

Análise da autossimilaridade de sinais de voz baseada em wavelets na detecção de patologias laríngeas

Jayne dos Santos Lima, Stefanie G. Vilela, Washington C. de A. Costa, Silvana Cunha Costa e Suzete E. N. Correia

Resumo—Este artigo utiliza o expoente de Hurst, obtido através da transformada wavelet discreta, como medida de autossimilaridade para caracterizar as não linearidades de sinais de vozes saudáveis e dos sinais afetados por patologias nas pregas vocais. Para avaliar o seu potencial de discriminação são usadas, no processo de classificação, as Máquinas de Vetor de Suporte. Os resultados obtidos atestam que há autossimilaridade nos sinais analisados para as wavelets investigadas.

Palavras-Chave—Detecção de patologias laríngeas, Expoente de Hurst, Transformada wavelet discreta, Máquinas de Vetor de Suporte.

Abstract—This article employs the Hurst exponent, obtained by discrete wavelet transform, as a measure of self-similarity to characterize the nonlinearities of healthy voices and from those affected by vocal folds pathologies. To evaluate their discriminative potential, Support Vector Machines are used in the classification process. The results show self-similarity at the analyzed signals for the investigated wavelets.

Keywords—Laryngeal pathology detection, Hurst exponent, Discrete Wavelet Transform, Support Vector Machine.

I. INTRODUÇÃO

Um sinal de voz pode ser visto como um processo aleatório com variações temporais. Ao se observar um sinal de voz saudável em diferentes escalas de tempo constata-se uma semelhança no padrão das amostras devido à periodicidade do sinal, em se tratando de sons sonoros. Vozes afetadas por patologias nas pregas vocais apresentam um comportamento irregular tanto das características temporais quanto espectrais [1].

O expoente de Hurst é uma medida de autossimilaridade capaz de fornecer informações sobre correlação e persistência em uma série temporal. O valor desse expoente varia entre 0 e 1. Para $H = 0.5$ o sinal é decorrelacionado. Para valores acima de 0,5 o sinal apresenta correlações positivas, e é dito persistente, ou seja, a probabilidade de repetição de um valor é maior do que cinquenta por cento. Para valores abaixo de 0,5 o sinal possui correlações negativas e é caracterizado como anti-persistente, ou seja, existe uma probabilidade maior do que cinquenta por cento de que um valor negativo seja seguido de um valor positivo ou vice-versa [2].

O expoente de Hurst pode ser obtido por meio de diferentes métodos, tais como: a estatística R/S, os métodos de Higuchi e da variância no tempo já avaliados, em trabalhos anteriores [3,4]. A transformada wavelet é uma ferramenta matemática que permite a análise dos sinais em resoluções distintas, de modo que em cada escala aspectos diferentes podem ser

observados. Como as wavelets, conjunto de funções usadas na decomposição, são definidas de forma autorrecursiva, tornam-se uma ferramenta adequada para a análise de processos autossimilares [2,5].

Neste trabalho, o parâmetro de Hurst, obtido por meio da transformada wavelet discreta, é investigado como extrator de características, para diferenciar vozes saudáveis de vozes afetadas por edema de Reinke, paralisia e nódulo nas pregas vocais. Três wavelets da família Daubechies foram testadas, as de ordem 1, 12 e 24. Para a classificação dos sinais, são empregadas as Máquinas de Vetor de Suporte.

II. FUNDAMENTAÇÃO TEÓRICA

A transformada wavelet discreta [6] pode ser calculada através de dois filtros: um filtro passa-alta relacionado a função wavelet $\psi(t)$ que fornece os coeficientes responsáveis pelos detalhes d_j , e um filtro passa-baixa relacionado a uma função chamada escalonamento, $\phi(t)$, que fornece os coeficientes de aproximação c_j , na escala ou resolução j .

Na estimativa do expoente de Hurst por meio da transformada wavelet discreta, considera-se o método proposto por Abry e Veitch [7], que emprega a energia do sinal Γ_j calculada por meio da média dos coeficientes de detalhes d_j , obtidos da análise multirresolução, da seguinte forma:

$$\Gamma_j = \frac{1}{n_j} \sum_k |d_j(k)|^2 \quad (1)$$

em que n_j é a quantidade de coeficientes wavelets no nível de resolução j e o parâmetro k corresponde à localização.

