



INSTITUTO FEDERAL DA PARAÍBA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA - PPGEE

ALDENI SUDÁRIO DE SOUSA

**ALGORITMO BIOINSPIRADO EM COLÔNIA ARTIFICIAL DE ABELHAS
APLICADO NA SELEÇÃO DE CARACTERÍSTICAS PARA DETECÇÃO DE
DESVIOS VOCAIS**

João Pessoa-PB
2017

ALDENI SUDÁRIO DE SOUSA

**ALGORITMO BIOINSPIRADO EM COLÔNIA ARTIFICIAL DE ABELHAS
APLICADO NA SELEÇÃO DE CARACTERÍSTICAS PARA DETECÇÃO DE
DESVIOS VOCAIS**

Dissertação de Mestrado submetida à Coordenação do Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal da Paraíba como requisito necessário para obtenção do grau de Mestre em Ciências no Domínio da Engenharia Elétrica.

Área de Concentração: Processamento de Sinais.

Orientadora: Prof. Dra. Suzete Élide Nóbrega Correia
Coorientadora: Prof. Dra. Silvana Luciene do Nascimento Cunha Costa

João Pessoa, Paraíba, Brasil
Dezembro de 2017
© Aldeni Sudário de Sousa

Dados Internacionais de Catalogação na Publicação (CIP)
Biblioteca Nilo Peçanha do IFPB, *campus* João Pessoa

S725a Sousa, Aldeni Sudário de.

Algoritmo bioinspirado em colônia artificial de abelhas aplicado na seleção de características para detecção de desvios vocais / Aldeni Sudário de Sousa. – 2017.

67 p. : il.

Dissertação (Mestrado em Engenharia Elétrica) – Instituto Federal de Educação, Ciência e Tecnologia da Paraíba / Programa de Pós-Graduação em Engenharia Elétrica, 2017.

Orientação : Dra Suzete Élide Nóbrega Correia.

1. Processamento digital de sinais – sinais de voz. 2. Colônia artificial de abelhas – análise acústica. 3. Algoritmo bioinspirado. 4. Patologia de voz. 5. Análise de quantificação de recorrência. I. Título.

ALGORITMO BIOINSPIRADO EM COLÔNIA ARTIFICIAL
DE ABELHAS APLICADO NA SELEÇÃO DE
CARACTERÍSTICAS PARA DETECÇÃO DE DESVIOS
VOCAIS

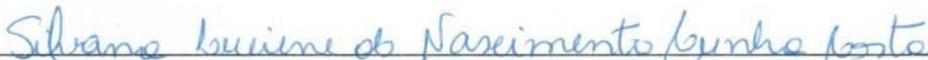
Dissertação de Mestrado submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal da Paraíba como requisito necessário à obtenção do grau de Mestre em Engenharia Elétrica.

Dissertação do Mestrado defendida e aprovada em 15 / 12 / 2017.

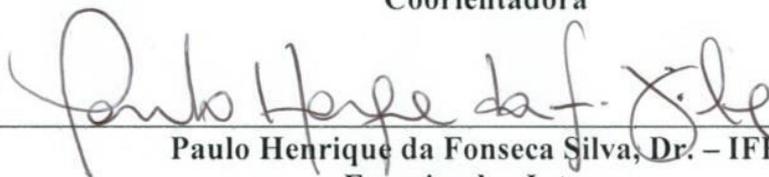
BANCA EXAMINADORA



Suzete Élide Nóbrega Correia, Dra. – IFPB
Orientadora



Silvana Luciene do Nascimento Cunha Costa, Dra. – IFPB
Coorientadora



Paulo Henrique da Fonseca Silva, Dr. – IFPB
Examinador Interno



Carlos Danilo Miranda Regis, Dr. – IFPB
Examinador Interno



José Josemar de Oliveira Júnior, Dr. – UFRN
Examinador Externo

À Antônia Batista, Paulo Ixtânio e Bento.

