

Análise comparativa entre técnicas de classificação de vozes saudáveis e patológicas utilizando SVM e LDA

Jayne dos Santos Lima^[1], Thamyres Tânulla Cavalcante Palitó^[2], Vinícius Jefferson Dias Vieira^[3], Silvana Cunha Costa^[4], Suzete Élide N. Correia^[5], Washington César de Almeida Costa^[6]

[1] jayneslima. [2] thamyrestamulla. [3] viniciusjdv. [4] silvanacunhacosta. [5] suzete.correia. [6] washinstoncesar@gmail.com. Instituto Federal de Educação, Ciência e Tecnologia da Paraíba. Av. 1º de Maio, 720, Jaguaribe. CEP: 58.015-430 – João Pessoa/PB

RESUMO

A análise acústica por meio de técnicas de processamento digital de sinais tem sido largamente aplicada na avaliação de desordens vocais provocadas por patologias laringeas, devido a sua simplicidade e natureza não invasiva. Neste trabalho, o expoente de Hurst – obtido pelos métodos da variância no tempo, estatística R/S e Higuchi – é extraído dos sinais de vozes e empregado como parâmetro no processo de classificação entre vozes saudáveis e patológicas, especificamente, edema de Reinke, paralisia e nódulos nas pregas vocais. É realizada uma análise comparativa do desempenho de dois métodos distintos de classificação: a Análise Discriminante Linear e as Máquinas de Vetor de Suporte. Os resultados indicam que as máquinas de vetor de suporte fornecem melhor desempenho, com uma taxa de correta classificação superior a 99%, na discriminação entre os sinais de vozes saudáveis e vozes afetadas por paralisia nas pregas vocais.

Palavras-chave: Patologias laringeas. Processamento digital de sinais. Parâmetro de Hurst. Máquinas de vetor de suporte. Análise discriminante linear.

ABSTRACT

Acoustic analysis by techniques of digital signal processing has been widely applied in the evaluation of vocal disorders caused by laryngeal pathology, due to its noninvasive nature and simplicity. In this work, the Hurst exponent – obtained by the method of variance in time, statistic R/S and Higuchi – is extracted from the voices' signals and used as parameter in classification process between healthy and pathological voices, specifically, vocal fold nodules, paralysis and Reinke's edema. It performed a comparative analysis of the performance of two different methods of classification: the Linear Discriminant Analysis and the Support Vector Machines. The results indicate that the technique of support vector machines is the most efficient showing a correct classification rate over 99% in the discrimination between healthy voices signals and voices affected by vocal paralysis.

Keywords: *Laryngeal pathology. Digital signal processing. Hurst parameter. Support vector machines. Linear discriminant analysis.*

1 Introdução

Vários pesquisadores têm dedicado esforços na obtenção de métodos eficientes para discriminar vozes patológicas usando análise acústica. Diferentes métodos de processamento de sinais foram propostos para ser utilizados em sistemas automáticos para a detecção de sinais de vozes patológicas. Para esta finalidade, a ideia principal de todos os sistemas propostos é o reconhecimento de padrões.

Várias técnicas vêm sendo utilizadas para a classificação de sinais de vozes patológicas com o uso de diferentes parâmetros e medidas acústicas, bem como a partir da aplicação de inúmeras ferramentas para o reconhecimento de padrões e a classificação automática dos sinais (ALMEIDA, 2010; COSTA, 2008; ESPINOSA, 2000).

Aprendizado de máquina é uma área da Inteligência Artificial que busca o desenvolvimento de sistemas baseados em procedimentos automáticos. Esta área tem como objetivo obter um ganho de desempenho na tarefa executada com a experiência adquirida com a manipulação de dados relativos ao problema tratado (ALMEIDA, 2010).

A eficiência do sistema depende, principalmente, da escolha das características e do classificador empregado. Embora vários sistemas já tenham sido propostos, incluindo as mais diversas características e classificadores, este é um campo de pesquisa amplo e não concluído, pois existe a constante necessidade de que o classificador utilizado seja robusto/eficiente, de forma que o sistema de reconhecimento de vozes seja o mais confiável possível.

