

Novas Métricas para a Classificação de Distúrbios da Qualidade da Energia Elétrica

André C. Pinho* Emanuel G. A. Garcia**

* Departamento de Engenharia Elétrica, Universidade Federal Fluminense, RJ, (e-mail: acpinho@id.uff.br).

** Departamento de Engenharia Elétrica, Universidade Federal Fluminense, RJ, (e-mail: emanoelgarcia@id.uff.br).

Abstract: The increasing use of non-linear loads and devices in power systems has increased the incidence of waveform changes in electrical energy signals. The intensity and frequency of these disturbances define energy quality being delivered to consumers. This work explored this theme and proposed two new approaches to improve the effectiveness of automatic classification of these disorders. The first concerns attributes extraction, which was carried out with the spectral analysis of *Wavelet* coefficients (details level 7), in which 4 new metrics were proposed. The second novelty consisted of a multiple indexes analysis to define a global marker for ranking and selecting attributes. These features were extracted and selected from a synthetic base of 10000 signals and subjected to two types of classifiers: an artificial neural network (ANN) and a Support Vector Machine (SVM). The results showed that 2 proposed attributes had a relevant impact on the classifiers' performance. Furthermore, it was found that the selection method was fully consistent with classifiers results.

Resumo: A crescente utilização de cargas e dispositivos não lineares nos sistemas de potência tem aumentado a incidência de alterações na forma de onda dos sinais de energia elétrica. A intensidade e a frequência desses distúrbios definem a qualidade da energia que está sendo entregue aos consumidores. Este trabalho explorou o tema supramencionado e propôs duas novas abordagens para aumentar a eficácia da classificação automática desses distúrbios. A primeira diz respeito à extração de atributos, que foi realizada com a análise espectral dos coeficientes da Transformada Discreta de *Wavelet* (detalhes nível 7), da qual foram propostas 4 novas métricas. A segunda novidade consistiu em uma análise de múltiplos índices para definição de um marcador global para ranqueamento e seleção de atributos. Tais características foram extraídas e selecionadas a partir de uma base sintética de 10000 sinais e foram submetidas a dois tipos de classificadores: uma rede neural artificial (RNA) e uma Máquina Vetor de Suporte (MVS). Os resultados demonstraram que 2 atributos propostos tiveram relevante impacto no desempenho dos classificadores. Outrossim, verificou-se que o método de seleção se mostrou plenamente coerente com os resultados das classificações.

Keywords: power disturbances, energy quality, attributes selection, machine learning.

Palavras-chaves: distúrbios, qualidade da energia, seleção de atributos, aprendizado de máquina.

1. INTRODUÇÃO

Os sistemas elétricos têm contado cada vez mais com a aplicação de dispositivos de comutação e proteção de estado sólido, assim como conversores de frequência e cargas não lineares. Estes elementos são a principal causa da alteração das características da forma de onda da energia transmitida. Tais alterações são classificadas como Distúrbios da Qualidade da Energia Elétrica (DQEE). A crescente integração da Geração Distribuída (GD) à rede elétrica convencional tem agravado bastante esse cenário. Os DQEE, além de diminuir a vida útil dos equipamentos, podem causar falhas ou mau funcionamento de dispositivos de proteção, danos à base de dados de serviços de Tecnologia da Informação (TI), assim como a ação imprevisível de sistemas de controle automático. Mishra (2019) deixou claro que os DQEE afetam diretamente

a continuidade da transmissão e distribuição da energia elétrica e, por isso, o monitoramento ininterrupto da rede elétrica tornou-se imprescindível para a prevenção de defeitos e planejamento de ações mitigadoras que visem a maximização da disponibilidade do serviço. Segundo Huang et al. (2016), a identificação precisa dos DQEE é um pré-requisito importante e basilar para a melhoria dos índices de qualidade do sistema elétrico. Já existem no mercado analisadores de DQEE em tempo real (*Fluke*, *Yokogawa*, *Flir*, entre outros fabricantes), no entanto, tais soluções ainda são bastantes caras e ineficazes para a análise de sinais complexos e para massas de dados muito grandes, conforme o estudo de Shen et al. (2019).

