

Avaliação da Qualidade Vocal Através da Aplicação do Algoritmo Bio-inspirado em Colônia de Abelhas

A. S. de Sousa*, P. I. L. Ferreira*, V. J. D. Vieira**, S. C. Costa*, S. E. N. Correia*

*Instituto Federal da Paraíba, João Pessoa, PB, Brasil

**Universidade Federal de Campina Grande, Campina Grande, PB, Brasil

aldeni.sousa@ifpb.edu.br

Abstract – *In this research, binary artificial bee colony based feature selection employing K-NN classifier is used for vocal deviation detection. The aim is to determine which acoustic measures based on the recurrence quantification analysis are relevant for discrimination between healthy voices and voices with vocal deviations (breathiness, roughness and strain). In 96 tests performed, accuracy rates around 90% was obtained, with a reduction of 15 for seven features at least.*

Palavras-chave: *Análise acústica, seleção de características, algoritmo bio-inspirado, colônia artificial de abelhas.*

Introdução

Duas técnicas têm sido, comumente, empregadas para a avaliação da qualidade vocal: a análise perceptivo-auditiva e a análise acústica. A primeira é realizada pela escuta da voz, na qual um avaliador treinado quantifica o distúrbio por meio de escalas. A segunda utiliza técnicas de processamento de sinais para extrair características da fala que representem o distúrbio vocal presente na elocução.

A qualidade vocal é mensurada de acordo com a presença e o grau do desvio vocal presente no sinal de voz avaliado. Diversas pesquisas têm sido realizadas buscando definir quais características são mais eficientes na detecção dos distúrbios vocais [1-2]. Muitas vezes, mais de uma característica é empregada com o intuito de aumentar a precisão, entretanto nem sempre o aumento do número de características ocasiona um aumento na acurácia. Dessa forma, técnicas que selecionem as características mais relevantes, de forma a reduzir a dimensionalidade dos dados de forma eficiente, tornam-se bastante atrativas.

Algoritmos bio-inspirados, baseados em populações, vêm sendo usados para seleção de características em vários domínios de problemas, para os quais soluções robustas são difíceis ou impossíveis de serem encontradas, usando abordagens tradicionais. Dentre eles, Otimização

por Nuvens de Partículas (*Particle Swarm Optimization*) [3-5], Otimização por Colônia de Formigas (*Ant Colony Optimization*) [6-7], Busca de Cardumes de Peixes (*Fish School Search*) [6] e Colônia Artificial de Abelhas (*Artificial Bee Colony- ABC*) [8].

O ABC é um algoritmo de pesquisa estocástica, inspirado no comportamento de inteligência coletiva de um enxame de abelhas, durante sua busca por alimento [8]. Pesquisas anteriores indicam que o algoritmo ABC se mostra superior ou competitivo, se comparado às demais abordagens, obtendo resultados positivos nos mais diversos tipos de classificação de sinais [8-12].

Com o intuito de determinar quais as medidas acústicas baseadas na análise de quantificação de recorrência são relevantes para avaliação da qualidade vocal, no presente trabalho é empregada a seleção de características, baseada no método ABC binário, empregando o classificador K-NN. Três tipos de desvios vocais são considerados: rugosidade, sopro e tensão.

O texto do artigo está organizado da seguinte forma: na segunda seção são apresentadas as características extraídas dos sinais de voz. Em seguida, é realizada a descrição da base de dados e da metodologia empregada, os resultados obtidos, a discussão e as conclusões da pesquisa.

Extração das características do sinal de voz

Foram extraídas de cada sinal 15 características através do método de análise de Quantificação de Recorrência [3].

Os gráficos de recorrência são formados por uma matriz quadrada de ordem N , em que N é o número de vetores (estados do sistema) de dimensão m , preenchida por pontos brancos e pretos. O ponto preto, chamado de ponto recorrente, é colocado na matriz de recorrência com coordenadas i e j somente se a distância entre o estado $\vec{\xi}_i$ ao estado $\vec{\xi}_j$, ou seja, se a distância entre o estado corrente do sistema e o

estado a ser comparado for menor que o raio de vizinhança ε [2, 13].