Dentre as muitas técnicas possíveis para a classificação de dados estão a análise discriminante linear ou *Linear Discriminant Analysis* (LDA) e as máquinas de vetor de suporte ou *Support Vector Machines* (SVMs), que vêm sendo também aplicadas para discriminação de vozes patológicas (ALMEIDA, 2010).

Na literatura podem ser encontradas diversas aplicações automatizadas da SVMs nas mais variadas áreas de pesquisa, tais como: bioinformática (NOBEL, 2004; LOURENA, 2006), reconhecimento de manuscritos (JUSTINO, 2003; BARANOSKI et al., 2005), reconhecimento facial (RODRIGUES, 2007), classificação de imagens de câncer de pele (SOARES, 2008) e reconhecimento de voz (ALMEIDA, 2010).

Almeida (2010) propõe um classificador inteligente para diagnóstico de patologias da laringe utilizando

SVMs. Os resultados obtidos para classificação de vozes saudáveis e patológicas foi de 98,46%.

Fonseca (2008) utilizou LS-SVM aplicada na análise de vozes patológicas. O resultado foi de 92% de acerto na identificação de vozes patológicas para os 50 sinais usados no treino do classificador.

Neste artigo é feita uma análise comparativa entre dois métodos de classificação para os sinais de vozes: as máquinas de vetor de suporte e a análise discriminante linear. A característica fornecida aos dois classificadores é o parâmetro de Hurst, obtido pelos seguintes métodos: estatística R/S, método de Higuchi e o método da variância no tempo.

2 Materiais e métodos

Nesta seção serão apresentados os métodos de obtenção do parâmetro de Hurst, os métodos de classificação utilizados e a base de dados empregada na pesquisa.

2.1 Parâmetro de Hurst

O parâmetro de Hurst (H) é uma medida estatística de autossimilaridade, capaz de representar o comportamento estocástico do sinal de voz (SOTERRONI et al.; FANTINATO et al., 2008). Pequenas variações no parâmetro de Hurst denotam mudanças significativas no comportamento dos sinais, caracterizando o grau de desordem do mesmo. Além disso, o cálculo deste parâmetro apresenta um baixo custo computacional e pode ser obtido em tempo real, durante atividade da fala. A seguir é feita uma descrição dos métodos utilizados, neste trabalho, para extração do parâmetro de Hurst.

Estatística R/S – O estimador R/S é um dos métodos mais simples e conhecidos para estimar o grau de dependência de uma sequência amostral. A estatística R/S nada mais é do que a divisão da amplitude pelo desvio padrão de uma amostra. Hurst (1951) observou uma relação entre a estatística R/S e o tamanho da amostra, de maneira que a estatística R/S é igual à metade do número de observações elevado a um expoente, denominado expoente de Hurst.

Sejam X_t os valores da série a ser estudada, r_t o retorno logarítmico desta série e N o tamanho da amostra com τ observações, sendo $\tau < N$. O cálculo da estatística R/S e do expoente de Hurst devem seguir os passos (CAJUEIRO et al., 2006):

1) Para cada τ , divide-se a amostra N em n blocos de τ elementos numerados com $n \leq i \leq 1$. Em cada bloco i os elementos $r_{t,i}$ são numerados com $1 \leq t \leq \tau$.

2) Calcula-se a média e o desvio padrão de cada bloco, de acordo com as equações (1) e (2), respectivamente:

$$\bar{r}_i = \frac{1}{\tau} \sum_{t=1}^{\tau} r_{t,i} \quad (1)$$

$$S_i = \left[\frac{1}{\tau} \sum_{t=1}^{\tau} (r_{t,i} - \bar{r}_i)^2 \right]^{1/2} \quad (2)$$

3) Calcula-se, para cada bloco i , a estatística $(R/S)_i$:

$$(R/S)_i = \frac{1}{S_i} [M_{\max} \sum_{k=1}^i (r_{k,i} - \bar{r}_i) - M_{\min} \sum_{k=1}^i (r_{k,i} - \bar{r}_i)] \quad (3)$$

em que Max e Min representam, respectivamente, os valores máximo e mínimo do somatório.

