

# Uma Estrutura em Árvore para Classificação de Múltiplos Distúrbios Elétricos

**Bruno Henrique Groenner Barbosa e Danton Diego Ferreira**

Departamento de Engenharia, Universidade Federal de Lavras, Lavras, MG, Brasil

brunohb,danton@deg.ufla.br

**Resumo** – Este trabalho apresenta uma nova técnica para classificação de distúrbios em sinais de potência, sejam eles múltiplos ou isolados. Para isso, o princípio de *dividir-para-conquistar* é empregado e uma estrutura em árvore é construída por meio de classificadores simples: perceptrons e um classificador bayesiano. Com o objetivo de reduzir seu custo computacional, apenas seis parâmetros extraídos a partir da filtragem do sinal elétrico são utilizados pelo classificador final, tais parâmetros são os cumulantes de segunda ordem e o valor de RMS. Resultados mostram que a abordagem proposta consegue classificar vários tipos de distúrbios com boa eficiência mesmo em diferentes valores para a relação sinal/ruído.

**Palavras-chave** – Qualidade de energia, distúrbios, múltiplo, árvore, classificação.

**Abstract** – This paper presents a new approach for power quality (PQ) multiple disturbance classification. For doing so, the principle of *divide-and-conquer* is employed and a tree structure is constructed by means of simple classifiers: perceptrons and a Bayesian classifier. Aiming at reducing its computational cost, only six parameters extracted from the filtered electrical signal are used by the final classifier, such parameters are the second order cumulants and the RMS value. Results show that the proposed approach can classify many types of PQ disturbances with good accuracy even for different values of signal to noise ratio.

**Keywords** – Power quality, disturbance, multiple, tree, classification.

## 1 INTRODUÇÃO

Qualidade da Energia Elétrica (QEE) refere-se a uma ampla variedade de fenômenos eletromagnéticos que caracterizam a tensão e a corrente em um determinado momento e em um determinado local do sistema de potência [1]. QEE tornou-se uma importante área de pesquisa devido à crescente preocupação de fornecer energia limpa da presença de ondas distorcidas para os consumidores. A proliferação de cargas não-lineares, tais como computadores pessoais, inversores de frequência e geração de energia distribuída causam mudanças nos padrões de tensão e corrente, levando aos distúrbios de QEE [2].

Alguns distúrbios, que geralmente aparecem na tensão elétrica são *sags*, *swells*, harmônicos, transitórios oscilatórios, *notches* e *spikes*, causando falha ou mau funcionamento dos equipamentos elétricos, o que pode, conseqüentemente, reduzir a vida útil dos mesmos além de causar perdas consideráveis. A fim de melhorar a QEE, as fontes e causas da ocorrência desses distúrbios devem ser conhecidas antes que ações apropriadas sejam tomadas.

No entanto, a fim de determinar as causas e fontes de distúrbios, é preciso ter a capacidade de detectar e classificar estes distúrbios. Recentemente, pesquisadores têm tentado usar técnicas eficientes e apropriadas de processamento de sinais e de inteligência computacional para detecção e classificação de distúrbios da QEE. O trabalho [3] apresenta uma boa revisão sobre as principais ferramentas de processamento de sinais aplicadas ao problema de qualidade da energia elétrica.

Embora exista atualmente um número razoável de sistemas de classificação de distúrbios, a maioria deles foram projetados considerando apenas distúrbios isolados. É sabido que, em situações reais, a ocorrência de distúrbios múltiplos é tão comum quanto à ocorrência dos distúrbios isolados, fazendo com que a eficiência de tais sistemas seja reduzida quando um múltiplo distúrbio ocorre.

Neste trabalho, um novo e simples sistema para classificação de distúrbios múltiplos ou isolados da qualidade de energia é proposto usando uma estrutura em árvore composta por classificadores bayesianos e perceptrons. Uma fase de pré-processamento foi aplicada a fim de reduzir a dimensão dos dados e facilitar a separação de diversas classes de distúrbios. Nesta etapa, cumulantes de segunda ordem [4] e RMS (*Root Mean Square*) são extraídos da forma de onda da tensão. Assim, a contribuição deste trabalho consiste na aplicação de tais variáveis para caracterizar um grande número de eventos de qualidade de energia.

Na próxima seção o problema de classificação de distúrbios elétricos é apresentado. A abordagem proposta neste trabalho é descrita na Seção 3 e seus resultados são mostrados na Seção 4. As conclusões e discussões finais são apresentadas na Seção 5.

