

# Algoritmo Bio-inspirado em Colônia de Abelhas Aplicado na Seleção de Características para Detecção de Desvios Vocais

Aldeni S. de Sousa<sup>1</sup>[0000-0001-8430-2281], Paulo I. L. Ferreira<sup>1</sup>[0000-0001-8946-5872], Vinicius J. D. Vieira<sup>2</sup>[0000-0003-1072-1533], Silvana Cunha Costa<sup>1</sup>[0000-0002-1923-2018] e Suzete E. N. Correia<sup>1</sup>[0000-0002-7675-3979]

<sup>1</sup> Instituto Federal da Paraíba, João Pessoa, PB, Brasil

<sup>2</sup> Universidade Federal de Campina Grande, Campina Grande, PB, Brasil  
aldeni.sousa@ifpb.edu.br

**Abstract.** Feature selection is an important step used in several pattern recognition tasks to identify the significant features and discard irrelevant or redundant ones from the original set. In this research, a feature selection algorithm based on binary artificial bee colony with K-NN classifier is used for the discriminative analysis between healthy voices and voices with vocal deviations (breathiness, roughness and strain). The aim is to determine which acoustic measures based on the recurrence quantification analysis are relevant and contribute more in voice signals discrimination. In thirty two tests performed, 88.33% of accuracy was obtained with a reduction of fifteen for seven features in the discrimination between healthy and strained voices, four features and accuracy of 88.33% in the classification between healthy and breathiness and a reduction for five features, with an accuracy of 93.33%, in the discrimination between healthy and rough voices.

**Keywords:** Acoustic Analysis, Vocal Deviation, Feature Selection, Binary Artificial Bee Colony.

## 1 Introdução

Desvios vocais como rugosidade (rouquidão provocada pela irregularidade na vibração das pregas vocais), sopro (presença de ruído de fundo audível causada pela abertura entre as pregas vocais) e tensão (esforço vocal por aumento de adução glótica) são frequentemente monitorados por profissionais especialistas em voz para avaliar a qualidade vocal. Comumente, duas técnicas têm sido empregadas para a identificação da presença do distúrbio 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.

Diversas pesquisas têm sido realizadas, nos últimos anos, buscando definir quais características são mais eficientes em representar os distúrbios vocais quanto ao tipo e ao grau de intensidade [1-2]. A ideia é determinar um conjunto de características que contribua para um diagnóstico eficiente na detecção e monitoramento do desvio vocal, de forma eficiente e com baixo custo computacional.

A análise acústica baseada em dinâmica não linear da produção vocal tem se mostrado eficiente para avaliação de distúrbios de voz, uma vez que há várias não linearidades envolvidas na vibração das pregas vocais e na geração da onda [3]. Métodos clássicos de análise de dados baseados no modelo linear de produção da fala têm sido enriquecidos com novos métodos derivados da teoria dos sistemas dinâmicos não lineares [4], entre as quais a análise de quantificação de recorrência [5].

Na detecção de desvios vocais, as características têm sido utilizadas, tanto de forma individual quanto combinadas, no intuito de fornecer melhor desempenho. No entanto, uma grande quantidade de características nem sempre representa maior acurácia na classificação. Dessa forma, técnicas que selecionem as características mais relevantes, de forma a reduzir a dimensionalidade dos dados de forma eficiente, tornam-se bastante atrativas.

Utilizar métodos de seleção de características em aplicações que envolvam a discriminação entre sinais de voz saudáveis e com desvios vocais significa novas possibilidades de determinar o subconjunto de características que representa diferentes aspectos do sinal vocal e, portanto, pode caracterizar melhor a condição global do sinal [6].

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*) [7-10], Otimização de Colônia de Formigas (*Ant Colony Optimization*) [10-11], Busca de Cardumes de Peixes (*Fish School Search*) [10] e Colônia Artificial de Abelhas (*Artificial Bee Colony- ABC*) [12-16], tem se destacado.

O ABC é um algoritmo de pesquisa estocástica, inspirado no comportamento de inteligência coletiva de um enxame de abelhas, durante sua busca por alimento, proposto por Karaboga and Akay [10]. Possui conceito simples, de fácil implementação e com poucos parâmetros de controle. Pesquisas anteriores indicam que o algoritmo ABC se mostra superior ou competitivo, quando comparado às demais abordagens, obtendo resultados positivos nos mais diversos tipos de classificação de sinais [12-14].