4) Calcula-se a média dos valores $(R/S)_i$ e se associa ao tamanho do bloco τ :

$$(R/S)_i = \frac{1}{n} \sum_{i=1}^n (R/S)_i \quad (4)$$

5) O expoente de Hurst é obtido da relação:

$$(R/S)_\tau = (\tau/2)^H \quad (5)$$

que pode ainda ser escrito da seguinte forma:

$$\log_{10}(R/S)_\tau = H \log_{10} \tau - H \log_{10} 2 \quad (6)$$

Com um gráfico de $\log_{10}(R/S)_\tau$ versus $\log_{10} \tau$, o resultado seria uma linha reta com inclinação H . O valor do parâmetro de Hurst pode ser estimado através da regressão linear sobre os pontos obtidos do estimador R/S.

Método de Higuchi – Este método, sugerido por Higuchi, considera a dimensão fractal D de uma série temporal no cálculo do comprimento de uma curva. O método do cálculo da dimensão fractal consiste em considerar um conjunto finito de observações de séries temporais tomadas em um intervalo regular (HIGUCHI, 1988):

$$X(1), X(2), X(3), \dots, X(N) \quad (7)$$

A partir de dada série, foi construída uma nova série temporal X_k^m , definida como segue:

$$X_k^m; X(m), X(m+k), X(m+2k), \dots, X\left(m + \left[\frac{N-m}{k}\right] \cdot k\right) \quad (8)$$

em que m e k são inteiros que indicam o tempo inicial e o intervalo de tempo, respectivamente $\left[\frac{N-m}{k}\right]$ e indica a notação de Gauss. Para um intervalo de tempo igual a k , tem-se k conjuntos da nova série temporal, no caso de $k = 3$ e $N = 100$, três séries temporais serão obtidas pelo processo acima descrito. Serão elas:

$$X_3^1; X(1), X(4), X(7), \dots, X(97), X(100), \quad (9)$$

$$X_3^2; X(2), X(5), X(8), \dots, X(98), \quad (10)$$

$$X_3^3; X(3), X(6), X(9), \dots, X(99), \quad (11)$$

O comprimento da curva, X_k^m , é definido por:

$$L_m(k) = \frac{\left\{ \left(\sum_{i=1}^{\left[\frac{N-m}{k}\right]} |X(m+ik) - X(m+(i-1)k)| \right) \cdot \frac{N-1}{\left[\frac{N-m}{k}\right]} \right\}}{k} \quad (12)$$

O termo $\frac{N-1}{\left[\frac{N-m}{k}\right] \cdot k}$ representa o fator de normalização para o comprimento da curva de sub-

conjunto de séries temporais. O comprimento da curva foi definido para o intervalo de tempo k , $\langle L(k) \rangle$, como o valor médio de k conjuntos de $L_m(k)$. Se $\langle L(k) \rangle, \alpha k^{-D}$, então a curva fractal é a dimensão D . O valor do parâmetro de Hurst é obtido da expressão em que $D = 2 - H$.

Método da variância no tempo – A série temporal original $(X = Xi; i = 1, 2, \dots, N)$ é dividida em N/m blocos de tamanho m e a série agregada $X^{(m)}(k)$ é calculada como:

$$X^{(m)}(k) = \frac{1}{m} \sum_{i=(k-1)m+1}^{km} X(i) \quad k = 1, 2, 3, \dots \quad (13)$$

A variância da amostra para a sequência agregada é calculada como:

$$\text{var}(X^{(m)}) = \frac{1}{N/m} \sum_{k=1}^{N/m} (X^{(m)}(k))^2 - \left(\frac{1}{N/m} \sum_{k=1}^{N/m} X^{(m)}(k) \right)^2 \quad (14)$$

Este processo é repetido para diferentes valores de m . O processo decresce linearmente em escala logarítmica num intervalo $-1 < \beta < 0$. A variância temporal ou agregada é obtida traçando-se um gráfico $\log(\text{var}(X^{(m)}))$ e novamente $\log(m)$, então os pontos estão situados sobre uma linha reta com $0 < \beta < 1$. Valores estimados de β sugerem autossimilaridade, e uma relação para o grau de autossimilaridade é dada por $H = 1 - \beta/2$ (YILMAZ, 2002).