Para a reconstrução do espaço de fases é necessário determinar o tempo de atraso ótimo ou passo de reconstrução τ . Takens [14] demonstrou que, com o uso da técnica dos tempos de retardo ou método das coordenadas defasadas, é possível reconstruir certas propriedades topológicas do espaço de estados (atrator) a partir da série temporal, $\{x_i\}$, em que vetores $\vec{\xi}_i$ m -dimensionais são reconstruídos, de acordo com a Equação 1.

$$\vec{\xi}_i = \{x(t_i), x(t_i + \tau), \dots, x(t_i + (m - 1)\tau)\}. \quad (1)$$

As medidas de quantificação de recorrência, por outro lado, fornecem uma avaliação quantitativa, possibilitando resultados de avaliação mais confiáveis. Foram utilizados o raio de vizinhança, o tempo de atraso ótimo e a dimensão de imersão, como parâmetros no sistema de classificação dos sinais, além das medidas de quantificação de recorrência descritas a seguir [2, 15].

- Determinismo (*Det*);
- Comprimento médio das linhas diagonais (*Lmed*);
- Comprimento máximo das linhas diagonais (*Lmax*);
- Entropia de Shannon (*Entr*);
- Laminaridade (*LAM*);
- Comprimento médio das estruturas verticais ou tempo de permanência (*Trapping Time - TT*);
- Comprimento máximo das estruturas verticais (*Vmax*);
- Tempo recorrência tipo 1 (*T1*);
- Tempo recorrência tipo 2 (*T2*);
- Entropia do tempo recorrência do tipo 1;
- Transitividade;
- Divergência.

Materiais e métodos

O fluxograma, apresentado na Figura 1, ilustra a metodologia empregada neste trabalho. Inicialmente, as medidas de quantificação de recorrência são extraídas dos sinais de voz. A versão binária do algoritmo ABC é empregada como seletor de características. Cada subconjunto de medidas gerado é avaliado através da classificação pelo método K-NN. Quando o critério de parada é atingido, as medidas que, em conjunto, fornecem melhor acurácia na classificação são determinadas.

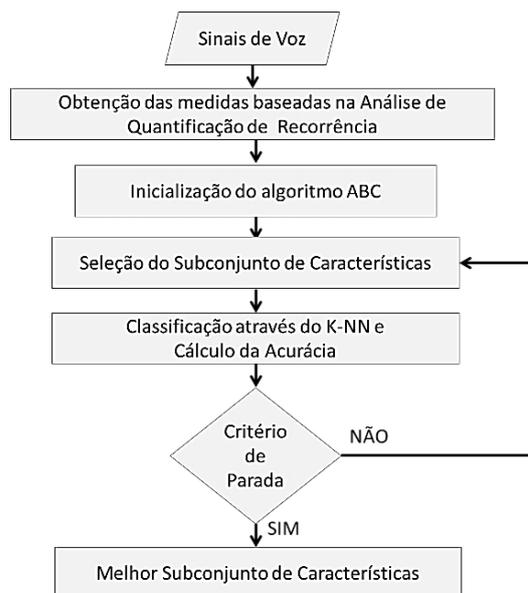


Figura 1. Fluxograma da metodologia empregada.

Base de Dados

Os sinais de voz empregados são provenientes da base de dados desenvolvida e disponibilizada pelo Laboratório Integrado de Estudos da Voz (LIEV) da Universidade Federal da Paraíba. A base faz parte de um projeto avaliado e aprovado pelo Comitê de Ética em Pesquisa do Centro de Ciências da Saúde/UFPB, com o parecer número 52492/12 [1].

Foram selecionados 120 sinais da base, sendo 30 de pacientes com vozes saudáveis e com 90 de pacientes com vozes desviadas, sendo 30 sinais de vozes com o desvio rugosidade, 30 com o desvio sopro e 30 com o desvio tensão.

Seleção de Características baseada no Algoritmo ABC

A seleção de características busca determinar o subconjunto ótimo, com S de características, que fornece a melhor acurácia no processo de classificação, a partir de um conjunto inicial F , em que $S \subset F$ [8]. Após a etapa de extração de características, os sinais de vozes são representados por um vetor contendo 15 medidas de quantificação de recorrência. O algoritmo ABC binário é utilizado para selecionar, dentre essas, as medidas mais relevantes na detecção de da qualidade vocal.

Um modelo básico do algoritmo ABC contém os seguintes componentes: fonte de alimento, abelha campeira, abelhas seguidoras e abelha escudeira. [12].

Na versão binária do algoritmo, as características são representadas pelas fontes de alimento e um espaço de busca discreto é considerado. Sendo assim, as possíveis soluções são representadas por um vetor binário de dimensão N , em que N representa o número total de características. Se o valor 1 for atribuído a uma posição do vetor, denota que a característica foi selecionada, caso contrário denota que a referida não foi selecionada para compor o subconjunto de características. As características selecionadas são classificadas pelo K-NN e avaliadas pelo valor da acurácia obtido [10-11].