Schiezaro [12] utiliza uma versão binária do algoritmo ABC para a seleção de características em diferentes tipos de dados, em que a adição de novas medidas ao subconjunto final é determinada por um parâmetro de perturbação proposto por Karaboga e Akay [17]. A acurácia obtida por um classificador K-NN (K - *Nearest Neighbor*) é usada como critério para determinar o subconjunto ótimo de características, com resultados promissores, quando comparado a outras abordagens da literatura.

Subanya *et al.* [15] propuseram um método para a seleção de características empregando o algoritmo ABC binário na detecção de patologias cardíacas. A acurácia do método é avaliada usando o classificador *Naive Bayesian*. Os resultados indicam que

o algoritmo proposto pode efetivamente classificar a doença com um número de características reduzidas.

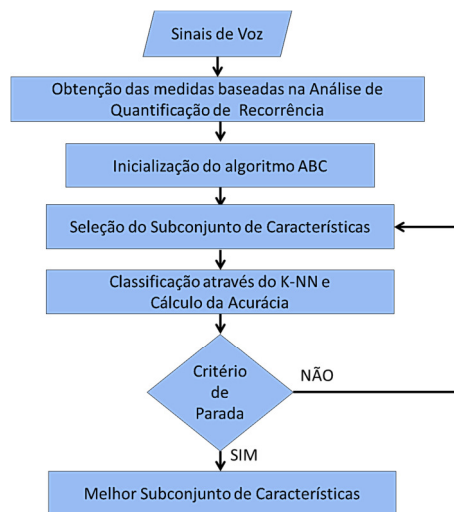
Rajamohana *et al.* [16] empregaram o algoritmo colônia artificial de abelhas binário em conjunto com K-NN para a seleção de características na classificação de sentimentos. Os resultados experimentais demonstraram que o método proposto seleciona características mais relevantes em comparação com os métodos competitivos.

Com o intuito de determinar quais as medidas acústicas baseadas na análise de quantificação de recorrência são relevantes para discriminar a presença do distúrbio vocal, no presente trabalho é empregada a seleção de características, baseada no método ABC binário, empregando o classificador K-NN. Tal escolha se deve ao fato do algoritmo ser de fácil entendimento e modelamento, além de possuir ampla aplicação.

O artigo está organizado da seguinte forma: na Seção 2 são apresentadas a descrição da base de dados e a metodologia empregada. Na Seção 3 são apresentados os resultados obtidos e discussão, seguida da Seção 4, em que são apresentadas as conclusões.

## 2 Materiais e Métodos

O fluxograma, apresentado na Fig. 1, ilustra a metodologia empregada neste trabalho. Inicialmente, as medidas de quantificação de recorrência são extraídas dos sinais de voz.



**Fig. 1.** Fluxograma da metodologia empregada.

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.

## 2.1 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 gravados dos pacientes, com idade entre 18 e 65 anos, sinais de vozes referentes à pronúncia da vogal sustentada /E/ (“é”), a uma taxa de amostragem de 44.100 amostras/s. Cada amostra foi quantizada com 16 bits. A coleta dos dados foi realizada em um ambiente tratado acusticamente.

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. Para cada sinal, foram extraídas 15 medidas de quantificação de recorrência, descritas a seguir.

## 2.2 Análise de Quantificação de Recorrência

Gráficos de Recorrência (*Recurrence Plots* – RPs) permitem uma análise bidimensional do comportamento de sistemas dinâmicos unidimensionais ou  $m$ -dimensional, utilizando uma ferramenta proposta por Eckmann *et al.* (1987), definido por [5]:

$$\mathcal{R}_{i,j}^{m,\varepsilon} = \Theta(\varepsilon - \|\vec{\xi}_i - \vec{\xi}_j\|), \quad \vec{\xi}_i \in \mathcal{R}^m, i, j = 1 \dots N, \quad (1)$$

em que:  $N$  é o número de estados  $\vec{\xi}_i$ ;  $\varepsilon$  é o raio vizinhança (*threshold*) no ponto  $\vec{\xi}_i$ ;  $\|\cdot\|$  é a norma da vizinhança, comumente a norma euclidiana;  $\Theta(\cdot)$  é a função de degrau unitário; e  $m$  é a dimensão de imersão (graus de liberdade do sistema).


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  $\varepsilon$  [2,18].

