

Classificação de distúrbios de tensão utilizando a transformada wavelet rápida e o algoritmo C4.5

Fayner Aciole¹

Departamento de engenharia elétrica/UNESP, Ilha Solteira, SP

Fabício Ely Gossler²

Departamento de engenharia elétrica/UNESP, Ilha Solteira, SP

Francisco Villarreal³

Departamento de matemática/UNESP, Ilha Solteira, SP

Preservar a qualidade da energia elétrica em sistemas elétricos de potência é algo essencial para o mundo moderno. Os distúrbios de tensão são fenômenos frequentes que ocorrem em tais sistemas e que podem implicar em diversos problemas no cotidiano. O domínio wavelet vem sendo amplamente utilizado para estratégias de detecção e classificação dessas anomalias [1]. Entretanto, dependendo da estratégia adotada, a escolha da wavelet pode influenciar significativamente nos resultados obtidos. Com isso, o presente trabalho tem como objetivo explorar diferentes wavelets a fim de determinar aquelas que são mais apropriadas para a classificação. Baseado em [1], o método utilizado consiste em decompor os sinais de tensão por meio da transformada wavelet rápida (TWR) e, posteriormente, utilizar tais resultados para construir vetores característicos na fase de classificação. O algoritmo C4.5 é explorado para gerar o modelo classificador.

Neste trabalho são explorados seis diferentes tipos de distúrbios de tensão de acordo com o modelo matemático proposto por [1]: harmônico, afundamento (*sag*), elevação (*swell*), *sag* com harmônico e *swell* com harmônico. A tensão sem nenhum tipo de distúrbio (operação normal) também é considerada. A frequência fundamental adotada é 60 Hz e a discretização dos sinais é realizada da mesma forma que em [1]. Para construir os vetores característicos, os sinais são decompostos pela TWR em 11 níveis de resolução, e a energia dos coeficientes wavelet de detalhes em cada nível é calculada. Desse modo, o vetor característico referente a um sinal de tensão $v(t)$ é definido como sendo $F_v = [E_{D1} E_{D2} E_{D3} \dots E_{D11}]$, onde E_{Dm} é a energia dos coeficientes wavelet de detalhes no nível m . Assim, F_v é usado como vetor de entrada para gerar o modelo classificador (C4.5). A fase de classificação é implementada no *software* WEKA [3], sendo o treinamento do modelo classificador realizado pelo método da validação cruzada 10-*fold*. Nesse primeiro momento de investigação, são exploradas 18 wavelets com diferentes números N de momentos nulos das famílias Daubechies (dbN) e Symlets ($symN$) [2].

Foram gerados 2800 sinais (400 para cada classe de distúrbio), sendo que 1400 foram usados para treinar o classificador e o restante para teste. Os resultados da classificação geral para cada wavelet explorada são exibidos na Figura 1. Note que o resultado pode variar para wavelets com o mesmo número de momentos nulos. Na Figura 1-(a) têm-se os resultados obtidos a partir dos sinais puros, ou seja, sinais que não possuem nenhum tipo de ruído. Nas Figuras 1-(b) e 1-(c) têm-se os resultados obtidos a partir dos sinais contaminados com ruído gaussiano branco com níveis de 20 e 30 dB, respectivamente. Note que, para sinais puros obteve-se uma acurácia acima de 99% para

¹fayner.aciole@unesp.br.

²fabricao.ely@unesp.br.

³francisco.villarreal@unesp.br.

todas as wavelets utilizadas. Neste caso, o melhor resultado obtido foi o da sym9 com 99,92% de precisão. Considerando os sinais obtidos a partir de sinais ruidosos é possível verificar uma maior dispersão dos resultados obtidos. Para sinais ruidosos de 20 dB, a sym7 foi a que apresentou o pior desempenho (83%) e as wavelets db3 e sym3 foram as que apresentaram maior acurácia (89,79%). As wavelets que obtiveram os melhores resultados na classificação dos sinais ruidosos de 30 dB foram a db2 e a sym2 com acurácia de 96,14%. Assim, os resultados preliminares apontam que a escolha apropriada da wavelet para o método utilizado depende do nível de ruído presente nos sinais.

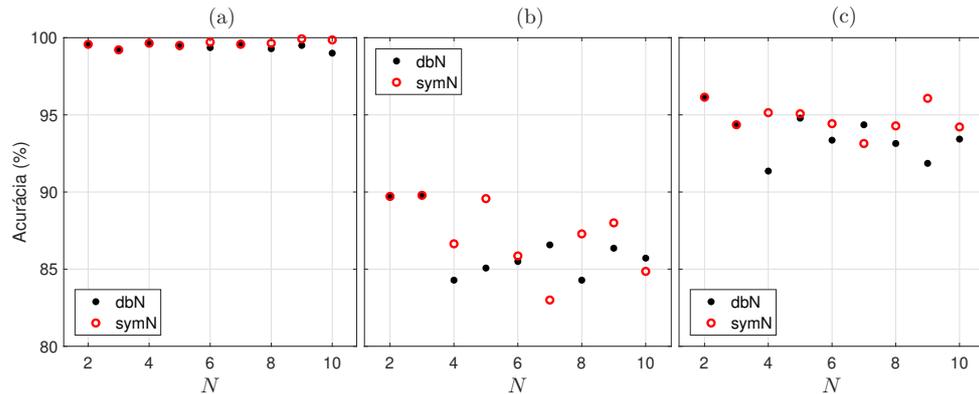


Figura 1: Resultados da classificação em termos de porcentagem usando diferentes wavelets dbN e symN com $2 \leq N \leq 10$ considerando (a) sinais puros e sinais ruidosos de (b) 20 dB e (c) 30 dB.

Agradecimentos

Os autores agradecem o suporte financeiro da agência FAPESP (processo nº 2018/12067-6).

Referências

- [1] Abdel-galil, T. K. A., Kamel, M., Youssef, A. M., El-Saadany, E. F. E. and Salama, M. M. A. Power quality disturbance classification using the inductive inference approach. *IEEE Transactions on power delivery*, 19:1812–1818, 2004. DOI: 10.1109/TPWRD.2003.822533.
- [2] Daubechies, I. *Ten lectures on wavelets*. Society for Industrial and Applied Mathematics, Philadelphia, 1992. DOI: 10.1137/1.9781611970104.
- [3] Witten, I. H., Frank, E., Hall, M. A. and Pal, C. J. *Data mining: practical machine learning tools and techniques, 4a edição*, Morgan Kaufmann, 2016.