O algoritmo ABC binário empregado, baseia-se no algoritmo proposto por Schiezero [8] e consiste das seguintes etapas:

1. Fase de inicialização: Criação das fontes de alimentos;
2. Fase da abelha campeira: Extração das características das fontes de alimentos e exploração de sua vizinha. Nesta etapa ocorre a adição ou não de novas características ao subconjunto em avaliação [16].
3. Fase da abelha seguidora: Cálculo da probabilidade de uma fonte de alimento ser explorada, de acordo com a Equação 2. Se uma abelha seguidora escolhe uma fonte para explorar, a abelha seguidora torna-se uma abelha campeira.
4. Fase da abelha escudeira: Verifica-se se existe fonte abandonada na fase da abelha seguidora e para cada fonte abandonada uma nova fonte de alimento será criada de forma aleatória.

$$p_i = \frac{acurácia_i}{\sum_{j=1}^N acurácia_j} \quad (2)$$

5. A melhor solução obtida até o momento é armazenada e o algoritmo é repetido sucessivamente, até que o critério de parada seja atingido.

Resultados experimentais

O ambiente de desenvolvimento é formado essencialmente pela linguagem de programação JAVA. Para a classificação dos dados foi usado o algoritmo IBk, que é uma implementação do classificador K-NN, na biblioteca Weka, cuja versão 3.9 foi empregada.

Os parâmetros de configuração do algoritmo ABC binário são: perturbação (responsável por ajustar a taxa de convergência do algoritmo), limite máximo (critério de parada que define uma maneira de impedir que a solução não fique presa a um máximo local) e número de iterações

(número de vezes que as iterações serão executadas pelo algoritmo). Neste trabalho foram utilizados os seguintes valores de parametrização: 0,1 para perturbação, 6 para limite máximo e 20 para o número de iterações.

Três casos de classificação foram considerados para a avaliação da qualidade vocal: Saudáveis (SDL) x Soprosos (SPR), Saudáveis x Rugosos (RUG) e Saudáveis x Tensos (TEN). A Tabela 1 mostra uma comparação, em termos de acurácia, entre resultados obtidos sem e com a utilização do algoritmo ABC.

Tabela 1. Comparação entre os resultados de classificação sem e com o algoritmo ABC

Casos de classificação	Acurácia (%)	
	Sem ABC	Com ABC
SDL x RUG	81,67	93,33
SDL x SPR	85,00	88,33
SDL x TEN	51,67	88,33

Na Tabela 2 é apresentado o número de características selecionadas pelo algoritmo ABC. Observa-se que com o uso do algoritmo ABC há uma redução da quantidade de características e um acréscimo no valor da acurácia.

Tabela 2. Número de características selecionadas pelo algoritmo ABC por caso de classificação

Casos de classificação	Número de características
SDL x RUG	5
SDL x SPR	4
SDL x TEN	7

O gráfico mostrado na Figura 2 apresenta a porcentagem de ocorrência das características em 96 testes realizados. Observa-se que as medidas do raio de vizinhança (ϵ) e o comprimento máximo das linhas diagonais ($Lmax$), respectivamente, não ocorrem em nenhum dos casos de classificação, podendo ser retiradas do vetor de características.

No caso da classificação SDLxRUG, as medidas dimensão de imersão (m), Determinismo e Entropia de Shannon ocorrem em mais de 60% dos testes. Na discriminação SDLxSPR, as medidas passo de reconstrução (τ) ocorre em mais de 80% dos testes e a medida (Trans) em quase 70% dos casos. Na distinção entre SDLxTEN as medidas dimensão de imersão, Determinismo e Entropia de Shannon foram as de maior ocorrência.

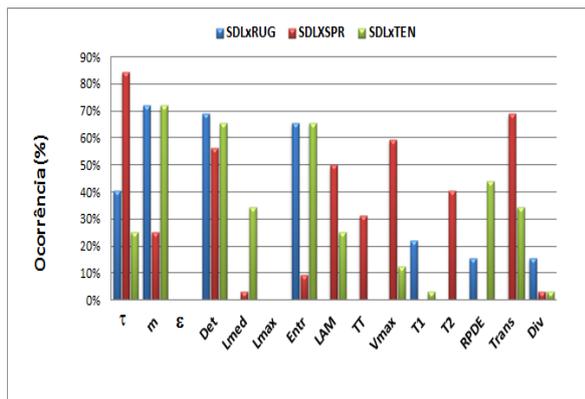


Figura 2. Número de ocorrência das medidas de recorrência.