## 2 CARACTERIZAÇÃO DO PROBLEMA

Segundo [5], a versão discreta do sinal de tensão pode ser dividida em janelas sem sobreposição de  $N$  amostras, que podem ser expressadas como uma soma de contribuições de vários fenômenos:

$$v[n] = v(t)|_{t=\frac{n}{f_s}} = f[n] + h[n] + i[n] + t[n] + r[n], \quad (1)$$

sendo que  $n = 0, \dots, N - 1$ ,  $f_s$  é a frequência de amostragem, as sequências  $f[n]$ ,  $h[n]$ ,  $i[n]$ ,  $t[n]$  e  $r[n]$  são o componente fundamental, harmônicos, interharmônicos, transitórios e ruído, respectivamente. Cada um desses sinais são definidos como:

$$f[n] := A_0[n] \cos\left[2\pi \frac{f_0[n]}{f_s} n + \theta_0[n]\right], \quad (2)$$

$$h[n] := \sum_{m=1}^M h_m[n], \quad (3)$$

$$i[n] := \sum_{j=1}^J i_j[n], \quad (4)$$

$$t[n] := t_{imp}[n] + t_{not}[n] + t_{osc}[n], \quad (5)$$

e  $r[n]$  é ruído independente e identicamente distribuído (i.i.d.) e normal  $\mathcal{N}(0, \sigma_n^2)$ .

Em (2),  $A_0[n]$ ,  $f_0[n]$  e  $\theta_0[n]$  referem-se a magnitude, frequência fundamental e fase do componente fundamental, respectivamente, e

$$h_m[n] := A_m[n] \cos\left[2\pi m \frac{f_0[n]}{f_s} n + \theta_m[n]\right] [u[n - n_{h_m,i}] - u[n - n_{h_m,f}]], \quad (6)$$

$$i_j[n] := A_{I,j}[n] \cos\left[2\pi \frac{f_{I,j}[n]}{f_s} n + \theta_{I,j}[n]\right] [u[n - n_{i_j,i}] - u[n - n_{i_j,f}]], \quad (7)$$

em que  $u[n]$  é a sequência do degrau unitário,  $n_{h_m,i}$  e  $n_{h_m,f}$  são as amostras iniciais e finais dos harmônicos, respectivamente. Igualmente,  $n_{i_j,i}$  e  $n_{i_j,f}$  referem às amostras iniciais e finais dos interharmônicos, respectivamente. Em (6),  $A_m[n]$  é a magnitude e  $\theta_m[n]$  é a fase do  $m$ -ésimo harmônico. Em (7),  $A_{I,j}[n]$ ,  $f_{I,j}[n]$  e  $\theta_{I,j}[n]$  são a magnitude, frequência e fase do  $j$ -ésimo interharmônico, respectivamente. Em (5),  $t_{imp}[n]$ ,  $t_{not}[n]$  e  $t_{osc}[n]$  são os transitórios impulsivos, nomeados *spikes*, *notches* e transitórios oscilatórios, que podem ser expressos por [5]:

$$t_{imp}[n] = \sum_{i=1}^{N_{imp}} t_{imp,i}[n] [u[n - n_{t_{imp,i},i}] - u[n - n_{t_{imp,i},f}]], \quad (8)$$

$$t_{not}[n] = \sum_{i=1}^{N_{not}} t_{not,i}[n] [u[n - n_{t_{not,i},i}] - u[n - n_{t_{not,i},f}]], \quad (9)$$

$$t_{osc}[n] = \sum_{i=1}^{N_{osc}} A_{osc,i}[n] \exp[-\alpha_{osc,i}[n - n_{osc,i}]] [u[n - n_{t_{osc,i},i}] - u[n - n_{t_{osc,i},f}]], \quad (10)$$

sendo  $t_{imp,i}[n]$ ,  $t_{not,i}[n]$  e  $t_{osc,i}[n]$  as  $n$ -ésimas amostras dos  $i$ -ésimos *spikes*, *notches* e transitórios oscilatórios, respectivamente.  $n_{t_{imp,i}}$ ,  $n_{t_{not,i}}$  e  $n_{t_{osc,i}}$  são o início de cada transitório impulsivo e  $n_{t_{imp,f}}$ ,  $n_{t_{not,f}}$  e  $n_{t_{osc,f}}$  o final.