Atenta a este novo desafio, a comunidade científica tem se empenhado bastante para apresentar estudos que viabilizem o desenvolvimento de soluções mais baratas e eficazes para o problema em foco. Para justificar tal afirmativa, o

trabalho de Mishra (2019) apresenta um gráfico que mostra um crescimento exponencial do termo "power quality" em artigos da base de dados *Scopus*, que representavam menos de 10 ocorrências no ano de 1990 e passaram para mais de 400 em 2016.

Segundo Lee and Shen (2011), o processo de identificação de DQEE consiste em três etapas : extração de atributos, seleção de atributos e classificação dos eventos.

A extração de atributos pode ser efetuada com medidas tanto no domínio do tempo quanto no da frequência. Energia ,excursão, e valor RMS dos sinais registrados são as principais métricas associadas ao domínio do tempo. A *Transformada de Fourier* e suas variantes são as técnicas mais utilizadas no domínio da frequência. A *Transformada de Wavelet* permite uma análise dual, tempo-frequência, inclusive de sinais não estacionários. O trabalho de Shen et al. (2019) elenca outras ferramentas para análise espectral que tem sido aplicadas à extração de atributos de sinais de energia, tais como: a *Transformada de Stockwell*, os *Filtros de Kalman*, a *Transformada de Hilbert*, *Curvelets*, entre outras.

Independente da ferramenta aplicada. o desempenho da classificação automática pode ser comprometido em função de amostras espúrias, ruído, da alta correlação entre certos atributos ou mesmo pela baixa variância de alguns deles.

Diante disso, é imperativo que tais atributos sejam previamente selecionados (ou mesmo processados) para maximizar a eficiência do processo de classificação. De acordo com Zhang and Chen (2018), a seleção de atributos é uma técnica para ranqueamento de características observadas nos eventos a serem analisados, conforme o grau de influência que cada uma delas exerce na categorização dos sinais registrados. Segundo Liu et al. (2017), a seleção dos atributos mais relevantes pode ser encarada como uma filtragem das características observadas, de maneira a reduzir a dimensão do problema e permitir um aumento da eficiência dos métodos de classificação.

Com relação à categorização dos DQEE verifica-se que as técnicas de aprendizado de máquina mais empregadas para este fim são as redes neurais artificiais (RNA), as redes neurais probabilísticas e a máquina vetor de suporte (MVS). As redes neurais convolucionais fazem parte de uma abordagem de *deep learning* que invariavelmente aumentam o nível de confiança da classificação, porém, a um custo computacional bem maior.

Este trabalho propôs uma dupla abordagem para maximizar a eficiência de ferramentas destinadas à classificação automática dos DQEE. A primeira parte consiste na extração de atributos baseada na análise espectral dos coeficientes de detalhes (sétimo nível) relativos à aplicação da *Transformada Discreta de Wavelet* aos distúrbios. A segunda etapa está relacionada ao desenvolvimento de um índice global, baseado em seis métricas de seleção, para ranqueamento dos atributos. Uma base de dados composta por 10000 distúrbios, divididos em 10 classes, foi gerada sinteticamente. Os resultados demonstraram a relevância de dois atributos propostos na eficiência dos classificadores (RNA e MVS), assim como, robusta coerência entre o processo de ranqueamento e o resultado das classificações.

Este artigo está organizado da seguinte forma: a Seção 2 traz um apanhado das publicações recentes acerca do processo de classificação automática dos DQEE. A Seção 3 descreve os passos seguidos por esse trabalho, detalhando a modelagem da geração sintética de sinais, as métricas para extração de 12 atributos, sendo 8 convencionais e 4 novidades propostas nesse trabalho. Nesta seção também foi apresentada a nova abordagem para ranqueamento dos atributos, assim como a configuração das duas ferramentas de aprendizado de máquina para a classificação automática dos distúrbios. A Seção 4 apresenta os resultados referentes às análises dos impactos da utilização dos atributos no processo de classificação automática. Além disso, nesta seção também é apresentada uma avaliação do processo de ranqueamento dos atributos. Por fim, a Seção 5 traz as conclusões deste trabalho, assim como propostas de novas atividades de pesquisa.

