



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
PRÓ-REITORIA DE PESQUISA E EXTENSÃO
COORDENAÇÃO DE PESQUISA

RELATÓRIO DE ATIVIDADES DO ALUNO

Programa: Programa Institucional Voluntário de Iniciação Científica - PIVIC

Título do Projeto: APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO E CLASSIFICAÇÃO DE PERTURBAÇÕES NA QUALIDADE DA ENERGIA

Aluno: André Fernandes Oliveira

Orientador: Pablo Bezerra Vilar

Assinatura do(a) aluno(a):

Assinatura do(a) orientador(a):

Campina Grande 30/09/2022

Introdução

Este trabalho está sendo desenvolvido com o objetivo de tornar mais rápido e eficiente o processo de detecção e classificação de perturbações de natureza elétrica que possam vir a ocorrer em sistemas elétricos. Isso será feito por meio do uso de algoritmos de inteligência artificial (IA), de forma que primeiramente, será feita a análise da precisão do algoritmo adotado para a classificação de distúrbios elétricos. Os algoritmos de IA desenvolvidos neste trabalho foram desenvolvidos tendo como base dados gerados a partir de equações que descrevem diferentes tipos de distúrbio. Neste contexto, foi realizada uma análise comparativa de alguns outros métodos já usados para fins semelhantes na literatura. Diante do exposto, este trabalho se propõe a facilitar e otimizar o processo de análise de qualidade de energia elétrica, garantindo agilidade, precisão, e tornando possível uma rápida atuação para a solução dos problemas em questão.

Fundamentação teórica

1. Qualidade de energia elétrica

Qualidade de energia é um conceito que pode ser entendido de várias formas, uma delas é a confiabilidade do sistema elétrico, ou, para um fabricante de equipamentos, como são as características de uma fonte de potência que permite com que suas máquinas funcionem apropriadamente. De modo geral, a análise de qualidade de energia é entendida como o estudo de qualquer problema que se manifeste em tensão, corrente ou frequência que possa resultar em falhas nos equipamentos do consumidor.

Dentro do estudo de qualidade de energia, observam-se alguns fenômenos notórios, que como dito, se caracterizam por parâmetros de tensão, corrente ou frequência, que não se adequam a limites estipulados para o fornecimento de um serviço satisfatório, um deles é o “*Sag*”, fenômeno que se caracteriza por uma queda no valor da tensão ou corrente para valores entre 0,1 e 0,9 p.u. (por unidade), que tem duração de 0,5 ciclos até um minuto. Este é um fenômeno relativamente comum, que muitas vezes é decorrente da energização de grandes cargas no sistema, ou da partida de motores de grande porte. Outro fenômeno bastante observado na análise de qualidade de energia, são os chamados “*Swells*”, que a contraposto, se caracteriza como um aumento da tensão ou corrente para valores de 1,1 até 1,8 p.u. por duração semelhante a descrita para o fenômeno anterior, e apesar de não serem tão comuns quanto os *sags*, os *swells* são observados como decorrência de faltas no sistema, e aterramentos feitos de forma inadequada ou até não existentes.

A partir destes exemplos, nota-se que problemas relativamente rotineiros na operação de um sistema elétrico já podem motivar o estudo de qualidade de energia, porém, na atualidade,

cada vez mais componentes de maior complexidade estão sendo inseridos no sistema elétrico, tornando necessária uma análise cada vez mais criteriosa da questão da qualidade de energia. Um exemplo é a caracterização do fenômeno conhecido como “*Notching*”, que é um distúrbio periódico de tensão que ocorre como consequência da inserção e operação comum de dispositivos de eletrônica de potência quando a corrente é comutada de uma fase para outra.

Outros fenômenos como variações na frequência da potência, por exemplo, geralmente podem ter origem rastreada para o processo de geração, onde a velocidade de rotação dos rotores nos geradores irá refletir diretamente na frequência do sinal de tensão observado nos enrolamentos da armadura do mesmo, e caso não haja uma atuação em cima deste distúrbio, problemas mais sérios podem vir a ocorrer.