A operação padrão do sistema de potência pode ser modelada por

$$\begin{aligned} s_n[n] &= f[n] + u[n], \\ &= A_0[n] \cos\left(2\pi \frac{f_0[n]}{f_s} n + \theta_0[n]\right) + u(n), \end{aligned} \quad (11)$$

e um evento ocorre quando alguma condição anormal perturba a forma de onda da tensão.

A formulação dada em (1) tem motivado a utilização de processamento de sinais e técnicas de inteligência computacional a fim de separar múltiplos distúrbios para fins de classificação. Em [5], o princípio de *dividir-para-conquistar* é aplicado para decompor os sinais elétricos em três componentes. Para a mesma finalidade, em [6] um método de análise baseado nos componentes independentes é apresentado e, em [7], um método de rede baseada em *wavelets* é proposto. Esses trabalhos têm alcançado bons e promissores resultados, no entanto, um esforço computacional aditivo é exigido por essas técnicas tornando sua aplicação em tempo real difícil de ser implementada.

### 3 MÉTODO PROPOSTO

A maioria dos sistemas de classificação de distúrbios da qualidade de energia apresentam a seguinte metodologia em três passos:

1. utilizando algum tipo de transformação e análise de dados, diversas características são extraídas dos dados a serem classificados, conhecido como passo de extração de características;
2. algumas características extraídas dos dados no primeiro passo são selecionadas para construir um conjunto de parâmetros representativo do distúrbio da qualidade de energia;
3. técnicas de classificação são, então, aplicadas para classificar os diversos distúrbios usando os parâmetros selecionados.

Neste trabalho, o sinal de tensão monitorado é decomposto em  $u$ , o componente de ruído, e  $f$ , o componente senoidal (vide Eq. 11), usando um filtro *notch* de resposta ao impulso infinita (IIR), conforme apresentado em [5] e mostrado na Fig. 1. Após a decomposição dos sinais, ferramentas de extração de características são aplicadas, conforme descrito a seguir.

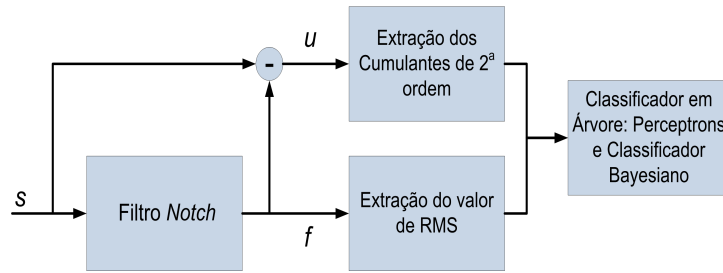


Figura 1: Metodologia proposta para classificação de distúrbios da qualidade de energia.

#### 3.1 CARACTERÍSTICAS EXTRAÍDAS

De acordo com [3], encontrar as características típicas de cada distúrbio é um tema de pesquisa em aberto. Alguns trabalhos recentes têm mostrado que o uso de Estatísticas de Ordem Superior (EOS) para lidar com a análise de transientes de dentro de eventos de qualidade de energia é uma abordagem promissora [8, 9]. Uma vantagem de usar EOS é a sua robustez ao ruído gaussiano [4].

Neste trabalho, a fim de encontrar um algoritmo com baixo custo computacional, apenas cumulantes de segunda ordem são extraídos a partir de  $u$  (11), Fig. 1.

Os cumulantes de segunda ordem de  $x(t)$ , um processo aleatório estacionário com média zero, podem ser expressos como:

$$C_{2,x}(\tau) = E\{x(t)x(t+\tau)\}. \quad (12)$$

Uma vez que informação é perdida quando um valor de  $\tau$  maior do que zero é usado, a seguinte expressão pode ser utilizada [5]:

$$\hat{C}_{2,x}(\tau) = \frac{1}{N} \sum_{n=0}^{N-1} x(n)x(\text{mod}(n+\tau, N)), \quad (13)$$

sendo  $x \in \mathbb{R}^N$  e  $\tau = 0, 1, \dots, N-1$ .