2. TRABALHOS RELACIONADOS

A extração de atributos que melhor caracterizem os DQEE associada a diferentes técnicas de classificação tem se tornado foco principal de inúmeros pesquisadores que atuam na área de sistemas de energia. Qiu et al. (2019) propõem um novo método para extração de atributos baseado na *Transformada de Stockwell*, no qual é aplicada a janela de *Kaiser* para distinguir melhor a concentração de energia em uma matriz tempo-frequência. A robustez e a eficiência do método são validadas por meio de experimentos envolvendo sinais sintéticos de diferentes distúrbios.

Khokhar et al. (2017) apresentam uma abordagem conjunta de extração e classificação de atributos baseada em *Wavelets* e *Máquina Vetor de Suporte*. O método proposto é aplicado a uma base sintética de distúrbios simples e combinados, e seu desempenho é comparado com outros métodos de classificação, baseados em redes neurais. Os resultados demonstraram que a alternativa proposta teve um desempenho superior, considerando os cenários analisados.

O artigo de Mahela and Shaik (2016) apresenta um método de detecção e classificação automática de distúrbios, no qual os atributos dos sinais contaminados são extraídos com base na análise multi-resolução da *Transformada de Stockwell*. Os sinais foram classificados com a aplicação de uma árvore de decisão, inicializada pelo algoritmo de clusterização *Fuzzy C-means*. Os autores consideraram os resultados dos experimentos satisfatórios em diferentes cenários de associação de distúrbios.

Sahani and Dash (2018) propõem o uso da *Transformada Hilbert Huang (THH)* para a extração de características dos sinais que serão submetidas a técnica de classificação denominada *Weighted Bidirectional Extreme Learning Machine (WBELM)*. Os resultados da aplicação desta metodologia foram comparados com a associação de técnicas de *Máquina Vetor de Suporte* com diferentes modos de extração de atributos baseados em *Wavelets*. Os resultados demonstraram que a abordagem proposta é superior em termos de complexidade computacional, precisão na classificação e tempo de detecção. A viabilidade do método proposto foi testada e validada tanto em simulação quanto em testes laboratoriais.

De and Debnath (2018) também apresentaram uma nova técnica para detecção e classificação automática de DQEE, integrando a *Lógica Fuzzy* e medidas de correlação cruzada dos espectros relacionados aos eventos com distúrbios. Segundo os autores, o método requer um número mínimo de atributos quando comparado com as abordagens tradicionais, além de ser imune à contaminação de ruído dos sinais registrados. Experimentos reais foram conduzidos em laboratório e o padrão IEEE 33 barras também foi validado por meio de simulações.

3. METODOLOGIA

A metodologia seguida neste trabalho começa pela geração de uma base sintética de distúrbios da qualidade da energia elétrica. Na sequência, cada evento da base sintética foi convertido em um vetor de atributos, de acordo com 12 métricas estabelecidas. O próximo passo foi a seleção/ranqueamento dos atributos para posterior classificação. Por último, a base com os atributos selecionados foi submetida a duas técnicas de aprendizado de máquina e os resultados obtidos foram avaliados para fins de validação do método proposto.

3.1 Geração da base sintética

Como mencionado na seção 1, uma base de dados com 10000 distúrbios, dividida em 10 classes com 1000 eventos cada, foi gerada sinteticamente, conforme a modelagem apresentada no trabalho de Lee and Shen (2011).

Cada evento desta base representa um registro da forma de onda de tensão com duração de 10 ciclos, a uma frequência fundamental de 60 Hz. Cada ciclo foi construído com 2001 pontos, resultando em uma frequência de amostragem de 120 KHz. Os sinais gerados foram submetidos à contaminação por ruído gaussiano, com taxas de 30, 40 e 50 dB de relação sinal/ruído.