Diante do exposto, observa-se que existe uma gama de distúrbios associados a qualidade de energia cujas origens são diversas, assim, é um desafio classificar cada um individualmente, o que é uma etapa essencial no processo de avaliação da qualidade de energia, uma vez que para se buscar a solução para o problema e atuar com agilidade no mesmo, é necessário um mecanismo que ofereça rapidez e eficiência quanto a detecção e classificação de perturbações. Neste contexto, o presente trabalho busca contribuir com esse processo de classificação a partir do uso de inteligência artificial.

2. Estado da arte: Inteligência artificial

Inteligência artificial pode ser entendida de forma genérica como sendo um estudo e projeto de sistemas inteligentes, onde a “inteligência” vem de um sistema que consegue perceber o ambiente no qual atuará, e toma atitudes que irão maximizar as chances de alcançar o objetivo desejado. Um conceito importante quando se trata de IA e mais especificamente de ML, é o de aprendizagem, que basicamente é a ideia de baseado nos acertos e erros, torna-se possível otimizar um processo de forma que, no futuro, seja possível lidar com um problema com cada vez mais eficiência. A ideia de aprendizado pode ser diretamente relacionada com prática e repetição com retenção de memória, portanto, torna-se natural a aplicação desta ideia por meios de métodos iterativos, que são amplamente utilizados na aplicação de algoritmos de IA. Uma definição mais objetiva pode ser observada a exemplo da feita por Tom Mitchell, que diz que um programa de computador é dito que aprendeu de uma experiência “**E**” com respeito a uma certa tarefa “**T**” e uma amostragem de performance “**P**”, se sua performance em “**T**”, conforme medido por “**P**”, melhora conforme de adquire experiência “**E**”.

No cenário atual, alguns algoritmos de IA se consolidaram como poderosas ferramentas de aprendizado de máquina, ferramentas estas baseadas em modelos matemáticos e estatísticos robustos, oferecem liberdade e poder para lidar com problemas com um grande volume de dados.

O exemplo mais notório talvez seja o das redes neurais, também chamadas de redes neurais artificiais, são modelos computacionais inspirados pelo sistema nervoso central de um animal, que são amplamente utilizados em abordagens de IA. Se tratando da análise de qualidade de energia, as redes neurais artificiais são amplamente usadas e chegam a atingir eficácias de predição de até 96,1% (Deng et al.,2021), precisão atingida ao se realizar o estudo de vários distúrbios elétricos como *sags*, *swells*, interrupções e *notching*, por meio de uma rede neural artificial.

Tipicamente, algoritmos de IA não são capazes de realizar a classificação desejada a partir dos dados da forma que são adquiridos no mundo real, sendo necessária a aplicação de um pré-processamento dos dados antes de sua classificação. Assim, as características que são de fato apresentados ao classificador são chamadas *features* (atributos) e o processo de criação dessas *features* é uma das etapas mais importantes e sensíveis do aprendizado de máquina.

No contexto da análise de qualidade de energia alguns exemplos de *features* seriam observar características como valor médio, valor rms, energia contida ou até transformada *wavelet* do sinal em questão (Eristi et al.,2010), de forma que se possa integrar todos estes parâmetros para a caracterização do fenômeno a ser avaliado.

De acordo com a literatura, um dos métodos mais promissores para a avaliação de distúrbios de qualidade de energia são as máquinas de vetores de suporte, neste contexto, o presente trabalho fez uso desta técnica e por isso ela é aqui apresentada.