Após a aplicação de (13) na componente de ruído  $u$ ,  $N$  cumulantes de segunda ordem podem ser obtidos. Considerando que não é possível usar os  $N$  cumulantes para a tarefa de classificação devido a limitações computacionais, alguns devem ser selecionados. Uma possível solução é usar o discriminante de Fisher para selecionar os cumulantes mais importantes e distintos entre as classes de distúrbios da QEE como em [8]. No entanto, neste trabalho, serão utilizados os cumulantes que obtiverem as maiores diferenças entre as classes. Por exemplo, suponha que há dois eventos de distúrbios de diferentes classes,  $A$  e  $B$ , e que os cumulantes de segunda ordem foram obtidos da componente de ruído utilizando a expressão (13), ou seja,  $C_{2,A}(\tau)$  e  $C_{2,B}(\tau)$ . Comparando-se os cumulantes das diferentes classes, pode-se escolher  $\tau$  que satisfaça:

$$\tau^* = \arg_{\tau} \max(C_{2,A}(\tau) - C_{2,B}(\tau))^2, \quad (14)$$

em que  $\tau^*$  pode ser um vetor,  $\tau^* \in \mathbb{R}^j$ ,  $j$  é o número máximo de cumulantes que irão representar a classe correspondente.

A Fig. 2 apresenta os cumulantes de segunda ordem de alguns eventos de distúrbio. Pode-se notar que os cumulantes de segunda ordem podem ser vistos como uma assinatura do distúrbio. No entanto, é difícil distinguir algumas classes baseando-se apenas nos cumulantes, por exemplo, para diferenciar entre *sag* e *swell*. Então, outra característica deve ser extraída. Neste trabalho, o valor de RMS da componente senoidal  $f$  em (11) também é usado:

$$RMS(f) = \sqrt{\frac{\sum_{n=1}^N (f(n) - \bar{f})^2}{N-1}}, \quad (15)$$

sendo  $N$  o número de amostras do sinal discreto  $f$  e  $\bar{f}$  a sua média.




Figura 2: Cumulantes de segunda ordem. (a) *sag* e (b) *spike*

### 3.2 CLASSIFICADOR BAYESIANO - RMS

Após a etapa de extração de parâmetros, ferramentas de classificação de padrões podem ser implementadas. Usando o valor RMS da componente senoidal  $f$  (15), um classificador bayesiano [10] é implementado para distinguir sinais que apresentam distúrbios do tipo *sag*, *swell* ou nenhum deles.

Um classificador bayesiano é um classificador probabilístico que aprende as distribuições de probabilidades a partir de dados e classifica uma instância de teste escolhendo a classe que apresenta a maior probabilidade *a posteriori* (MAP). A classe escolhida é a que satisfaz:

$$\mathcal{H}_{MAP} = \arg_{\mathcal{H}_i \in \mathcal{H}} \max p(x|\mathcal{H}_i)p(\mathcal{H}_i), \quad (16)$$

em que  $P(\mathcal{H}_i)$  representa a probabilidade *a priori* e  $p(x|\mathcal{H}_i)$  representa a função de densidade de probabilidade condicional da classe  $\mathcal{H}_i$  em que  $x$  é o valor do atributo (RMS) e  $i = 1, 2, 3$  correspondente às classes que incluem distúrbio do tipo *sag*, classes que não possuem nem *sag* nem *swell* e classes que incluem distúrbios do tipo *swell*, respectivamente. A função de densidade de probabilidade condicional utilizada é baseada na distribuição gaussiana expressa por

$$p(x|\mathcal{H}_i) = \frac{1}{(2\pi\sigma_i^2)^{1/2}} \exp \left\{ -\frac{1}{2\sigma_i^2} (x - \mu_i)^2 \right\},$$

sendo  $\mu_i$  o valor médio da classe  $\mathcal{H}_i$  e  $\sigma_i$  sua variância.

Assumindo probabilidades *a priori* uniformes, a Eq.(16) simplifica para

$$\mathcal{H}_{ML} = \arg_{\mathcal{H}_i \in \mathcal{H}} \max p(x|\mathcal{H}_i) \quad (17)$$

em que  $\mathcal{H}_{ML}$  é chamada de hipótese de Máxima Verossimilhança.

Assim, de acordo com o valor RMS extraído de  $f$  (15), três classes podem ser distinguidas usando o classificador bayesiano proposto.

### 3.3 UMA ABORDAGEM DO TIPO ÁRVORE

Além do valor RMS, cumulantes de segunda ordem também são extraídos do sinal de potência, mais precisamente do transiente  $u$  (1), conforme (13). Dessa forma, além do classificador Bayesiano proposto para classificar classes baseando-se no valor de RMS (sendo possível classificar apenas três classes neste caso - aquelas com *sag* ou com *swell* ou aquelas que não apresentam nenhum dos dois distúrbios), outros classificadores são propostos para distinguir alguns eventos baseado-se apenas nos cumulantes extraídos.