Para a reconstrução do espaço de fases é necessário determinar o tempo de atraso ótimo ou passo de reconstrução  $\tau$ . Takens [19] 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 2:

$$\vec{\xi}_i = \{x(t_i), x(t_i + \tau), \dots, x(t_i + (m-1)\tau)\}. \quad (2)$$

Na Fig. 2 são apresentados exemplos de gráficos de recorrência para sinais saudáveis e sinais que apresentam os desvios vocais rugosidade, sopro e tensão. A análise visual dos gráficos, pela composição das estruturas diagonais e verticais, pela

quantidade de pontos recorrentes, permite uma comparação subjetiva, qualitativa, que pode levar a diferentes conclusões, dependendo do avaliador. Por exemplo, processos com comportamentos estocásticos tendem a não apresentar estruturas diagonais. Por outro lado, processos determinísticos causam diagonais mais longas e menos pontos de recorrência isolados [20].



**Fig. 2.** Gráficos de recorrência para sinais (vogal sustentada /É/ (“é”)), classificados como: (a) saudáveis; e com os desvios (b) rugosidade; (c) soprosidade e (d) tensão.

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 [2,5,20].

- Determinismo (*Det*): mede a quantidade dos pontos de recorrência presentes na formação das linhas diagonais em relação a todo o conjunto dos pontos de recorrência, dado pela Equação 3:

$$Det = \frac{\sum_{l=lmin}^N l \cdot P^E(l)}{\sum_{ij} R_{i,j}^{m,\epsilon}} \quad (3)$$

- Comprimento médio das linhas diagonais (*Lmed*): Está relacionado ao tempo médio em que dois segmentos de uma trajetória estão próximos um do outro e pode ser interpretado como o tempo médio de predição, dado por:

$$Lmed = \frac{\sum_{l=lmin}^N l \cdot P^E(l)}{\sum_{ij} P^E(l)} \quad (4)$$

- Comprimento máximo das linhas diagonais (*Lmax*): Está relacionado à linha diagonal de maior comprimento presente no gráfico de recorrência:

$$Lmax = \max(\{li: i = 1 \dots Nl\}), \quad (5)$$

em que *li* refere-se às linhas diagonais e *Nl* o número de linhas diagonais.

- Entropia de Shannon (*Entr*): Refere-se à entropia de Shannon da distribuição de frequência dos comprimentos das linhas diagonais. Esta medida reflete a complexidade da estrutura determinística no sistema:

$$Entr = - \sum_{l=lmin}^N p(l) \cdot \ln p(l), \quad (6)$$

em que  $lmin$  é o comprimento mínimo das linhas diagonais,  $p(l)$  é a distribuição de frequência das linhas diagonais.

- Laminaridade ( $LAM$ )– é a relação entre os conjuntos de pontos de recorrência que formam as estruturas verticais e o número total de pontos recorrentes. Sendo  $v$  o comprimento das linhas verticais e  $P^\varepsilon(v)$  a distribuição das linhas verticais, tem-se que:

$$LAM = \frac{\sum_{v=vmin}^N v \times P^\varepsilon(v)}{\sum_{v=1}^N P^\varepsilon(v)}. \quad (7)$$

- Comprimento médio das estruturas verticais ou tempo de permanência (*Trapping Time - TT*) - Contém informações sobre a quantidade e o comprimento das estruturas verticais, observando o tempo médio em que o sistema permanece em um estado específico, dado por:

$$TT = \frac{\sum_{v=vmin}^N v \times P^\varepsilon(v)}{\sum_{v=vmin}^N P^\varepsilon(v)}. \quad (8)$$

em que  $P^\varepsilon(v)$  representa a distribuição de frequência das linhas verticais e  $vmin$  é o comprimento mínimo das linhas verticais.

- Comprimento máximo das estruturas verticais ( $Vmax$ ) - Esta medida mede o tempo máximo em que o sistema permanece em um estado específico, estando relacionada à duração máxima de um comportamento caótico, dada pela Equação 8.

$$Vmax = \max(\{Vl: i = 1 \dots Nv\}), \quad (9)$$

em que  $Nv$  é o número de linhas verticais e  $Vl$  o comprimento da linha vertical.