a. A Máquina de Vetores de Suporte

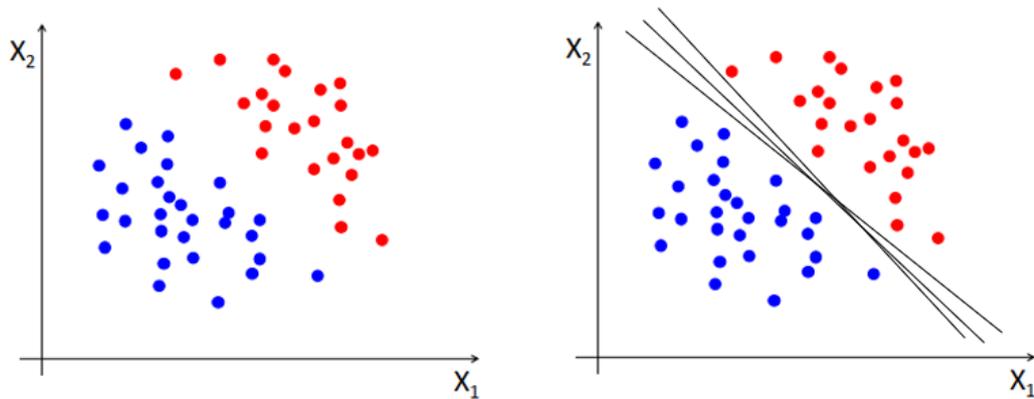
A máquina de vetores de suporte (SVM, do inglês Support Vector Machine) é um método de aprendizado de máquina desenvolvido inicialmente para realizar classificação binária. A descrição mais simples e intuitiva de SVM é a classificação de um conjunto em dois grupos, como demonstrado na Figura .

Como pode ser constatado na Figura , existem diversas retas que podem separar os dois conjuntos. Estendendo o raciocínio para um problema n-dimensional a SVM define um hiperplano para separação dos dados e diferencia-se de outras técnicas de classificação por buscar determinar a separação que maximize a distância entre os pontos dos dois grupos. Tipicamente é escolhido, com base na experiência do desenvolvedor, um parâmetro de regularização responsável por determinar a quão rigorosa deve ser a busca pela separação.

Para o caso da Figura 1, o conjunto é linearmente separável, por isso a classificação é possível no espaço original das amostras. No entanto, nem sempre isso é possível. Para realizar a classificação de um conjunto de dados não linear, é geralmente realizada uma transformação dimensional nos dados. A partir da transformação, o conjunto de dados, anteriormente inseparável

linearmente, passa a ser separável. A função responsável por realizar a transformação dimensional é comumente referida como *Kernel*.

Figura 1 - Gráfico ilustrativo de um conjunto linearmente separável em duas classes.

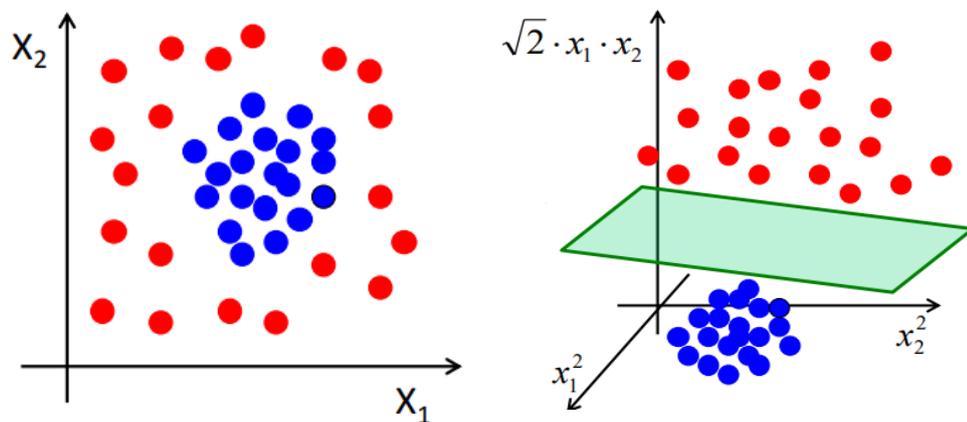


Fonte: adaptado de [16].