Suponha que existam duas classes,  $A$  e  $B$ , e que alguns cumulantes são selecionados satisfazendo (14). Para classificar essas classes, considerando que elas sejam linearmente separáveis, uma solução possível é a utilização de um Perceptron [11]. Neste caso, as entradas do Perceptron são os valores de cumulantes de segunda ordem selecionados e sua saída é um número binário. Assim, é necessário estimar os pesos do Perceptron de acordo com uma regra de aprendizagem e definir sua função não-linear. Uma das funções não-lineares mais utilizadas, sendo empregada neste trabalho, é a função hiperbólica:

$$g(x) = \frac{1}{1 + e^{-x}} \quad (18)$$

em que  $x$  é a soma das entradas mais o termo de polarização multiplicados pelos seus pesos.

No entanto, uma vez que o objetivo deste trabalho é classificar um grande número de eventos de QEE diferentes e o classificador perceptron descrito só pode classificar duas classes, uma alternativa é usar o princípio de *dividir-para-conquistar*. Isso significa que o processo de classificação é realizado em várias etapas simples. Essas etapas são organizadas em um modelo em árvore onde cada nó é um perceptron diferente ou o classificador Bayesiano. Para isso, as classes mais semelhantes, baseando-se em seus cumulantes de segunda ordem, são agrupadas e dois subgrupos são formados. Para agrupar classes o critério utilizado é o valor de correlação entre os cumulantes extraídos. Após o agrupamento, o classificador tem que aprender a classificar os subgrupos.

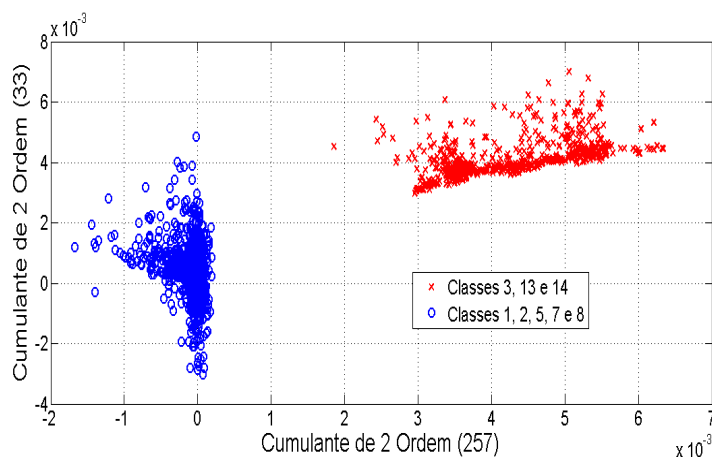


Figura 3: Exemplo de classes em que a distribuição dos cumulantes de segunda ordem são linearmente separáveis.

Classes			
1	Sag	11	Har. + Sag
2	Swell	12	Har. + Swell
3	Notch	13	Notch + Sag
4	Spike	14	Notch + Swell
5	Trans.	15	Spike + Sag
6	Har.	16	Spike + Swell
7	Trans. + Sag	17	Har. + Trans. + Sag
8	Trans. + Swell	18	Har. + Trans. + Swell
9	Har. + Trans.	19	Har. + Notch + Sag
10	Har. + Notch	20	Har. + Notch + Swell

Tabela 1: Distúrbios da qualidade de energia, onde *Har.* representa distúrbios do tipo harmônicos e *Trans.* representa distúrbios de transitórios oscilatórios

## 4 RESULTADOS EXPERIMENTAIS

A fim de verificar o desempenho da abordagem proposta na classificação de distúrbios múltiplos ou isolados, simulações foram realizadas com várias formas de onda de tensão com taxa de amostragem de 15,36kHz, 1.024 amostras ou 4 ciclos, usando diferentes relações sinal/ruído (20, 25 ou 30 dB). Um número de 500 ocorrências de cada distúrbio foi utilizado para treinamento e validação do algoritmo. Todas as formas de onda foram simuladas seguindo a norma [1]. As classes a serem classificadas são apresentadas na Tab. 1, um total de 20 classes, sendo 6 de distúrbios isolados e o restante de múltiplos distúrbios. A abordagem proposta foi executada 100 vezes.