- Tempo recorrência tipo 1 ( $T^1$ ) - indica a distância entre um ponto recorrente e o ponto referência do raio de vizinhança.
- Tempo recorrência tipo 2 ( $T^2$ ) – é a distância entre o primeiro ponto recorrente e o ponto de referência do raio de vizinhança.
- Entropia do tempo recorrência do tipo 1 (RPDE- *Recurrence Probability Density Entropy*), definida matematicamente e medida por:

$$RPDE = \frac{\sum_{i=1}^{T^1max} P(i) \ln(P(i))}{\ln T^1max} \quad (10)$$

em que  $P(i)$  é a densidade de probabilidade do tempo de recorrência do tipo 1,  $T^1max$  é o tempo máximo de recorrência de tipo 1.

- Transitividade - é uma espécie de taxa de recorrência local, onde pode ser utilizada em conjunto com o raio vizinhança para a construção do gráfico de recorrência, dada por:

$$Trans = \frac{\sum_{i,j,k=1}^N R_{i,j}^{m,\varepsilon} R_{i,k}^{m,\varepsilon} R_{k,i}^{m,\varepsilon}}{\sum_{i,j,k=1}^N R_{i,j}^{m,\varepsilon} R_{k,i}^{m,\varepsilon}} \quad (11)$$

- Divergência - É o inverso de  $Lmax$ .

### 2.3 Seleção de Características baseada no Algoritmo ABC e Classificação

A seleção de características busca determinar o subconjunto ótimo, com um conjunto  $S$  de características, que fornece a melhor acurácia no processo de classificação, a partir de um conjunto inicial  $F$ , em que  $S \subset F$  [12]. 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 desvios vocais.

Um modelo básico do algoritmo ABC para descrever a busca e seleção das fontes de alimento das abelhas, necessário para simular uma inteligência coletiva da colmeia, contém os seguintes componentes essenciais: fonte de alimento, abelha campeira, abelhas seguidoras e abelha escudeira. As abelhas se movem ao redor do espaço de busca para encontrar as melhores soluções. O número de fontes de alimentos representa a posição das possíveis soluções do problema de otimização, enquanto a quantidade de néctar de uma fonte representa a qualidade (função objetivo) da solução associada [16].

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. Para a classificação dos desvios vocais, é empregado o classificador  $K$ - $NN$ , cujo desempenho é avaliado pelo valor máximo de acurácia obtido [15-16]. Foi empregada a técnica de validação cruzada com dez subconjuntos.

O algoritmo ABC binário empregado, representado na Fig. 3, baseia-se no proposto por Schiezero [12] e consiste das seguintes etapas:




Fig. 3. Diagrama representativo do Algoritmo ABC.

1. Inicialmente, são atribuídos valores para o número de abelhas campeiras, o número de abelhas seguidoras, o número máximo de iterações e o número pré-determinado de iterações (limite) para as abelhas escudeiras.

2. A população de fontes de alimentos (possíveis conjuntos de características) deve ser inicializada e atribuída às abelhas campeiras. A estratégia empregada consiste em criar fontes com subconjuntos com apenas uma única característica igual 1 e às demais zero. A população inicial deve ser avaliada pelo valor da acurácia obtida através da sua classificação pelo K-NN.
3. Abelhas campeiras: cada uma das fontes de alimento criada na fase de inicialização tem sua vizinhança explorada e um novo subconjunto de características é obtido considerando o parâmetro de perturbação MR (*Modification Rate*) ou *Perturbation Frequency* [21].
4. Atualização das abelhas campeiras: Caso a qualidade da fonte de alimento vizinha, recém-criada, seja melhor do que a fonte de alimento atual, então a fonte de alimento vizinha passa a ser considerada como possível solução do problema.
5. Abelhas seguidoras: analisam as informações de qualidade coletadas na fase da abelha campeira e decide quais são as melhores fontes a serem exploradas de acordo com a probabilidade:

$$p_i = \frac{acurácia_i}{\sum_{j=1}^N acurácia_j}, \quad (12)$$

em que *acurácia* representa a função objetivo (qualidade) da fonte de alimento em análise.

6. Abelhas seguidoras: uma nova solução é gerada e comparada com a qualidade de cada fonte de alimento. Caso a qualidade da nova fonte seja maior do que a qualidade da fonte de alimento existente, ela será explorada; caso o contrário, ela não será.
7. Abelhas Escudeiras: abandonam a fonte de alimento da abelha campeira se o valor da acurácia não é melhorado após um número pré-determinado de iterações (limite). Caso existam, novas fontes de alimento são criadas aleatoriamente para cada uma que foi abandonada. Essas novas fontes serão exploradas pelas abelhas escudeiras.
8. A melhor solução obtida até o momento é memorizada e o algoritmo é repetido sucessivamente, a partir do passo 3, até que o critério de parada seja atingido.