Uma estimativa para o expoente de Hurst (H) segue da regressão linear de $\log_2(\Gamma_j)$ por j . O coeficiente angular γ dessa reta ajustada fornece uma estimativa para H por meio da relação $\gamma = 2H \pm 1$, em que $H = (\gamma+1)/2$ para $\gamma < 1$, e $H = (\gamma-1)/2$ para $\gamma > 1$.

III. MATERIAIS E MÉTODOS

A Figura 1 apresenta um diagrama da metodologia empregada. Os sinais de voz são provenientes da base de dados gravada pelo *Massachusetts Eye and Ear Infirmary Voice and Speech Lab* [8]. Todos os sinais utilizados são da vogal sustentada /a/, amostrados a uma taxa de 25.000 amostras/s. Foram utilizados 53 arquivos de vozes saudáveis e 114 sinais de vozes patológicas, dentre as quais 44 são afetadas por edema de Reinke, 52 por paralisia e 18 por nódulos nas pregas vocais.

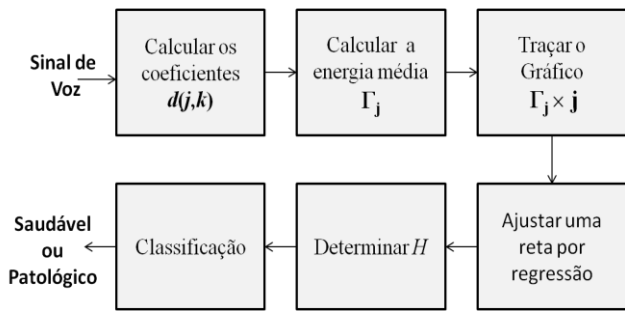


Fig. 1. Diagrama da metodologia empregada para a detecção de patologias laringeas.

O expoente de Hurst é extraído considerando o sinal de voz como uma série completa. Estes sinais são decompostos através das wavelets de Daubechies de ordem 1,12 e 24. Os coeficientes de detalhe são calculados para 10 níveis de resolução.

A classificação dos sinais de voz entre saudáveis e patológicos é feito por meio das Máquinas de Vetor de Suporte [9]. O treinamento foi realizado através do aprendizado supervisionado, empregando validação cruzada. Foram considerados 10 subconjuntos para treino e validação. Os subconjuntos de treino são obtidos selecionando-se aleatoriamente e sem repetição de cada classe analisada 90% das amostras dos sinais de vozes da base. As amostras restantes são usadas para compor os subconjuntos de validação.

IV. RESULTADOS

Na Tabela I são apresentados os valores médios obtido dos expoentes de Hurst dos sinais de vozes saudáveis e patológicos, com as três wavelets analisadas. A partir dos valores médios do expoente de Hurst, pode-se verificar a existência de correlações positivas nos sinais analisados, indicando autossimilaridade, tendo em vista que os valores obtidos são superiores a 0,5.

TABELA I. VALOR MÉDIO DE H PARA OS SINAIS DE VOZES SAUDÁVEIS E PATOLÓGICOS

Sinais de Voz	Wavelets de Daubechies		
	Ordem 1	Ordem 12	Ordem 24
Saudável	0,5696	0,7428	0,7410
Edema	0,6916	0,6701	0,6266
Paralisia	0,7429	0,5645	0,5946
Nódulos	0,7496	0,5517	0,6451

Na Tabela II estão apresentados os resultados obtidos para a classificação do expoente de Hurst por meio das Máquinas de Vetor de Suporte. A métrica de avaliação de desempenho utilizada é a correta classificação, que é dada pela razão entre o número de acertos pelo número total de sinais empregados. São apresentados os resultados da comparação entre as seguintes classes: sinais de vozes saudáveis e patológicos (SDLxPTL), saudáveis e afetados por edema de Reinke (SDLxEDM), saudáveis e afetados por paralisia (SDLxPAR) e saudáveis e afetados por nódulos (SDLxNDL).