Agradecimentos

A Deus, por toda graça recebida, pelas oportunidades encontradas, pelos amigos e família a mim concedidos, pelo IFPB – berço dos meus sonhos;

Ao meu filho, Bento, por tornar meus dias mais leves, cheios de luz e beleza;

À minha mãe, Antônia Batista Neta, por todo amor, educação e exemplo de lutas e vitórias;

Ao meu Pai (*in memoriam*) pelo amor e carinho;

Ao meu esposo, Paulo Ixtânio Leite Ferreira, pelo companheirismo, amor, paciência, ajuda e compreensão;

À Professora Suzete Correia, minha orientadora, pela dedicação, ensinamentos e carinho;

À Professora Silvana Costa, minha coorientadora, pelos ensinamentos, conselhos e orientações;

Ao Professor Paulo Henrique, membro da banca, por partilhar seus conhecimentos e sugestões tão valiosas;

Ao Professor Carlos Danilo, membro da banca, por ter disponibilizado seu tempo e conhecimento;

Ao Professor José Josemar, membro da banca, por aceitar avaliar este trabalho, de forma a compartilhar os seus valiosos conhecimentos e acrescentar mais valor a esta pesquisa;

A todos os colegas do mestrado, pelo conhecimento compartilhado, pelas conversas e motivação. Em especial, a Anselmo, Kallyna, Pablo e Moisés;

Aos meus amigos e companheiros de trabalho do IFPB – João Pessoa, em especial à Cleidenédia, à equipe DOF, homenageados aqui em nome de Josué Bertulino e à equipe do NTI homenageados aqui em nome de Theohelber Campos;

A todos os familiares e amigos pelo carinho;

A todos os Professores do Colegiado do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) do IFPB;

Ao Instituto Federal da Paraíba pelas oportunidades.

*A voz do anjo sussurrou no meu ouvido
eu não duvido, já escuto os teus sinais
(Alceu Paiva Valença)*

Resumo

A seleção de características é uma etapa importante, empregada em várias tarefas de reconhecimento de padrões, para identificar os atributos mais significativos e descartar aqueles irrelevantes ou redundantes pertencentes a um conjunto original. Algoritmos bioinspirados, baseados no comportamento de organismos, são adequados para problemas de otimização e vêm sendo, recentemente, empregados para a seleção de características em vários domínios de problemas. Nesta pesquisa, a versão binária do algoritmo bioinspirado em colônia artificial de abelhas é aplicado na seleção de características para detecção de desvios vocais, com o intuito de determinar quais medidas acústicas baseadas na análise da quantificação de recorrência são relevantes para a discriminação entre vozes saudáveis e vozes com desvios vocais (soprosidade, rugosidade e tensão). Os resultados apontam que, de forma geral, houve uma redução na quantidade de características utilizadas na classificação, empregando-se o classificador K-NN, com taxas de acurácia superiores a 86%, apresentando competitividade quando comparados com outras abordagens.

Palavras-Chave: Análise Acústica, Seleção de Características, Algoritmos bioinspirados, Colônia Artificial de Abelhas, Análise de Quantificação de Recorrência.

Abstract

Feature selection is an important step, used in various pattern recognition tasks, to identify the most significant attributes and discard irrelevant or redundant ones belonging to an original set. Bio-inspired algorithms, based on the behavior of organisms, are suitable for optimization problems and have recently been used to select characteristics in several problem domains. In this research, the binary version of the artificial bee-colony bio-inspired algorithm is applied in the selection of characteristics to detect vocal deviations, in order to determine which acoustic measures based on the recurrence quantification analysis are relevant for the discrimination between normal voices and voices with vocal deviations (breathiness, roughness and tension). The obtained results indicate that, in general, there was a reduction in the number of characteristics used in the classification, using the K-NN classifier, with accuracy rates above 86%, presenting competitiveness when compared with other approaches.

Key-Words: Acoustic Analysis, Feature Selection, Bio-inspired algorithms, Artificial Bee Colony, Quantification Recurrence Analysis.