2.2 Análise de Discriminante Linear

A análise discriminante é uma técnica da estatística multivariada utilizada para discriminar e classificar objetos em duas ou mais classes (VARELLA, 2004). O problema da discriminação entre dois ou mais grupos, visando posterior classificação, consiste em se obter funções matemáticas capazes de classificar um indivíduo Z em uma de várias populações (classes) $\pi_i, (i = 1, 2, \dots, g)$, com base em medidas de um número p de características. Busca-se minimizar a probabilidade de má classificação, isto é, minimizar a probabilidade de classificar erroneamente um indivíduo em uma população π_i , quando realmente pertence à população $\pi_j, (i \neq j) i, j = 1, 2, \dots, g$.

A ideia básica é a obtenção de uma combinação linear das características observadas que apresente maior poder de discriminação entre populações. Esta combinação linear é denominada função discriminante.

Tal função tem a propriedade de minimizar as probabilidades de má classificação, quando as populações são normalmente distribuídas com média μ e variância σ conhecidas. Entretanto, tal situação não ocorre, isto é, a média e a variância das populações normalmente não são conhecidas, portanto havendo a necessidade de estimação desses parâmetros. Pode-se assumir que as populações têm uma mesma matriz de covariâncias ou não. Quando a regra de classificação assume que as variâncias das populações são iguais, as funções discriminantes são ditas lineares e, quando não, são funções discriminantes quadráticas (VARELLA, 2004).

A função discriminante linear de Fisher do vetor aleatório Z que produz a máxima separação entre duas populações é dada por:

$$D(Z) = L \times Z = [\mu_1 - \mu_2] \times \Sigma^{-1} X \quad (15)$$

em que L é o vetor discriminante, μ é o vetor de médias e S a matriz comum de covariâncias das populações π_1 e π_2 .

2.3 Máquinas de Vetor de Suporte

O objetivo da classificação por meio de vetor de suporte é desenvolver uma forma computacionalmente eficiente de aprender bons hiperplanos de separação em um espaço de características de alta dimensão, entendendo-se por bons hiperplanos aqueles que aperfeiçoam os limites de generalização, e por computacionalmente eficiente, algoritmos capazes de trabalhar com amostras de tamanho de ordem de 100 mil instâncias. Existem diversos limites de generalização com diferentes algoritmos: otimização da margem máxima, distribuição das margens, números de vetores de suporte, etc.


Em sua forma básica, as máquinas de vetor de suporte são classificadores lineares que separam os dados em duas classes através de um hiperplano de separação. Um hiperplano ótimo separa os dados com a máxima margem possível, que é definida pela soma das distâncias entre os pontos positivos e os pontos negativos mais próximos do hiperplano. Estes pontos são chamados de vetores de suporte e estão circulos na Figura 1. O hiperplano é construído com base em treinamento prévio em um conjunto finito de dados (VAPNIK, 1999).

Sendo um conjunto de treinamento $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ onde y tem valor 1 ou -1, indicando a que classe x pertence, e sendo x um vetor de p dimensões normalizado (com valores 0, 1 ou -1), a SVM divide o hiperplano de acordo com a equação (16):

$$w^T + b = 0 \quad w^T + b = 0 \quad (16)$$

em que o vetor w é um vetor perpendicular ao hiperplano, x é o vetor de entrada e b é uma variável que permite que a margem do hiperplano seja maximizada, pois sem esta variável o hiperplano obrigatoriamente passaria pela origem.

Figura 1 – Classificação de um conjunto de dados usando uma SVM linear (RODRIGUES et al., 2007).