Observa-se que os melhores valores entre todas as classes testadas são obtidos pela wavelet de Daubechies de ordem 1. Tal fato pode ser justificado pela quantidade de coeficientes empregados na decomposição da transformada wavelet discreta. A relação entre o número de coeficientes e a ordem N

da wavelet de Daubechies é dada por 2^N. Quanto menor a ordem da wavelet, menor é a sua regularidade e menos suave é a wavelet mãe e, conseqüentemente, filtros com menor número de coeficientes são obtidos [2]. Filtros de pequeno comprimento são indicados para a extração de detalhes. O melhor resultado foi obtido na separação entre o grupo de sinais saudáveis e afetados por nódulos nas pregas vocais.

TABELA II. TAXA DE CORRETA CLASSIFICAÇÃO (%) DO EXPOENTE DE HURST POR MEIO DAS MÁQUINAS DE VETOR DE SUPORTE

Classes	Wavelets de Daubechies		
	Ordem 1	Ordem 12	Ordem 24
SDLxPTL	89,28	77,38	82,73
SDLxEDM	87,75	69,38	78,57
SDLxPAR	91,58	61,68	82,24
SDLxNDL	94,36	81,69	81,69

V. CONCLUSÕES

Neste trabalho o expoente de Hurst, obtido por meio da transformada wavelet discreta, foi avaliado como medida de autossimilaridade na detecção de patologias na laringe. Entre as famílias wavelets empregadas a de Daubechies de ordem 1 demonstrou ser a mais eficaz para detectar desordens vocais presentes no sinal de voz. Uma taxa de classificação superior a 94% foi obtida na separação entre sinais de vozes saudáveis e vozes afetadas por nódulos vocais. Na separação entre sinais afetados por paralisia nas pregas vocais e sinais saudáveis, a taxa de classificação é superior a 90%. Conclui-se que, através do expoente de Hurst é possível verificar autossimilaridade nos sinais analisados e que este parâmetro pode ser considerado como extrator num sistema para a detecção de patologias laringeas.

AGRADECIMENTOS

Os autores agradecem a UFCG pelo fornecimento da base de dados e ao IFPB pelo suporte financeiro.

REFERÊNCIAS

- [1] W. C. de A. Costa, S. L. do N. C. Costa, F.M. de Assis e B.G. Aguiar Neto, "Classificação de sinais de vozes saudáveis e patológicas por meio da combinação entre medidas da análise dinâmica não linear e codificação preditiva linear", Revista Brasileira de Engenharia Biomédica, v. 29, no. 1, Março 2013.
- [2] A. C. Soterroni, M. O. Domingues, F. M. Ramos, "Estimativa do expoente de Hurst de séries temporais caóticas por meio da transformada wavelet discreta", Brazilian Conference on Dynamics, Control and Applications, 2008.
- [3] J. S. Lima, T. T. C. Palito, S. C. Costa, S. E. N. Correia, W. C. Costa, "Análise comparativa entre métodos de obtenção do parâmetro de Hurst na detecção de patologias laringeas", Anais do XXIII Congresso Brasileiro em Engenharia Biomédica, 2012.
- [4] J. S. Lima, T. T. C. Palito, S. C. Costa, S. E. N. Correia. "Classificação de sinais vozes patológicas por meio do parâmetro de Hurst e LDA". Anais do XXX Simpósio Brasileiro de Telecomunicações, 2012.
- [5] R. F. Custódio, *Análise não-linear no reconhecimento de padrões sonoros: Estudo de caso para sons pulmonares*, Tese de Doutorado, Universidade Federal do Rio Grande do Sul, Porto Alegre, 1999.
- [6] S. Mallat, *A Wavelet Tour of Signal Processing*, Academic Press, 1999.
- [7] P. Abry e D. Veith, "A wavelet-based joint estimator of the parameters of long-range dependence", IEEE Trans. Inf. Theory, vol. 45, no. 3, pp. 878-897, Mar. 1998
- [8] K. Elemetrics, *Kay Elemetrics Corp. Disordered Voice Database*, model 4337, 03 Ed, 1994.
- [9] VAPNIK, V. *The nature of Statistical Learning Theory*, Springer-Vaerlag, 1995.