Lista de Figuras

Figura 1 – Fluxograma do algoritmo ABC.....	26
Figura 2 - Processo de inicialização.	30
Figura 3 – Vetores e seus valores iniciais.....	31
Figura 4 - Processo executado pela abelha campeira.	31
Figura 5 - Exploração e criação das fontes de alimentos (vizinhas)	32
Figura 6 - Processo executado pela abelha seguidora.	32
Figura 7 - Processo executado pela abelha escudeira.....	33
Figura 8 - Fluxograma da metodologia empregada.	34
Figura 9 - Gráficos de recorrência para sinais (vogal sustentada / \mathcal{E} / (“é”)), classificados como: (a) saudáveis; (b) com rugosidade; (c) com soprosidade; (d) com tensão.....	36
Figura 10 - Representação das fontes de alimento (inicialização).	41
Figura 11 - Acurácia em termos do Parâmetro Iteração	47
Figura 12 - Número de características selecionadas em termos de Iterações.....	47
Figura 13 - Acurácia em termos do Parâmetro Limite Máximo.....	48
Figura 14- Número de Características em termos do Parâmetro Limite Máximo.....	49
Figura 15 - Acurácia x Parâmetro de Perturbação.....	50
Figura 16 - Número de Características x Parâmetro de Perturbação.....	51
Figura 17 - Incidência das características.....	53
Figura 18 - Gráficos <i>Boxplot</i> das características individuais.	55

Lista de Tabelas e Quadros

Quadro I - Resumo do estado da arte	21
Tabela 1 - Representação dos vetores de características (fonte de alimento) inicial.	40
Tabela 2 - Comparação entre os classificadores avaliados.....	45
Tabela 3 - Valores dos parâmetros do algoritmo ABC.	46
Tabela 4 - Comparação entre os resultados de classificação sem e com o algoritmo ABC.....	57
Tabela 5 - Comparação entre os classificadores KNN e SVM.....	57
Tabela 6 - Classe de sinais SDLxSPR- Comparação com Souza (2017).....	58
Tabela 7 - Classe de sinais SDLxRUG - Comparação com Souza (2017).....	58
Tabela 8 - Classe de sinais SDLxTEN - Comparação com Souza (2017).	59
Tabela 9 - Sinais saudáveis x Sinal com Patologia – Comparação com Lopes <i>et al.</i> (2016).....	59

Lista de Siglas

ABC - Artificial Bee Colony

ACO - Ant Colony Optimization

AG – Algoritmo Genético

ANNIGMA – Artificial Neural Net Input Gain Measurement Approximation

CRP - Cross Recurrence Plot

FS - Feature Selection

FURIA – Fuzzy Unordered Rule Induction Algorithm

GP - Genetic Programming

IDE – Inverse Document Frequency

IDS – Intrusion Detection System

IMDb – Internet Movie Database

K-NN - K-Nearest Neighbor

LIEV - Laboratório Integrado de Estudos da Voz

MLP – Multilayered Perceptron

MLPFS – Multi-Layered Perceptron Based Feature Selection

MQR's - Medidas de Quantificação de Recorrência

NBPSO - New Binary Particle Swarm Optimization

PCA - Principal Component Analysis

PSO - Particle Swarm Optimization

RAM – Random Access Memory

RIDOR - Ripple Down Rule Learner

SVM - Support Vector Machine

UCI - Universidade da Califórnia, Irvine

UFPB – Universidade Federal da Paraíba

Lista de Símbolos

x_{ij} - Fontes de alimento aleatórias

v_{ij} - vizinhança de uma fonte de alimento

f_i - Função de custo da função

p_i - Probabilidade de uma abelha seguidora escolher uma fonte de alimento

P – Instâncias com rótulos marcados como verdadeiros

F - Instâncias com rótulos marcados como falso

τ - Passo de reconstrução

m - Dimensão de imersão

ε - Raio de vizinhança

L_{med} - Comprimento médio das linhas diagonais

L_{max} - Comprimento máximo das linhas diagonais

V_{max} - Comprimento máximo das estruturas verticais

T^1 - Tempo de recorrência do tipo 1

T^2 - Tempo de recorrência do tipo 2

$\vec{\xi}_i$ - Vetores m -dimensionais de uma série temporal (estados de um sistema)