Como o interesse está na maior margem de separação, tem-se que dar atenção aos hiperplanos paralelos e ao hiperplano ótimo, mais próximo aos vetores de suporte de cada classe. Estes hiperplanos podem ser descritos pelas equações:

$$w^T + b = 1 \tag{17}$$

$$w^T + b = -1. \tag{18}$$

Sendo o conjunto de dados de aprendizado linearmente separável, é possível selecionar estes hiperplanos maximizando a distância entre eles de modo que não haja pontos no intervalo destes pontos. A geometria mostra que a distância entre estes dois hiperplanos é $2/|w|$, portanto deseja-se minimizar o valor de $|w|$, garantindo que para cada vetor de entrada x_i :

$$\left\{ \begin{array}{l} w^T x_i + b \geq 1, \text{ se } y_i = 1 \\ w^T x_i + b \leq -1, \text{ se } y_i = -1 \end{array} \right\} \tag{19}$$

O que pode ser reescrito como:

$$y_i [w^T x_i + b] \geq 1 \tag{20}$$

Quando é necessário realizar uma separação não linear de um conjunto de dados, aplica-se um processo de mapeamento aos exemplos contidos no conjunto. Em um espaço de maior dimensão, também denominado espaço de características, os dados das duas classes podem ser separados por uma SVM linear com baixo erro. Esse processo de mapeamento é realizado pela introdução e uso de funções *Kernel*, que computam produtos escalares entre cada par de exemplos no espaço de características. Logo, a única

modificação necessária nas SVMs para definir funções não lineares na separação dos dados é substituir todos os produtos escalares entre exemplos pela função *Kernel* (LORENA e CARVALHO, 2008).

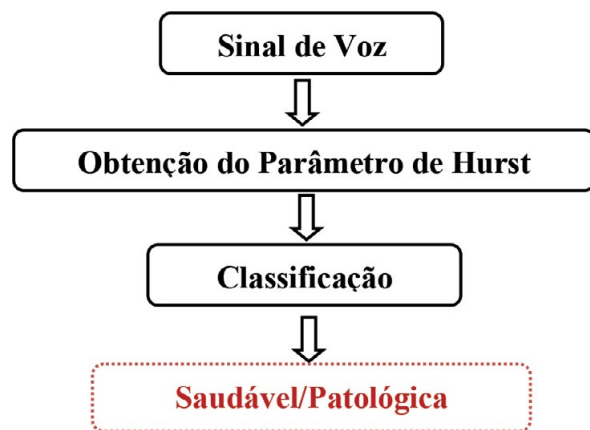
2.4 Base de dados

A base de dados utilizada neste trabalho, *Disordered Voice Database, Model 4337*, foi gravada pelo *Massachusetts Eye and Ear Infirmary (MEEI) Voice and Speech Lab* e comercializada pela *Kay Elemetrics (KAY ELEMETRICS, 1994)*. Esta base inclui cerca de 700 amostras de pacientes com uma grande variedade de desordens da voz provocadas por causas orgânicas, neurológicas, traumáticas e psicogênicas. As amostras contêm de 1 a 3 segundos da vogal sustentada /ah/. Foram utilizadas 167 amostras no total, sendo 53 de vozes saudáveis (SDL) e 114 de vozes patológicas (PTL): 44 sinais com edema de Reinke (EDM), 52 com paralisia nos nervos laríngeos (PRL) e 18 com nódulos vocais (NDL).

2.5 Sistema proposto

Na Figura 2 é apresentado um diagrama simplificado da metodologia empregada para o sistema proposto de classificação dos sinais de vozes, dividido em três etapas fundamentais:

Figura 2 – Diagrama de blocos básico para o sistema proposto.



O primeiro passo é a aquisição do sinal. Neste trabalho o sinal é oriundo da base de dados citada anteriormente.

Nesta etapa ocorre a extração do expoente de Hurst de cada sinal pelos métodos da Variância Agregada, estatística R/S e método de Higuchi, que serão

os dados de entrada no processo de classificação. Os expoentes de Hurst utilizados neste trabalho foram extraídos e analisados em pesquisas anteriores (PALITÓ et al., 2010; LIMA et al., 2011a e 2011b).

A última etapa é a classificação dos sinais de vozes entre saudáveis e patológicos por meio das técnicas de análise discriminante linear e máquinas de vetor de suporte.