3.2 Extração de atributos

Excursão(*exc*), valor RMS(*rms*) e Energia(*E*) foram os primeiros atributos elencados para caracterização dos distúrbios sintetizados.

Para análise no domínio da frequência, foi aplicada a *Transformada Rápida de Fourier*, do Inglês *FFT*, diretamente sobre as sequências discretas dos sinais. Desta forma, o espectro de cada sinal sintetizado pôde ser representado por uma sequência de frequências discretas f_k e respectivas energias e_k .

Mais dois atributos foram escolhidos: a largura de banda (*bw*) e frequência central ponderada (*fcp*). A largura de banda foi calculada em torno da componente de maior energia, considerando como frequências de corte aquelas componentes que tinham energia *3dB* abaixo da componente de referência. O segundo atributo proposto foi a média ponderada das componentes de frequência, f_k pelos respectivos níveis de energia e_k , conforme a equação (1), onde N representa o número de amostras de cada sequência.

$$fcp = \frac{\sum_{n=1}^{N/2} (f_k \cdot [e_k])}{\sum_{n=1}^{N/2} [e_k]} \quad (1)$$

Para compor um conjunto de 12 atributos, estudou-se a aplicação da *Transformada Discreta de Wavelet (TDW, Daubechies-6)* nos distúrbios e observou-se que a componente de detalhe resultante da decomposição em nível 7 (*cd7*) apresentou a melhor relação entre a filtragem da componente fundamental e a manutenção do comportamento oscilatório do distúrbio. Esses coeficientes representam uma faixa de frequência entre 486,5 e 937,5 Hz. A partir daí, mais 3 atributos foram extraídos: a energia dos coeficientes de detalhe (*Ecd7*); a energia dos coeficientes de aproximação (*Ea7*); e a entropia dos *cd7* (*e7*), calculada com base na janela de Shannon.

Proposta de novas métricas espectrais: por fim, este trabalho propôs como métricas inovadoras mais quatro atributos, também baseados nos *cd7*. A ideia foi mensurar o efeito da subamostragem na decomposição de sétimo nível, em relação à faixa de frequência original dos distúrbios. A partir daí, calculou-se a largura de banda normalizada (*bwCd7*), a frequência central ponderada normalizada (*fcpCd7*), o valor máximo de energia encontrado no espectro dos coeficientes (*emCd7*) e a respectiva frequência associada (*fmCd7*). A largura de banda e frequência central ponderada foram calculadas de forma idêntica ao cálculo feito para a sequência original, só que agora aplicada aos *cd7*.

As Figuras de 1 e 2 apresentam a análise espectral dos *cd7*, relacionados a 2 tipos de distúrbios (transiente e harmônicos). Pode-se observar que a distribuição de energia em relação às frequências normalizadas distingue com facilidade os dois sinais.

Cabe ressaltar que os valores associados aos eixos com denominação "frequência normalizada" referem-se ao efeito da subamostragem e não às verdadeiras componentes de frequência do sinal. Desta forma, esta análise espectral, presta-se apenas a coleta de valores de referência para caracterização dos sinais.

3.3 Seleção de atributos

Em virtude da extensa gama de ferramentas para a seleção de atributos, este trabalho optou por realizar uma análise multi parâmetros, considerando 6 métricas de avaliação da significância dessas características.

As métricas escolhidas, detalhadas no trabalho de Hussain et al. (2018), foram:

- (1) *Correlação de Pearson* entre cada atributo e as categorias dos DQEE;
- (2) *Symmetrical Uncertainty*, métrica aplicada entre cada atributo e as categorias dos DQEE;
- (3) *Classificador OneR*, algoritmo de seleção de atributos, baseado em regras;
- (4) *Information Gain*, algoritmo de seleção de atributos, baseado na teoria da informação;

- (5) *Gain Ratio*, algoritmo que representa uma variação do *Information Gain*;
- (6) *ReliefF*, algoritmo que utiliza métricas estatísticas para atribuir um índice de relevância aos atributos.