$\mathbb{R}_{i,j}^{m,\varepsilon}$ - Definição para gráfico de recorrência

\mathbb{R}^m - Espaço m -dimensional

$\Theta(\cdot)$ - Função degrau unitário

ε - Símbolo fonético da vogal “e”

$P_{\varepsilon}(l)$ - Distribuição de frequência dos comprimentos das estruturas diagonais no gráfico de recorrência

$P_{\varepsilon}(v)$ - Distribuição de frequência dos comprimentos das estruturas verticais no gráfico de recorrência

$P(l)$ - Distribuição de probabilidade

v - Comprimento das estruturas verticais no gráfico de recorrência

N_v - Número de linhas verticais no gráfico de recorrência

$P(i)$ - Densidade de probabilidade do tempo de recorrência do tipo 1

T^1_{max} - Tempo máximo de recorrência do tipo 1

Sumário

Capítulo I – Introdução.....	15
1.1 Estado da Arte.....	17
1.2 Objetivo Geral.....	20
1.3 Objetivos Específicos.....	20
1.4 Organização do Documento.....	22
Capítulo II – Fundamentação Teórica	23
2.1 Dimensionalidade dos Vetores de Características	23
2.2 Seleção de Características.....	24
2.3 Algoritmo ABC.....	25
2.4 Algoritmo ABC Binário.....	28
Capítulo III – Materiais e Métodos.....	34
3.1 Base de Dados.....	35
3.2 Extração de Características	35
3.3 Seleção de Características Empregando o Algoritmo ABC	40
3.4 Classificadores	41
3.4.1 K-NN.....	42
3.4.2 <i>Naïve Bayes</i>	42
3.4.3 <i>Support Vector Machine</i>	42
3.4.4 <i>Multilayer Perceptron (MLP)</i>	43
IV Resultados	44
4.1 Avaliação dos Classificadores	44
4.2 Parâmetros de Configuração do Algoritmo ABC	45
4.2.1 Iteração	46
4.2.2 Limite Máximo.....	48
4.2.3 Parâmetro de Perturbação.....	50

4.3 Avaliação das Características	52
4.4 Análises Estatísticas das Características	53
4.5 Comparação com outros Métodos	57
V Conclusões.....	60
5.1 Contribuições da Pesquisa	62
Referências	63

Capítulo I – Introdução

A fala é considerada o principal meio de comunicação entre humanos. Ela carrega consigo informações físicas, psicológicas e sociais que caracterizam cada indivíduo como único na sociedade, além de demonstrar o estado emocional e de humor do falante (VIEIRA, 2014; BRANDI, 2002). Dentre os problemas que podem acometer a voz, os desvios vocais são os mais estudados e podem acometer os seres humanos independentemente da idade, inclusive acompanhando-o desde a fase da infância (VIEIRA, 2014).

Desvios vocais como rugosidade (rouquidão provocada pela irregularidade na vibração das pregas vocais), soprosidade (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 em conjunto, com objetivo de obter um diagnóstico mais eficaz e preciso na identificação da presença do distúrbio vocal: a análise perceptivo-auditiva e a análise acústica.

Na análise perceptivo-auditiva, a qualidade vocal é avaliada de forma subjetiva por profissionais treinados (fonoaudiólogos) que ouvem e selecionam as características presentes no sinal de voz com o intuito de identificar se há ou não alterações na fala. A análise acústica, de caráter objetivo, emprega técnicas de processamento digital de sinais para extração de características do sinal de voz, obtendo medidas representativas, tanto no domínio do tempo quanto da frequência, permitindo a avaliação da qualidade vocal presente na elocução (COSTA, ASSIS, *et al.*, 2013).