### 3 Resultados experimentais

O computador utilizado nos testes foi um Intel Core i7-4510U com 2.0 GHz, 16 GB de memória de acesso aleatório (RAM – *Random Access Memory*) e sistema operacional Windows versão 7. A implementação do método foi realizada em um ambiente de desenvolvimento 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 tiveram seus valores variados de acordo com a Tabela 1. São eles: 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). O número de fontes de alimentos é determinado pela quantidade de medidas da análise de recorrência empregadas.

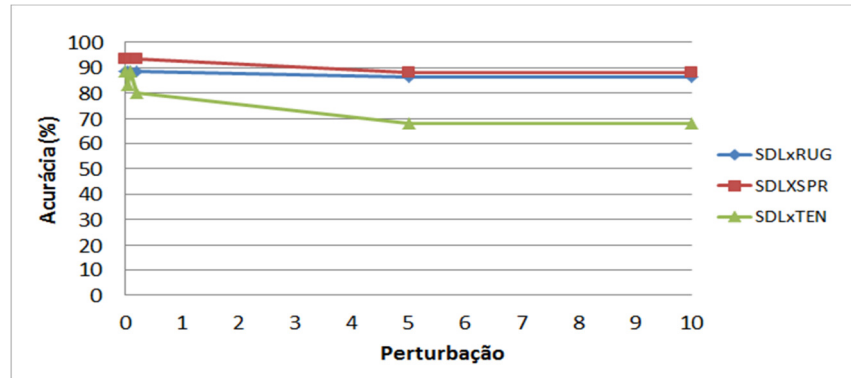
**Tabela 1.** Valores dos parâmetros do algoritmo ABC

Parâmetro	Valores
Quantidade das fontes de alimentos	15
Perturbação	0,005 - 10
Limite máximo	2 - 50
Número de iterações	2 - 100

Três casos de classificação foram considerados para a discriminação entre sinais de vozes saudáveis e com desvios vocais: Saudáveis (SDL) x Soprosos (SPR), Saudáveis x Rugosos (RUG) e Saudáveis x Tensos (TEN). Os gráficos das Fig. 4 e 5 ilustram os valores de acurácia em relação à variação dos parâmetros número de iterações e perturbação, respectivamente, para cada um dos tipos de classificação. Não houve variação significativa da acurácia ao se alterar o parâmetro limite máximo, podendo ser atribuído ao mesmo o valor mínimo adotado.



**Fig. 4.** Valores de Acurácia em função do número de Iterações.



**Fig. 5.** Valores de Acurácia de acordo com a variação do parâmetro perturbação.

Podem ser observados, na Fig. 4, que a melhor solução é encontrada em poucas iterações para os casos SDLxRUG e SDLxSPR. Para a discriminação SDLxTEN um número maior é requerido, o que pode ser justificado pela similaridade entre as duas classes [1]. Quanto ao parâmetro de perturbação, os valores menores que 0,1 conseguem fazer com que haja a convergência do algoritmo e que seja possível determinar a melhor taxa de acurácia, conforme ilustra a Fig. 5.

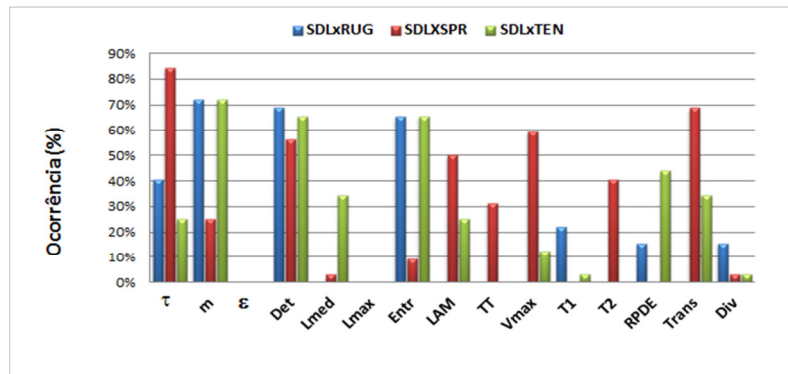
Na Tabela 2 é apresentada a relação entre a maior taxa de acurácia obtida com o menor número de características. O conjunto inicial, contendo 15 medidas, pode ser reduzido para a metade, com acurácia de no mínimo 88,33%.