Conclusões

Quinze medidas da análise de quantificação de recorrência, foram avaliadas através do método de seleção de características baseado no algoritmo ABC para otimizar o diagnóstico da qualidade vocal.

Houve uma redução no número de características utilizadas na classificação, entre quatro e sete, com taxas de acurácia superiores a 88%. Verificou-se que para avaliação da qualidade vocal as características: passo de reconstrução, Transitividade, dimensão de imersão, Determinismo e Entropia de Shannon são as mais relevantes.

Referências

- [1] Lopes, L. W., Vieira, V. J. D., Costa, S. L. N. C., Correia, S. E. N., Behlau, M.: Effectiveness of recurrence quantification measures in discriminating patients with and without voice disorders. In: 10th International Conference on Voice Physiology and Biomechanics; p. 14-17, Viña del Mar, Chile (2016).
- [2] Vieira, V. J. D.: Avaliação de Distúrbios da Voz por meio de Análise de Quantificação de Recorrência. Instituto Federal de Educação, Ciência e Tecnologia da Paraíba. Dissertação de mestrado (2014).
- [3] Souza, T. A., Souza, M. A., Costa, W. C. de A., Costa, S. C., Correia, S. E. N., Vieira, V. J. D.: Feature selection based on binary particle swarm optimization and neural networks for pathological voice detection. In: 2015 Latin America Congress on Computational Intelligence (LA-CCI) (2015).
- [4] Liu, Y., Wang, G., Chen, H., Dong, H., Zhu, X. and Wang, S.: An improved particle swarm optimization for feature selection. Journal of Bionic Engineering 8(2), 191-200 (2011).

- [5] Ding, S.: Spectral and wavelet-based feature selection with particle swarm optimization for hyperspectral classification. Journal of Software, 6(7), 1248-1256 (2011).
- [6] Seijas, L. M., Carneiro, R. F., Santana Jr., C. J., Soares, L. S. L., Bezerra, S. G. T. A., Bastos-Filho, C. J. A.: Metaheuristics for Feature Selection in Handwritten Digit Recognition. In: 2015 Latin America Congress on Computational Intelligence (LA-CCI) (2015).
- [7] Zhang, C. e Hu, H.: Ant Colony Optimization Combining with Mutual Information for Feature Selection in Support Vector Machines. In: 18th Australian Joint Conference on Artificial Intelligence, pp. 5-9 (2005).
- [8] Schiezarro, M.: Seleção de Características Baseada no Algoritmo de Colônia Artificial de Abelhas. Universidade Estadual de Campinas. Dissertação de Mestrado (2014).
- [9] Shanthi, S., Bhaskaran, V. M.: Modified Artificial Bee Colony Based Feature Selection: A New Method in the Application of Mammogram Image Classification. International Journal of Science, Engineering and Technology Research (IJSETR), 3(6), 1664-1667 (2014).
- [10] Palanisamy, S. e Kanmani, S.: Artificial Bee Colony Approach for Optimizing Feature Selection. International Journal of Computer Science Issues, 9(3), 432-438 (2012).
- [11] Subanya B, Rajalaxmi, R.R.: Artificial Bee Colony based Feature Selection for Effective Cardiovascular Disease Diagnosis. In: International Journal of Scientific & Engineering Research, 5(5), 606-612 (2014).
- [12] Rajamohana, S. P., Umamaheswari, K.: Feature Selection using Binary Artificial Bee Colony for Sentiment Classification. International Research Journal of Engineering and Technology, 3(12), 510-514 (2016).
- [13] Eckmann, J. P.; Kamphorst S. O.; Ruelle, D.: Recurrence plots of dynamical systems. Europhys Letters, 56(5), 973-977 (1987).
- [14] Takens, F.: Detecting strange attractors in turbulence, in Dynamical systems and turbulence. Proceedings of a Symposium Held at the University of Warwick pp. 366-381, Springer (1981).
- [15] Costa, W. C. de A.: Análise dinâmica não linear de sinais de voz para detecção de patologias laringeas. Universidade Federal de Campina Grande. Tese de Doutorado (2012).
- [16] Karaboga, D. e Akay, B.: A Modified Artificial Bee Colony Algorithm for Real Parameter Optimization. Information Sciences, 192:120-142 (2012).