Pode-se observar pelas classes listadas na Tab. 1 que existem três conjuntos de classes: aquelas que possuem distúrbio do tipo *sag*, aquelas que possuem distúrbio do tipo *swell* e aquelas que não possuem esses distúrbios. Como mostrado anteriormente, uma possível solução para classificar esses três conjuntos de classe é a utilização de um classificador bayesiano que possua como entrada o valor de RMS. Sendo assim, os três conjuntos foram formados e um classificador bayesiano treinado utilizando 60% das amostras das classes disponíveis para treinamento. Para validação do classificador, o restante das amostras foi utilizado e o acerto percentual obtido foi de  $99,92\% \pm 0,04\%$ . A Fig.4 apresenta a probabilidade *a posteriori* de cada um dos três conjuntos de classes com relação ao valor de RMS.

Como discutido anteriormente, os cumulantes de segunda ordem podem ser vistos como uma assinatura do distúrbio. Porém, como o objetivo é utilizar classificadores simples de saída binária, as classes devem ser sempre agrupadas em dois subconjuntos, formados por classes cujos valores de cumulantes são mais correlacionados. Por exemplo, após a obtenção dos primeiros 512 cumulantes de cada classe, é possível observar que a classe 6 e a classe 11 deveriam pertencer a um mesmo subconjunto pois a correlação entre seus cumulantes é igual a 0,98. Por outro lado, as classes 1 e 6 não deveriam pertencer a um mesmo subconjunto pois a correlação entre seus cumulantes é de 0,17.

Com isso, para construção da estrutura em árvore, é necessário, primeiramente, agrupar as classes que mais se correlacionam em dois subconjuntos. Após a definição dos subconjuntos, apenas 5 cumulantes são escolhidos de acordo com (14). Escolhidos os subconjuntos e selecionados os cumulantes, um perceptron é treinado para classificar as classes que pertencem a um dos dois subconjuntos. Depois da classificação realizada pelo primeiro perceptron (topo da árvore), dois subconjuntos são formados novamente e este processo continua até que cada classe possa ser classificada. Como tentativa de reduzir o custo computacional, os primeiros 5 cumulantes selecionados foram também utilizados nos demais perceptrons. A Fig. 5 apresenta a árvore de classificação obtida. Ao final do processo de classificação, o classificador bayesiano é sempre utilizado, separando classes que




Figura 4: Probabilidade *a posteriori* do classificador bayesiano (RMS). Classes que incluem *sag* (linha pontilhada), classes que incluem *swell* (linha tracejada) e classes que não apresentam nenhum dos dois distúrbios (linha contínua).