**Tabela 2.** Relação entre a melhor acurácia e o menor número de características

Caso de classificação	Acurácia (%)	Quantidade de características
SDL x RUG	93,33	5
SDL x SPR	88,33	4
SDL x TEN	88,33	7

O gráfico da Fig. 6 apresenta a porcentagem de ocorrência das características em 32 testes realizados, ou seja, demonstra o quão importante cada posição do vetor (característica) é relevante para a discriminação dos sinais de voz entre saudáveis e desviados. Observa-se que as medidas do raio de vizinhança ( $\epsilon$ ) e o comprimento máximo das linhas diagonais ( $L_{max}$ ), 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 ( $\tau$ ) 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 (mais de 70%), Determinismo e Entropia de Shannon foram as de maior ocorrência. Observa-se pelo gráfico da Fig. 6 e pela Tabela 2, que na discriminação entre sinais saudáveis e tensos precisa-se de um número maior de medidas que os outros casos.



**Fig. 6.** Número de ocorrência das medidas de recorrência

Quando comparados os resultados, desta pesquisa, com os resultados obtidos por Lopes *et al* [1], observa-se que os valores de acurácia obtidos foram superiores. Lopes *et al.* [1], conseguiram atingir uma acurácia máxima de 83,27%, na discriminação entre vozes saudáveis e desviadas, considerando oito medidas de quantificação de recorrência e empregando no processo de classificação a análise discriminante quadrática.

## 4 Conclusões

Neste trabalho, quinze medidas da análise de quantificação de recorrência, foram avaliadas através do método de seleção de características baseado no algoritmo Colônia Artificial de Abelhas para otimizar o diagnóstico de desvios vocais. O algoritmo ABC, para os sinais analisados, teve uma rápida convergência e mostrou-se pouco sensível aos parâmetros de perturbação e limite máximo. Houve uma redução na quantidade de características utilizadas na classificação, de quinze para até sete, com taxas de acurácia superiores a 88%. O método se mostrou eficaz e capaz de indicar as características mais relevantes para a discriminação dos sinais de voz saudáveis dos sinais com os desvios de rugosidade, sopro e tensão.

## References

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. Rosa, M. de O.: Laringe Digital. Escola de Engenharia de São Carlos da Universidade de São Paulo. Tese de Doutorado (2002).

4. Jiang, J., Zhang, Y., McGilligan, C.: Chaos in voice, from modeling to measurement. *Journal of Voice* 20(1), 2–17 (2006).
5. Marwan, N.: Encounters With Neighbours - Current Developments of Concepts Based on Recurrence Plots and Their Applications. University of Potsdam, Ph.D. thesis (2003).
6. Al-nasheri A, Muhammad G, Alsulaiman M, Ali Z, Messalam TA, Farahat M et al.: An investigation of Multidimensional Voice Program Parameters in three diferente databases for voice pathology detection and classification. *Journal of Voice* 31(1), 113-118 (2017).
7. 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).
8. 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).
9. Ding, S.: Spectral and wavelet-based feature selection with particle swarm optimization for hyperspectral classification. *Journal of Software*, 6(7), 1248-1256 (2011).
10. 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).
11. 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).
12. Schiezero, M.: Seleção de Características Baseada no Algoritmo de Colônia Artificial de Abelhas. Universidade Estadual de Campinas. Dissertação de Mestrado (2014).
13. 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).
14. Palanisamy, S. e Kanmani, S: Artificial Bee Colony Approach for Optimizing Feature Selection. *International Journal of Computer Science Issues*, 9(3), 432-438 (2012).
15. 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).
16. 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).
17. Karaboga, D. e Akay, B.: A Survey: Algorithms Simulating Bee Swarm Intelligence. *Artificial Intelligence Review*, 31(1-4):61–85 (2009).
18. Eckmann, J. P.; Kamphorst S. O.; Ruelle, D.: Recurrence plots of dynamical systems. *Europhys Letters*, 56(5), 973–977 (1987).
19. 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).
20. Costa, W. C. de A.: Análise dinâmica não linear de sinais de voz para detecção de patologias laríngeas. Universidade Federal de Campina Grande. Tese de Doutorado (2012).
21. Karaboga, D. e Akay, B.: A Modified Artificial Bee Colony Algorithm for Real Parameter Optimization. *Information Sciences*, 192:120–142 (2012).