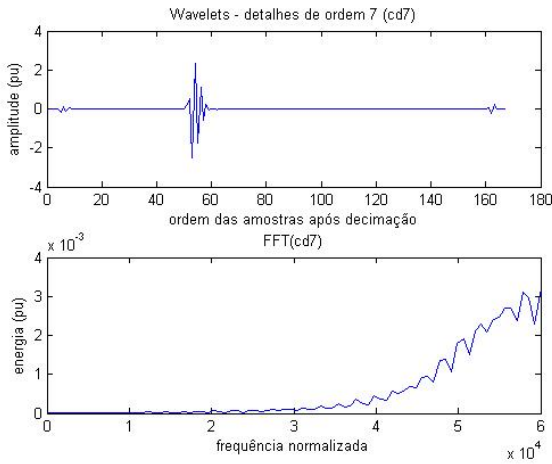


Figura 1. Análise Espectral cd7: Transiente

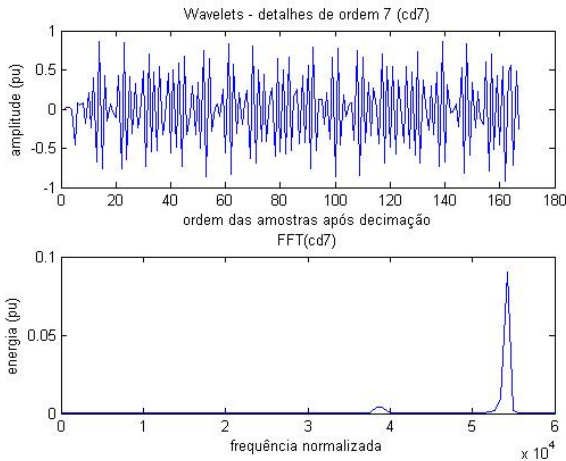


Figura 2. Análise Espectral cd7: Harmônicos

O índice global foi obtido pela totalização dos índices normalizados. Tal normalização se fez necessária pois cada uma das métricas tinha uma faixa de variação distinta. Considerando i como a variável relacionada às 6 métricas e j aquela relacionada aos 12 atributos, a equação 2 define o modelo de cálculo do índice global para cada atributo a .

$$I_G^a = \sum_{i=1}^6 \frac{I^{i,j=a}}{\sum_{j=1}^{12} I^{i,j}} \quad (2)$$

3.4 Classificação automática dos distúrbios

Para classificação dos DQEE foram comparadas duas alternativas: a classificação efetuada por uma rede neural artificial e pela aplicação de uma máquina de vetor de suporte.

A estratégia para a aplicação das duas abordagens foi usar 66% da base de dados para treinamento do modelo e os outros 34% para teste propriamente dito.

Configuração da Rede Neural: o modelo de rede neural escolhido foi uma *Multi Layer Perceptron (MLP)*, associada ao algoritmo *backpropagation*, configurada para classificação dos distúrbios em três cenários: 12, 6 e 4 atributos. Em todos os cenários as MLPs contaram com 3 camadas de neurônios. A primeira, relacionada ao número de atributos e a última, fixa, com 10 neurônios, um para cada classe de distúrbio. Considerando a notação $(a : b : c)$, onde a , b e c representam o número de neurônios das camadas de entrada, oculta e de saída, respectivamente, as estruturas utilizadas foram $(12 : 11 : 10)$, $(6 : 8 : 10)$ e $(4 : 7 : 10)$. A taxa de aprendizagem utilizada foi de 0.3 e o momento aplicado para atualização dos pesos dos neurônios foi ajustado para 0.2. As redes foram treinadas em 500 épocas.

Configuração da Máquina Vetor de Suporte (MVS):

a MVS escolhida baseou-se no algoritmo de otimização sequencial mínima de John Platt's. A calibração foi realizada com suporte de uma regressão logística e o kernel polinomial foi o escolhido para a classificação propriamente dita.