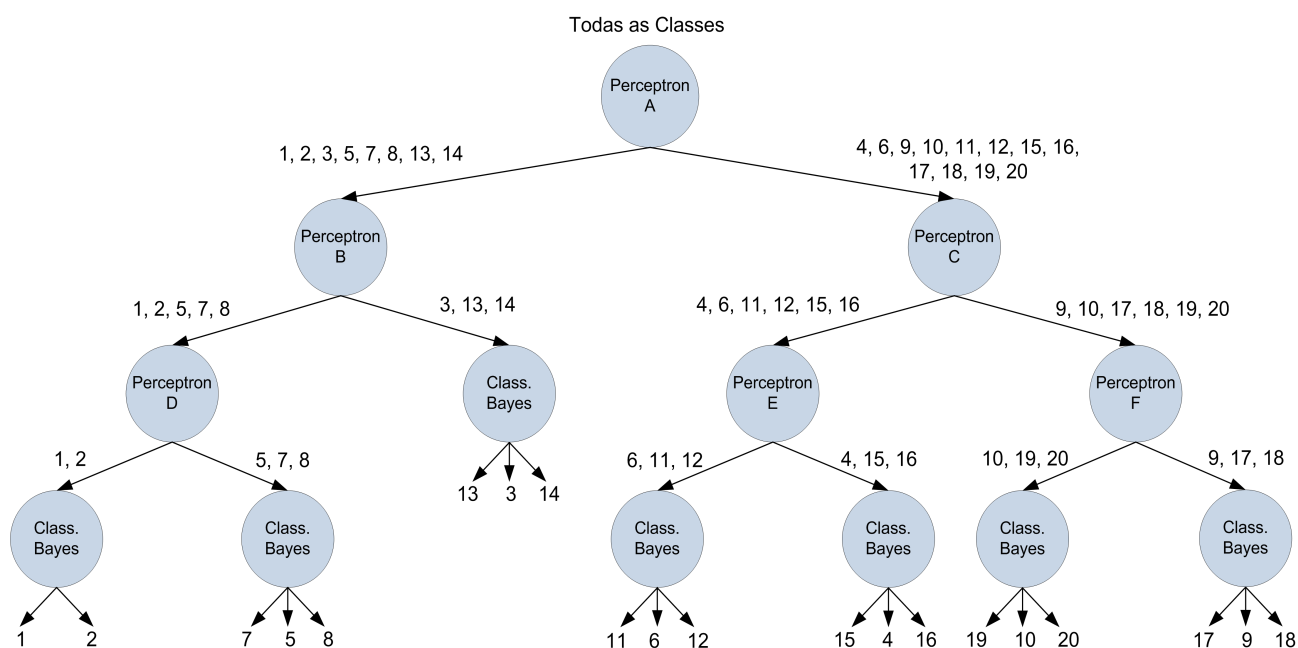


Figura 5: Árvore de classificação.

normalmente possuem cumulantes de segunda ordem similares – as classes *sag* e *swell* possuem cumulantes muito parecidos.

A Tab.2 apresenta o desempenho da abordagem proposta para diferentes níveis de ruído, mostrando que o classificador proposto obteve índices elevados de acerto. Um dado interessante é que, em alguns casos, mesmo não tendo acertado a classe, a escolha não foi totalmente errônea. Por exemplo, em 2,64% dos casos, a classe 9 foi classificada como se fosse a classe 6, detectando corretamente um dos distúrbios presentes.

Embora uma das vantagens de se utilizar EOS seja sua robustez ao ruído, houve um queda de desempenho do classificador, principalmente com relação sinal/ruído de 20dB. Mesmo assim, em várias classes o desempenho continuou satisfatório e este nível de ruído é considerado elevado.

Com relação ao custo computacional do método proposto, a Tab. 3 apresenta o número de operações de soma e multiplicação, o número de avaliações da função de ativação (Perceptrons) e número de cálculos da função exponencial para a classificação dos diferentes distúrbios, para as classes pertencentes ao pior caso de complexidade computacional na estrutura da árvore de classificação (3 Perceptrons mais 1 classificador Bayesiano). A fim de comparar a complexidade computacional do método proposto com outro disponível na literatura, a Tab. 3 apresenta também o custo computacional da técnica apresentada em [12]. Como pode ser observado, a abordagem proposta possui um custo computacional inferior e, ainda, classifica um número maior de classes (20 contra 18).

	30dB	25dB	20dB
1	99,61 ± 0,58	96,74 ± 1,41	85,61 ± 2,63
2	99,66 ± 0,54	95,99 ± 1,68	85,77 ± 2,67
3	99,90 ± 0,28	99,88 ± 0,30	99,60 ± 0,45
4	99,90 ± 0,28	98,95 ± 0,82	97,07 ± 1,38
5	99,83 ± 0,29	98,88 ± 0,72	93,57 ± 1,81
6	97,99 ± 1,24	95,65 ± 1,42	91,67 ± 2,79
7	99,63 ± 0,42	97,03 ± 1,19	92,23 ± 1,73
8	99,50 ± 0,47	95,53 ± 1,34	89,68 ± 2,01
9	94,18 ± 1,86	91,53 ± 1,83	85,31 ± 2,21
10	99,60 ± 0,37	99,55 ± 0,43	99,31 ± 0,49
11	99,99 ± 0,09	99,34 ± 0,57	93,20 ± 1,67
12	99,95 ± 0,30	97,70 ± 1,02	82,62 ± 2,69
13	99,96 ± 0,15	99,95 ± 0,16	99,63 ± 0,40
14	99,57 ± 0,39	99,52 ± 0,41	99,20 ± 0,51
15	94,21 ± 2,02	90,37 ± 2,48	76,35 ± 3,21
16	97,51 ± 0,99	96,16 ± 1,22	90,44 ± 1,98
17	96,69 ± 1,31	95,01 ± 1,31	93,05 ± 1,51
18	95,71 ± 1,25	94,08 ± 1,51	92,75 ± 1,43
19	97,67 ± 1,24	98,08 ± 0,92	96,15 ± 1,17
20	98,30 ± 1,28	97,86 ± 1,08	96,01 ± 1,06

Tabela 2: Eficiência do classificador (validação).