Na Figura 2 é demonstrado o uso de uma função Kernel para a transformação dimensional em um conjunto de dados que não é linearmente separável. Para esse caso é utilizada a função Kernel descrita em (1).

$$z = \sqrt{2}x_1x_2 \tag{1}$$

Figura 2 - Gráfico ilustrativo de um conjunto não linearmente separável.



Fonte: adaptado de [16].

Como consequência do uso da função, o conjunto que era descrito pelo par ordenado apresentado em (2) passa a ser descrito por (3).

$$\{x_1, x_2\}, \tag{2}$$

$$\{x_1^2, x_2^2, \sqrt{2}x_1x_2\}. \tag{3}$$

A função Kernel mais utilizada na máquina de vetores de suporte é a RBF (Radial BasisFunction), apresentada em (4),

$$z = e^{-\frac{1}{n}\|x_1-x_2\|^2}, \quad (4)$$

em que n é o tamanho dos vetores x_1 e x_2 . Outras funções Kernel muito utilizadas são a Polinomial e Sigmoide.

Atualmente, o uso de técnicas de ML para o estudo de qualidade de energia se aperfeiçoou suficientemente a ponto de oferecer resultados sólidos, como visto anteriormente. Portanto, ao se confrontar com o problema de análise de qualidade de energia, que lida com grande volume de dados e uma necessidade constante de monitoramento, as técnicas de aprendizado de máquina apresentam grande potencial para facilitar a detecção de distúrbios indesejados, tornando-se um estudo importante que irá impactar a maneira com que se lida com qualidade de energia.

b. Transformada Wavelet

Neste trabalho, a transformada wavelet é usada como uma ferramenta para o processo de extração de *features* para o sistema de classificação proposto, e essencialmente a transformada wavelet é uma técnica usada para decompor um sinal em múltiplas componentes que correspondem a diferentes faixas de frequência, o que permite o estudo de cada componente separadamente.

Fundamentalmente, a transformada wavelet é uma forma de análise na frequência e no tempo. Pra isso, são utilizadas ‘*wavelets*’ (pequenas ondas), que são funções com energia limitada e valor médio igual a zero, de modo que devem atender a equação (5):

$$\int_{-\infty}^{+\infty} \psi(t)dt = 0 \quad (5)$$

Normalmente as funções são normalizadas, ou seja, $|\psi| = 1$ e centradas em $t = 0$. As *wavelets* tem papel similar aos quais os senos e cossenos adotam na análise de Fourier, mas na transformada wavelet, primeiramente é selecionada uma *wavelet* específica para atuar como função base, comumente ela é chamada de wavelet mãe, e a partir dela são geradas outras *wavelets* que diferem por serem deslocadas no tempo ou com diferentes magnitudes, e podem ser parametrizadas pela seguinte expressão (6):

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right) \quad (6)$$

portanto, a magnitude do sinal pode ser alterada pela variável ‘ a ’ que é um número real positivo e o deslocamento no tempo pela variável ‘ b ’, também um número real. Portanto, pode-se dizer que a transformada wavelet de um sinal ‘ $f(t)$ ’ em uma escala ‘ a ’ e com um deslocamento no tempo ‘ b ’ pode ser obtida por meio do produto escalar do sinal ‘ $f(t)$ ’ com a versão em particular da wavelet mãe $\psi_{a,b}(t)$, e pode ser calculada pela equação (7):

$$W\{f(a, b)\} = \int_{-\infty}^{+\infty} f(t) \cdot \frac{1}{\sqrt{a}} \psi^*\left(\frac{t-b}{a}\right) \quad (7)$$

Uma importante questão é a escolha da wavelet mãe, dentre as quais, as funções *Morlet*, *Haar*, *Symlet*, *Coiflet*, e *Daubechies* são escolhas populares. No escopo deste estudo, a wavelet mãe adotada foi a do tipo *Daubechies*, mais especificamente a de ordem quatro, que é o tipo mais utilizado na problemática de análise de qualidade de energia.