4. ANÁLISE DOS RESULTADOS

Antes da análise da seleção dos atributos foi preciso confirmar que as características extraídas tinham condições de proporcionar uma classificação precisa dos DQEE modelados na base sintética. Para isso, submeteu-se a base transformada (12 atributos por distúrbio) aos dois métodos de classificação, detalhados na seção 3, considerando três cenários de contaminação por ruído. A Tabela 1 apresenta o desempenho dos classificadores, assim como a confiabilidade dos resultados, expressa pela estatística *Kappa*, onde valores próximos de 1 representam alta confiabilidade e próximos de 0, baixa confiabilidade..

Tabela 1. Classificação dos DQEE: vetores com 12 atributos

SNR (dB)	MLP		MVS	
	% acertos	Kappa	% acertos	Kappa
50	98.0294	0.9788	95.5	0.95
40	98.0294	0.9781	95.3529	0.9484
30	96.6765	0.9631	93.3235	0.9258

Os resultados demonstraram que os classificadores obtiveram um desempenho expressivo com erros de classificação variando entre 2 e 6 %, aproximadamente. Como era de se esperar, quanto maior a contaminação por ruído, maior o quantidade de erros de classificação verificados. Outrossim, constatou-se que a MLP apresentou desempenho superior à MVS em todos os cenários.

Seguindo a metodologia adotada, procedeu-se a avaliação dos atributos, considerando as 6 métricas de significância descritas na seção 3.3 e aplicadas ao o conjunto de vetores com os 12 atributos extraídos da base de DQEE, sintetizada com menor contaminação de ruído ($SNR = 50dB$). A Tabela 2 apresenta as medidas efetuadas e o ranqueamento dos atributos, organizado em função do índice global.

Para verificar a coerência do método de ranqueamento proposto, optou-se por comparar a classificação usando apenas os 6 atributos mais bem ranqueados (6+), com a realizada com os 6 menos adequados (6-). As Figuras

Tabela 2. Ranqueamento dos atributos

Atributos	Ferramentas de Seleção						I_G^a	Ranque
	Correlação	Gain Ratio	Information Gain	OneR	ReliefF	Symmetrical Uncertainty		
<i>E</i>	0.195	0.563	2.444	64.95	0.0741	0.638	0.5694	4
<i>fcP</i>	0.162	0.459	1.698	45.62	0.0423	0.484	0.4166	11
<i>bw</i>	0.149	0.53	0.305	17.75	0.0316	0.157	0.2477	12
<i>exc</i>	0.247	0.551	1.864	49.05	0.1411	0.556	0.5829	1
<i>rms</i>	0.206	0.563	2.444	65.21	0.0795	0.638	0.5793	2
<i>Ea7</i>	0.195	0.567	2.453	63.99	0.0744	0.642	0.5698	3
<i>Ecd7</i>	0.243	0.425	1.798	46.61	0.0813	0.476	0.4845	9
<i>e7</i>	0.212	0.457	1.908	49.93	0.0878	0.509	0.4996	8
<i>emCd7</i>	0.25	0.49	1.935	48.88	0.082	0.532	0.5182	7
<i>fmCd7</i>	0.182	0.484	1.617	42.38	0.0773	0.485	0.4521	10
<i>bwCd7</i>	0.221	0.444	1.621	43.38	0.1697	0.465	0.5453	5
<i>fcPCd7</i>	0.233	0.463	1.752	43.35	0.1381	0.493	0.5345	6

3 e 4 demonstram que a seleção aplicada favoreceu a classificação com um aumento de aproximadamente 20 pontos percentuais, no caso da MLP e 27 no caso da MVS. Estes resultados confirmam que o método proposto nesse trabalho produz uma seleção otimizada dos atributos.