Os expoentes de Hurst extraídos pelo método da variância no tempo são utilizados como dados de entrada para as SVMs e LDA, que atuam como o método de reconhecimento de padrões.

O treinamento das máquinas de vetor de suporte é realizado através do aprendizado supervisionado, pois este tipo de aprendizado detecta automaticamente os exemplos mais relevantes nas bases de dados utilizadas, os vetores de suporte e realiza o mapeamento implícito dos dados em um espaço de dimensões elevadas, através das funções *Kernel*.

O processo de classificação de vozes patológicas é dividido em duas partes: o conjunto de treinamento e o conjunto de validação. No processo de classificação da LDA, foram utilizados 50% dos sinais para a etapa de treinamento e 50% na etapa de teste. No caso das SVMs foram utilizados 10 subconjuntos na etapa de validação cruzada.

Foram utilizadas quatro máquinas de vetor de suporte, uma para cada classe de sinais. Em todas as máquinas utilizou-se o *Kernel* polinomial com parâmetro $C = 0,8$. Este parâmetro indica a distância da margem até a linha de separação das classes.

3 Resultados e discussão

A métrica de avaliação de desempenho utilizada é a correta classificação, que é dada pela razão entre o número de acertos e o número total de amostras. São apresentados os resultados de uma comparação entre os dois métodos empregados para a classificação dos sinais de vozes, ambos utilizando como medida de entrada o parâmetro de Hurst, obtido pelo método da variância no tempo.

Nas Tabelas 1 e 2 estão os resultados obtidos para a classificação do parâmetro de Hurst por meio da técnica LDA e os resultados obtidos para a técnica de SVM, respectivamente.

Tabela 1 – Taxas de correta classificação para a técnica de análise discriminante linear.

Correta Classificação (%)			
Classe	RS	Variância	Higuchi
SDL/PTL	71,30	94,92	93,40
SDL/PAR	82,84	98,39	96,87
SDL/EDM	74,57	89,29	90,10

Tabela 2 – Taxas de correta classificação para a técnica das máquinas de vetor de suporte (SVM).

Correta Classificação (%)			
Classe	RS	Variância	Higuchi
SDL/PTL	80,00	96,41	91,75
SDL/PAR	82,63	99,05	98,11
SDL/EDM	77,32	90,72	88,62

Levando em consideração que os melhores resultados foram obtidos para o parâmetro de Hurst por meio da variância agregada, e analisando os dois classificadores, é possível verificar a maior eficiência da técnica SVM nesse caso. Entretanto, a técnica de análise discriminante linear foi melhor quando empregado, para a extração do parâmetro de Hurst, o método de Higuchi.

4 Considerações finais

Neste trabalho foi avaliado o desempenho das máquinas de vetor de suporte e da análise discriminante linear no processo de classificação de sinais de vozes saudáveis e patológicas, a partir do parâmetro de Hurst. A técnica da variância no tempo para a extração do parâmetro de Hurst, em conjunto com as máquinas de vetor de suporte na classificação, apresentaram maior eficiência em todas as classes analisadas, fornecendo uma taxa de correta classificação superior a 99%.

Como trabalhos futuros, pretende-se: 1) combinar o expoente de Hurst com outras características dos sinais de vozes, tais como entropia e coeficientes LPC, entre outras; 2) avaliar o desempenho dos mé-

todos empregados neste trabalho na discriminação entre patologias; e 3) analisar o uso de outras funções *Kernel* (na etapa de classificação) e filtros (na etapa de pré-processamento) para melhorar o desempenho das máquinas de vetor de suporte.

REFERÊNCIAS

ALMEIDA, N.C. **Sistema inteligente para diagnóstico de patologia na laringe utilizando Máquinas de Vetor de Suporte.**

Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, 2010.

BARANOSKI, F. L.; JUSTINO, E. J. R.; BORTOLOZZI, F. **Identificação da autoria em documentos manuscritos usando SVM.** *In: V ENIA, São Leopoldo-RS, p. 544-552, 2005.*

CAJUEIRO, D. O.; TABAK, B. M.; SOUZA, S. R. S. **Investigação da memória de longo prazo na taxa de câmbio do Brasil. Trabalhos para Discussão,** Banco Central do Brasil, Brasília, n. 113, ago. 2006.