3. Metodologia e Resultados

a. Base de dados

Para a aplicação de qualquer técnica de IA, tal qual a SVM, é necessária uma base de dados representativos do problema que se deseja caracterizar, tais dados serão por tanto utilizados na parametrização e teste do classificador.

No contexto deste trabalho, a base de dados deve por tanto ser composta de sinais de tensão puros e sinais de tensão com as perturbações que se deseja caracterizar. Naturalmente, os sinais puros são apenas sinais de senoidais de tensão em função do tempo, contudo, os sinais com perturbações de qualidade precisam ser adequadamente modelados. A modelagem do Sag foi baseada na equação (8) oriunda do trabalho de Eristi, Uçar e Demir (2010).

$$x(t) = A(1 - \alpha(u(t - t1) - u(t - t2))) \cdot \text{sen}(\omega t) \quad (8)$$

onde $T \leq t2 - t1 \leq 9T$. Ambos os sinais foram modelados para um intervalo $0 \leq t \leq 0.4$, o sinal senoidal possui um valor de pico **P** e o sinal “sag” um valor de pico **A**. Feita a modelagem dos sinais, foram obtidas cinco amostras diferentes para cada sinal, variando-se os parâmetros **P** e **A**, ambos sendo variados em uma magnitude de 0,25 e tendo como valor inicial 1 e valor final 0,25. O parâmetro **P** correspondente ao valor de pico do sinal senoidal, e o parâmetro **A** ao valor de pico do sinal com distúrbio.

b. Extração e análise de atributos

Após a obtenção de sinais, foi feito o processo de extração de atributos (*features*). Para isso, foi aplicada a transformação wavelet. Para se obter a transformada de cada sinal, foi usada a ferramenta analisadora de wavelets do *software Matlab®*, onde a partir dela, foi possível decompor o sinal gerado em um coeficiente de aproximação e dez coeficientes de detalhes, tendo em vista que o processo foi feito com base na escolha de uma wavelet mãe do tipo *Daubechies* de quarta ordem. Um exemplo da utilização da ferramenta analisadora pode ser visto na figura (3):

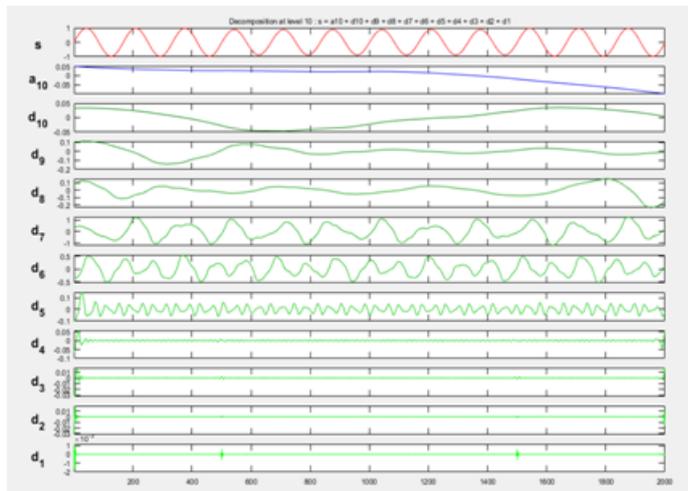


Figura 3: Utilização da ferramenta analisadora de *wavelets* para a decomposição de um sinal *sag*

A partir disto ponto, dez *features* foram criadas, são elas:

1. Valor médio;
2. Desvio padrão;
3. Distorção;
4. Curtose;
5. Valor RMS (*Root Mean Square*);
6. Fator de forma;
7. Fator de crista;
8. Energia;
9. *Entropia-Shannon*;
10. *log-energy entropy*.