Figura 3. Classificação dos DQEE: 6 atributos mais e menos significantes - MLP

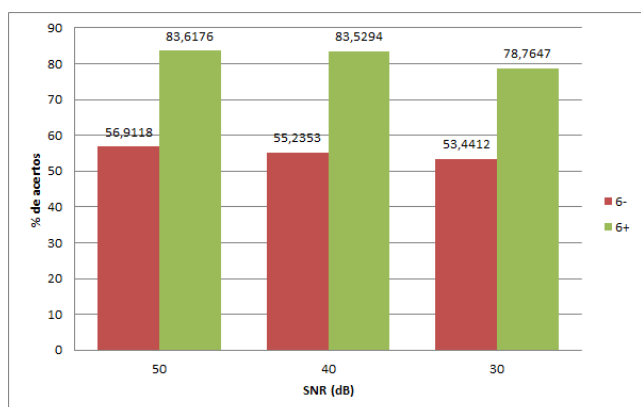


Figura 4. Classificação dos DQEE: 6 atributos mais e menos significantes - MVS

Dos resultados apresentados na Tabela 2, verificou-se que entre os 6 atributos mais bem ranqueados, dois correspondiam às inovações propostas na seção 3.2. Com o objetivo de verificar o impacto da adoção desses dois novos atributos no processo de classificação, comparou-se o desempenho dos classificadores considerando os seguintes composições dos vetores de atributos: os 4 mais bem

ranqueados (4+); os 4 mais bem ranqueados junto com os 2 atributos menos significantes (4+/2-); e os 6 mais bem ranqueados.

As Figuras 5 e 6 apresentam os gráficos comparativos do mencionado experimento, que comprovam o relevante impacto positivo proporcionado pela agregação dos atributos *bwCd7* e *fcPCd7*. Consta-se um aumento de 20 e 30 pontos percentuais no desempenho da MLP e da MVS, respectivamente. Nota-se, ainda, que a agregação dos 2 atributos menos significantes também melhorou o desempenho dos classificadores, porém com impactos distintos para os dois métodos de classificação: enquanto na MLP o desempenho aumentou cerca de 10 pontos percentuais, na MVS o ganho variou, timidamente, em torno de 4 pontos percentuais, muito distante dos resultados considerando os 6 melhores atributos.




Figura 5. Desempenho da MLP para diferentes vetores de atributos

Cabe destacar que os atributos *largura de banda* e *frequência central ponderada* tiveram suas significâncias potencializadas quando as medidas foram extraídas dos *cd7* (5º e 6º lugares), no lugar do sinal original (12º e 11º lugares).

5. CONCLUSÃO E TRABALHOS FUTUROS

Inúmeros são os trabalhos científicos que trazem à tona um problema que tem afetado com maior frequência os sistemas de potência: distúrbios da qualidade da energia elétrica. A adoção de medidas que minimizem a ocorrência desses eventos depende de um contínuo monitoramento




Figura 6. Desempenho da MVS para diferentes vetores de atributos

da rede e de uma capacidade computacional, capaz de classificar tais distúrbios automaticamente.

Este trabalho explorou esta temática e deu especial destaque para as fases de extração e seleção de atributos. Foram propostas 4 novas métricas de extração de atributos, baseadas na análise espectral da decomposição em Wavelet, particularmente, os coeficientes de detalhe de sétimo nível. Além disso, este artigo trouxe uma nova abordagem para seleção e ranqueamento dos atributos, baseada na análise de múltiplos índices de significância.

Para a realização dos experimentos, foi gerada uma base sintética com 10000 formas de onda, contaminadas com diferentes níveis de ruído, compreendendo 10 tipos de distúrbios. Esta base foi transformada em uma nova base composta por 10000 vetores com 12 atributos (8 tradicionais e 4 propostos nesse trabalho). Duas técnicas de aprendizado de máquina foram aplicadas para a classificação automática: rede neural e máquina vetor de suporte.

Os resultados demonstraram que dois atributos propostos proporcionaram relevante impacto no desempenho da classificação, sobretudo quando da utilização da máquina vetor de suporte.