COSTA, S. L. N. C. **Análise acústica, baseada no Modelo Linear de Produção da Fala, para discriminação de vozes patológicas.** Tese de Doutorado, Universidade Federal de Campina Grande, 2008.

ESPINOSA, C. H. M. F.; GOMEZ, V. P. **Diagnosis of vocal and voice disorders by the speech signal.** *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks, v. 4, pp. 253-258, 2000.*

FANTINATO, P. C. **Segmentação de voz baseada na análise fractal e na transformada wavelet** Dissertação de Mestrado, Instituto de Física de São Carlos da Universidade de São Paulo, 123 p., 2008.

FONSECA, E. S. **Wavelets, predição linear e LS-SVM aplicados na análise e classificação de sinais de vozes.** Tese de Doutorado, Escola de Engenharia de São Carlos da Universidade de São Paulo, 2008.

HIGUCHI, T., **Approach to an irregular time series on the basis of the fractal theory,** *Physics D., v. 31, pp. 277-283, 1988.*

HURST, E. **Long term storage capacity of reservoirs.** *Transactions of the American society of civil engineers, v. 116, p. 770-799, 1951.*

JUSTINO, E. J. R.; SABOURIN, R.; BOTOLOZZI, F. **An off-Line signature verification**

method based on SVM classifier and graphometric features. ICAPR, 2003.

KAY ELEMETRICS CORP. **Disordered voice database,** model 4337, 3. ed., 1994.

LIMA, J.S.; PALITÓ, T.T.C.; COSTA, S. C.; CORREIA, S. E. N. **Avaliação do potencial discriminativo do parâmetro de Hurst para o diagnóstico de vozes patológicas.** *In: 19º Simposio Internacional de Iniciação Científica da USP. São Carlos-SP, 2011a.*

LIMA, J.S.; PALITÓ, T.T.C.; COSTA, S. C.; CORREIA, S. E. N. **Avaliação estatística do uso do parâmetro de Hurst na discriminação entre vozes saudáveis e vozes patológicas.** *In: VI Congresso de Pesquisa e Inovação da Rede Norte e Nordeste de Educação Tecnológica. Natal-RN, 2011b.*

LORENA, A. C.; CARVALHO, A. C. P. F. **Investigação de estratégias para a geração de Máquinas de Vetores de Suporte multiclases.** Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo, 2008.

PALITÓ, T. T. C.; LIMA, J.S.; VILELA, S. G.; COSTA, S. C.; CORREIA, S. E. N. **O uso do parâmetro de Hurst no diagnóstico de patologias na laringe.** *In: 63ª Reunião Anual da SBPC. Goiania-GO, Jul. 2011.*

RODRIGUES, R. B.; VIANA, R.; PISTORI, H.; ALVAREZ, M. A. **Máquinas de Vetores de Suporte aplicadas à classificação de defeitos em couro bovino.** GPEC – Universidade Católica Dom Bosco, 2007.

SOARES, H. B. **Análise e Classificação de Imagens de lesões da pele por atributos de cor, forma e textura utilizando Máquina de Vetor de Suporte.** Tese de Doutorado. Departamento de Computação e Automação, Universidade Federal do Rio Grande do Norte, fev. 2008.

SOTERRONI, A. C.; DOMINGUES, M. O.; RAMOS, F. M. **Estimativa do expoente de Hurst de séries temporais caóticas por meio da transformada wavelet discreta.** *In: Brazilian Conference on Dynamics, Control and Applications, 2008.*

VAPNIK, V. **The nature of Statistical Learning Theory.** Nova York, Springer-Vaerlag, 1995.

VARELLA, C.A.A. **Estimativa da produtividade e do estresse nutricional da cultura do milho usando imagens digitais.** 2004. 92

f. Tese (Doutorado em Engenharia Agrícola) –
Universidade Federal de Viçosa, Viçosa, 2004.

YILMAZ, H. **IP over DVB: Management of
Self-similarity**. Bogazici University, 2002.