Tais *features* foram extraídas para cada coeficiente de aproximação e de detalhes de cada um dos sinais gerados.

c. Classificação dos sinais utilizando SVM

O próximo passo foi preparar os dados obtidos para serem repassados para a SVM, e para este fim, dispôs-se as *features* em matrizes (11,11), cuja primeira coluna corresponde ao *label* (rótulo) associado a cada *feature*, de forma que o valor 1 diz respeito a um sinal que de fato corresponde a um distúrbio, e 0 a um sinal normal. Já as demais colunas, correspondem aos valores calculados das *features* anteriormente citadas, calculadas para cada coeficiente de detalhes e para o coeficiente de aproximação. No fim do processo, após a extração das *features* para cada sinal gerado, obteve-se uma matriz (110,11), cujas linhas foram reorganizadas de forma aleatória a fim de se preparar os dados para o algoritmo a ser utilizado.

Depois de serem fornecidos os dados, o próximo passo foi fazer a escolha adequada dos parâmetros C e σ , que tem o intuito de prover um limiar de decisão adequado para o problema em

questão, além disso, outro fator importante é escolher uma função “Kernel” para a SVM, a função utilizada foi a Kernel Gaussiana. A ferramenta *fitsvm* do *Matlab* possui métodos de buscar os melhores parâmetros para a função kernel escolhida, fazendo uso de uma otimização Bayesiana, e com base em um pré-determinado conjunto de parâmetros a serem testados, a ferramenta faz diversas iterações a fim de achar o conjunto de parâmetros que se caracterizam como os melhores no processo de *k-fold cross-validation*. Uma imagem do resultado do processo de otimização dos parâmetros pode ser vista na figura 4:

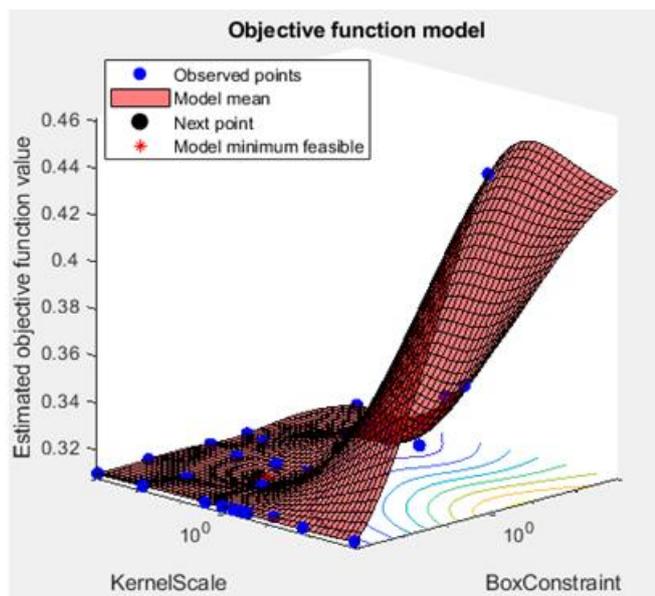


Figura 4: Visualização do processo iterativo de otimização dos parâmetros da função kernel

De acordo com a figura (4), é possível visualizar o processo de busca pelos melhores parâmetros para a função *kernel* por parte do algoritmo. Aqui, o eixo denominado *KernelScale* corresponde ao parâmetro σ da função *kernel*, e o eixo *BoxConstraint* corresponde ao valor do parâmetro *C*. Diante disso, são feitos sucessivos testes para encontrar a combinação de parâmetros que resultam no ponto de mínimo da função para o modelo criado para a SVM. Da figura, é possível observar a localização de cada ponto correspondente a uma determinada combinação de parâmetros, sendo os pontos em azul (*Observed points*) os pontos que dizem respeito a uma certa combinação de parâmetros que não resultaram num ponto de mínimo, e o ponto em vermelho (*Model minimum feasible*) o ponto correspondente a combinação de parâmetros que retornou o melhor resultado possível, ou seja, um ponto de mínimo.