Operações	Método Proposto	Método em [12]
Soma	7.188	94.074
Multiplicação	11.285	123.758
Função de Ativação	3	30
Exponencial	1	–

Tabela 3: Complexidade computacional do método proposto e do método apresentado em [12].

## 5 CONCLUSÕES

A classificação de múltiplos distúrbios em sinais de potência não é uma tarefa simples e não existem muitos trabalhos na literatura que investigam tal problema para uma grande variedade de distúrbios. Dessa forma, este trabalho teve por objetivo desenvolver uma técnica para classificação de um número considerável de tipos de distúrbios.

Utilizando um número reduzido de parâmetros extraídos do sinal de potência, um total de seis (5 cumulantes de segunda ordem e o valor de RMS), e classificadores simples, alguns perceptrons e um classificador bayesiano, foi possível obter um classificador com estrutura em árvore com um bom índice de desempenho sem ter uma alto custo computacional. Ademais, a utilização de uma estrutura em árvore possibilita um entendimento maior do problema em questão, pois é possível visualizar as classes que são mais parecidas ou distintas com relação aos seus cumulantes de segunda ordem. Este sistema, portanto, pode ser útil nas atuais redes inteligentes (*smart grid*), dados a sua reduzida complexidade computacional e bom índice de desempenho.

Como trabalhos futuros, espera-se obter um sistema que possa classificar ainda mais distúrbios e desenvolver uma plataforma em tempo real para classificação de distúrbios elétricos.

## REFERÊNCIAS

- [1] IEEE Standard 1159. “IEEE recommended practice for monitoring electric power quality”. Technical report, IEEE, 1995.
- [2] W. G. Morsi and M. E. El-Hawary. “A New Perspective for the IEEE Standard 1459-2000 Via Stationary Wavelet Transform in the Presence of Nonstationary Power Quality Disturbance”. *IEEE Transactions on Power Delivery*, vol. 23, no. 4, pp. 2356–2365, October 2008.
- [3] M. Bollen, I. Gu, S. Santoso, M. Mcgranaghan, P. Crossley, M. Ribeiro and P. Ribeiro. “Bridging the gap between signal and power”. *Signal Processing Magazine, IEEE*, vol. 26, no. 4, pp. 12–31, Julho 2009.
- [4] C. Nikias and J. Mendel. “Signal processing with higher-order statistics”. *IEEE Trans. on Signal Processing*, vol. 41, no. 1, pp. 10–38, Janeiro 1999.
- [5] M. V. Ribeiro and J. L. R. Pereira. “Classification of single and multiple disturbances in electric signals”. *EURASIP J. Adv. Signal Process*, vol. 2007, no. 2, pp. 15–15, 2007.

- [6] D. D. Ferreira, J. M. de Seixas and A. S. Cerqueira. “ICA-based Method for Power Quality Disturbance Analysis”. In *15th International Conference on Intelligent System Applications to Power Systems*, Brazil, Novembro 2009.
- [7] C. L. Chuang, Y. L. Lu, T. L. Huang, Y. T. Hsiao and J. A. Jiang. “Recognition of multiple PQ disturbances using Wavelet-based Neural Networks - part 2: Implementation and Applications”. In *Transmission and Distribution Conference and Exhibition: Asia and Pacific IEEE/PES*, pp. 48–59, Dalian, China, 2005.
- [8] D. D. Ferreira, A. S. Cerqueira, C. A. Duque and M. V. Ribeiro. “HOS-based method for classification of power quality disturbances”. *Electronics Letters*, vol. 45, no. 3, pp. 83–185, 2009.
- [9] J. J. G. de la Rosa, A. M. Muñoz, A. Gallego, R. Piotrkowski and E. Castro. “Higher-order characterization of power quality transients and their classification using competitive layers”. *Measurement*, vol. 42, no. 3, pp. 478–484, 2009.
- [10] T. Mitchell. *Machine Learning*. McGraw-Hill Education, first edition, October 1997.
- [11] R. O. Duda, P. E. Hart and D. G. Stork. *Pattern Classification*. Wiley-Interscience, second edition, 2000.
- [12] D. D. Ferreira, C. A. Duque, A. S. Cerqueira, M. V. Ribeiro and J. M. d. Seixas. “Sistema automático de classificação de distúrbios elétricos múltiplo e isolados”. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, vol. 22, pp. 39 – 48, 02 2011.