Outrossim, as análises apresentadas destacaram que o método de seleção e ranqueamento proposto, produziu resultados bastantes coerentes com o desempenho dos classificadores, considerando diferentes conjuntos de atributos. Em outras palavras, atributos mais bem ranqueados proporcionaram um desempenho melhor dos classificadores.

Pode-se concluir que as propostas sugeridas nesse trabalho, corroboradas pelos resultados apresentados, representam um avanço na pesquisa sobre distúrbios da qualidade da energia elétrica, no sentido de se desenvolverem sistemas inteligentes de controle e operação que mantenham tais inconformidades em níveis aceitáveis.

A verificação da adequabilidade dos atributos propostos para a classificação de registros distúrbios reais, assim como para análise de faltas do sistema elétrico, figuram como as futuras atividades de pesquisa sobre o tema. A aplicação de outras transformadas para análise dos coeficientes de detalhes da *Wavelet* também é uma questão a ser explorada em breve.

REFERÊNCIAS

- De, S. and Debnath, S. (2018). Real-time cross-correlation-based technique for detection and classification of power quality disturbances. *IET Generation, Transmission and Distribution*. doi:10.1049/iet-gtd.2017.0507.
- Huang, N., Peng, H., Cai, G., and Chen, J. (2016). Power quality disturbances feature selection and recognition using optimal multi-resolution fast S-transform and CART algorithm. *Energies*. doi:10.3390/en9110927.
- Hussain, S., Dahan, N.A., Ba-Alwib, F.M., and Ribata, N. (2018). Educational data mining and analysis of students' academic performance using WEKA. *Indonesian Journal of Electrical Engineering and Computer Science*. doi:10.11591/ijeecs.v9.i2.pp447-459.
- Khokhar, S., Zin, A.A., Bhayo, M.A., and Mokhtar, A.S. (2017). Automated recognition of single & hybrid power quality disturbances using wavelet transform based support vector machine. *Jurnal Teknologi*. doi:10.11113/jt.v79.5693.
- Lee, C.Y. and Shen, Y.X. (2011). Optimal feature selection for power-quality disturbances classification. *IEEE Transactions on Power Delivery*, 26(4), 2342–2351. doi:10.1109/TPWRD.2011.2149547.
- Liu, C., Wang, W., Zhao, Q., Shen, X., and Konan, M. (2017). A new feature selection method based on a validity index of feature subset. *Pattern Recognition Letters*. doi:10.1016/j.patrec.2017.03.018.
- Mahela, O.P. and Shaik, A.G. (2016). Recognition of power quality disturbances using S-transform and Fuzzy C-means clustering. In *Proceedings of the 2016 International Conference on Cogeneration, Small Power Plants and District Energy, ICUE 2016*. doi:10.1109/COGEN.2016.7728955.
- Mishra, M. (2019). Power quality disturbance detection and classification using signal processing and soft computing techniques: A comprehensive review. *International Transactions on Electrical Energy Systems*, 29(8). doi:10.1002/2050-7038.12008.
- Qiu, W., Tang, Q., Liu, J., Teng, Z., and Yao, W. (2019). Power Quality Disturbances Recognition Using Modified S Transform and Parallel Stack Sparse Auto-encoder. *Electric Power Systems Research*. doi:10.1016/j.eprsr.2019.105876.
- Sahani, M. and Dash, P.K. (2018). Automatic Power Quality Events Recognition Based on Hilbert Huang Transform and Weighted Bidirectional Extreme Learning Machine. *IEEE Transactions on Industrial Informatics*. doi:10.1109/TII.2018.2803042.
- Shen, Y., Abubakar, M., Liu, H., and Hussain, F. (2019). Power quality disturbance monitoring and classification based on improved PCA and convolution neural network for wind-grid distribution systems. *Energies*, 12(7). doi:10.3390/en12071280.
- Zhang, W. and Chen, J. (2018). Relief feature selection and parameter optimization for support vector machine based on mixed kernel function. *International Journal of Performability Engineering*, 14(2), 280–289. doi:10.23940/ijpe.18.02.p9.280289.