Depois que todos os passos anteriores foram realizados, o algoritmo estava pronto para ser utilizado. Em um primeiro momento, é feita uma seleção das *features* que resultam na melhor precisão do classificador e nesta etapa, fazendo uso de um algoritmo de *forward feature selection*, foi selecionada a combinação das duas *features* que resultaram na melhor acurácia do classificador. De posse das *features* selecionadas anteriormente, e dos parâmetros da função

kernel, o algoritmo *fitcsvm* estava pronto para criar um modelo e testá-lo. Tendo em vista uma divisão dos dados para aproximadamente 80% deles correspondendo a dados para o treinamento do modelo, e 20% aos dados para o teste e validação do mesmo, foi possível obter os resultados apresentados na tabela 1:

<i>Dimensão</i>	Precisão (%)	<i>Features</i> selecionadas
1	44	1
2	100	3,4
3	76	2,4,5
4	88	1,4,6,8
5	88	1,2,3,4,7
6	76	1,2,4,5,6,8
7	88	1,2,3,4,6,8,9
8	100	1,2,3,4,6,7,8,9
9	88	1,2,3,4,5,6,7,8,9
10	60	1,2,3,4,5,6,7,8,9,10

Tabela 1: Precisão do classificador para diversas combinações de *features*

Destaca-se ainda que em testes feitos com um número maior de *features* alimentadas ao algoritmo, observa-se em uma precisão menor, indicativo do fenômeno de *overfitting*. Outro ponto a ser observado é que a alta precisão obtida também é função do pequeno conjunto de sinais gerados, uma vez que em uma situação com um grande volume de dados, certamente a precisão do classificador cairia.

Considerações finais

Neste trabalho, foi analisado problema de classificação das perturbações da qualidade de energia elétrica. Inicialmente foi realizado um estudo sobre as características das perturbações dos classificadores que foram utilizados com sucesso em aplicações semelhantes, a partir desse ponto, como um estudo de caso, buscou-se construir uma Máquina de Vetores de Suporte (SVM) para classificar sinais de *Sags*.

Os resultados obtidos mostram que, utilizando a transformada *wavelet*, foi possível extrair um conjunto de atributos que permite a classificação inequívoca do fenômeno de interesse, indicando que a pesquisa, ainda que esteja em estágio muito inicial, alcançou algum sucesso.

Como perspectivas de trabalho futuro, o próximo e passo a ser realizado é a geração de novos sinais correspondentes a novos distúrbios, e a realização do processo de extração de *features* nos mesmos. Além disso, também se vê necessário o aumento do volume de dados para cada fenômeno a fim de garantir um desempenho mais realista do classificador. Serão ainda aplicados métodos estatísticos de análise de correlação para melhorar a seleção de *features* e técnicas de análise de desempenho para avaliar o comportamento do classificador em desenvolvimento.

Referências

1. H. Eristi, A. Uçar e Y. Demir. Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines, *Electric Power Systems Research* 80:743–752, 2010.
2. G. Hu, J. Xie e F. Zhu. Classification of power quality disturbances using wavelet and fuzzy support vector machines, *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics, Guangzhou*, 18-21, 2005.
3. W. Deng, D. Xu, Y. Xu e M. Li. Detection and Classification of Power Quality Disturbances Using Variational Mode Decomposition and Convolutional Neural Networks, *IEEE 11th Annual Computing and Communication Workshop and Conference (CCWC)*, 2021.
4. Z. Morajev, A. A. Abdoos e M. Pazoki. Detection and Classification of Power Quality Disturbances Using Wavelet Transform and Support Vector Machines, *Electric Power Components and Systems*, 38:182–196, 2010.
5. K. Sekar, S. S. Kumar e K. Karthick. Power Quality Disturbance Detection using Machine Learning Algorithm, *IEEE INTERNATIONAL CONFERENCE ON ADVANCES AND DEVELOPMENTS IN ELECTRICAL AND ELECTRONICS ENGINEERING*, 2020.
6. P. Shinde, P. Patil, A. Ahmad e R. Munje. Support Vector Machine: A Machine Learning Approach for Power Quality Application, *5th International Conference for Convergence in Technology (I2CT)*, 2019.