale, D. e Ellis, D. (2003). Mind your p's and q's: Power-quality events capture and data acquisition system, *IEEE Industry Applications Magazine* **9**(2): 55–63.
- Chen, S., Ma, B. e Zhang, K. (2009). On the similarity metric and the distance metric, *Theoretical Computer Science* **410**: 2365–2376.
- de Simas Filho, E. F., Seixas, J. e Caloba, L. (2009). *Optimized Calorimeter Signal Compaction for an Independent Component based ATLAS Electron/Jet Second-level Trigger*, XII Advanced Computing and Analysis Techniques in Physics Research.
- Deza, M. M. e Deza, E. (2009). *Encyclopedia of Distances*, Springer.
- Han, R. e Zhou, Q. (2016). Data-driven solutions for power system fault analysis and novelty detection, *11th International Conference on Computer Science & Education (ICCSE)* pp. 86–91.
- IEEE (2019). Ieee recommended practice for monitoring electric power quality - redline, *IEEE Std 1159-2019 (Revision of IEEE Std 1159-2009) - Redline* pp. 1–180.
- J. Cordova, C. S., M. Gilanifar, Y. Z., Srivastava, A. e Arghandeh, R. (2018). Shape preserving incremental learning for power systems fault detection, *IEEE Control Systems Letters* **3**(1): 85–90.
- Jain, S. (2018). Chapter one - power quality: An introduction, in S. K. Dwivedi, S. Jain, K. K. Gupta e P. Chaturvedi (eds), *Modeling and Control of Power Electronics Converter System for Power Quality Improvements*, Academic Press, pp. 1–29.
- Johnson, D. O. e Hassan, K. A. (2016). Issues of power quality in electrical systems, *International Journal of Energy and Power Engineering* **5**(4): 148.
- Kapisch, E. B., Silva, L. R. M., Cerqueira, A. S., de Andrade Filho, L. M., Duque, C. A. e Ribeiro, P. F. (2016). A gapless waveform recorder for monitoring smart grids, *17th International Conference on Harmonics and Quality of Power (ICHQP)* pp. 130–136.
- Kapisch, E. B., Silva, L. R. M., Martins, C. H. N., Barbosa, A. S., Duque, C. A., de Andrade Filho, L. M. e Cerqueira, A. S. (2014). An electrical signal disturbance detector and compressor based on fpga platform, *International Conference on Harmonics and Quality of Power (ICHQP)* **16**: 278–282.
- Naderi, Y., Hosseini, S. H., Ghassemzadeh, S., Mohammadi-Ivatloo, B., Savaghebi, M., Vasquez, J. C. e Guerrero, J. M. (2020). Power quality issues of smart microgrids: applied techniques and decision making analysis, *Decision Making Applications in Modern Power Systems*, Elsevier, pp. 89–119.
- Phadke, A. G. e Thorp, J. S. (2017). Phasor estimation at off-nominal frequency inputs, *Springer International Publishing* pp. 47–72.
- Rezkallah, M., Chandra, A., Hamadi, A., Ibrahim, H. e Ghandour, M. (2019). Power quality in smart grids, *Pathways to a Smarter Power System*, Elsevier, pp. 225–245.
- Ribeiro, P. F., Duque, C. A., da Silveira, P. M. e Cerqueira, A. S. (2013). *Power systems signal processing for smart grids*, John Wiley & Sons.
- Rodrigues, N. M., Janeiro, F. M. e Ramos, P. M. (2018). Digital filter performance for zero crossing detection in power quality embedded measurement systems, *IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*.
- Sahani, M., Dash, P. e Samal, D. (2020). A real-time power quality events recognition using variational mode decomposition and online-sequential extreme learning machine, *Measurement* p. 107597.
- San, G., Zhang, W., Guo, X., Hua, C., Xin, H. e Blaabjerg, F. (2020). Large-disturbance stability for power-converter-dominated microgrid: A review, *Renewable and Sustainable Energy Reviews* **127**: 109859.
- Silva, L. R. M., Kapisch, E. B., Martins, C. H. N., Filho, L. M. A., Cerqueira, A. S., Duque, C. A. e Ribeiro, P. F. (2017). Gapless power-quality disturbance recorder, *IEEE Transactions on Power Delivery* **32**(2): 862 – 871.
- Silva, L. R. M., Kapish, E. B., Duque, C. A., de Andrade Filho, L. M., Cerqueira, A. S. e Ribeiro, P. F. (2016). The concept of novelty detection applied to power quality, *2016 IEEE Power and Energy Society General Meeting (PESGM)*, IEEE, pp. 1–5.
- Tan, P.-N., Steinbach, M. e Kumar, V. (2016). *Introduction to data mining*, Pearson Education India.
- Van Trees, H. L. (2004). *Detection, Estimation, and Modulation Theory, Part I: Detection, Estimation, and Linear Modulation Theory*, John Wiley & Sons.