Diversas pesquisas têm sido realizadas, nos últimos anos, buscando definir quais características são mais significativas em representar os distúrbios vocais quanto ao tipo e ao grau de intensidade (LOPES, COSTA, *et al.*, 2016; VIEIRA, 2014). A ideia é determinar um conjunto de características que contribua para um diagnóstico eficaz na detecção e monitoramento do desvio vocal, de forma eficiente e com baixo custo de treinamento.

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 (ROSA, 2002). 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 (JIANG, 2006), entre as quais a análise de quantificação de recorrência (MARWAN, 2003).

Na detecção de desvios vocais, as características dos sinais de voz 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 represente diferentes aspectos do sinal vocal e, portanto, pode caracterizar melhor a condição global do sinal (AL-NASHERI, MURAMMAD, *et al.*, 2017).

A seleção de características, de forma geral, pode ser descrita em quatro etapas: geração e avaliação de subconjuntos, critério de parada e validação de resultados. O objetivo do processo é determinar o subconjunto mais representativo do conjunto geral de atributos, sem o comprometimento da precisão de representação. Essas aplicações vêm sendo estudadas e aperfeiçoadas com a utilização de metodologias baseadas em algoritmos de computação evolutiva.

A computação evolutiva trabalha com soluções locais para evoluir os indivíduos pertencentes à população com o objetivo de sempre fornecer melhores soluções. A evolução dos indivíduos ocorre de acordo com regras que são baseadas na troca de informações entre os componentes do grupo. Dentre os algoritmos evolutivos destacam-se: Algoritmos Genéticos (*Genetic Algorithm* - GA), Programação Evolutiva (*Evolutionary Programming* - EP), Algoritmos de Estratégia Evolutiva (*Evolution Strategy* - EE), Algoritmos de Estimação de Distribuição (*Estimation of Distribution Algorithm* - EDA), Programação Genética (*Genetic Programming* - GP) e outros algoritmos bioinspirados (COELHO, S. e COELHO, R., 1999).

Os algoritmos bioinspirados vêm sendo usados para seleção de características em diversas áreas de conhecimento, para as quais soluções robustas são difíceis ou impossíveis de serem encontradas por meio de abordagens tradicionais. Dentre eles, se destacam: a Otimização por Enxame de Partículas (*Particle Swarm Optimization* - PSO), (SOUZA, SOUZA, *et al.*, 2015; DING, 2011 e LIU, WANG, *et al.*, 2011); a Otimização por Colônia de Formigas (*Ant Colony Optimization* - ACO) (SEIJAS,

CARNEIRO, *et al.*, 2015; ZHANG e HU, 2005); a Busca por Cardumes de Peixes (*Fish School Search - FSS*) (SEIJAS, CARNEIRO, *et al.*, 2015) e a Colônia Artificial de Abelhas (*Artificial Bee Colony - ABC*) (SCHIEZARO, 2014; SHANTHI e BHASHARAM, 2014; PALANISAMY e KANMANI, 2012; RAJAMOHANA e MAHESWARI, 2016; B. e RAJALAXMI, 2014).

O ABC é um algoritmo de pesquisa estocástica, inspirado no comportamento de inteligência coletiva de enxame de abelhas durante a busca por alimento. Pesquisas anteriores indicam que o algoritmo ABC se mostra superior ou competitivo, em termos de acurácia e número de características selecionadas, quando comparado às demais abordagens na classificação de características de sinais (SCHIEZARO, 2014; SHANTHI e BHASHARAM, 2014; PALANISAMY e KANMANI, 2012).

Com o intuito de determinar quais medidas acústicas baseadas na análise de quantificação de recorrência são relevantes para discriminar a presença do distúrbio vocal, no presente trabalho é empregada à seleção de características, baseada na versão binária do algoritmo ABC, de acordo com o trabalho de Schiezaró (2014). Passo de reconstrução escolha se deve ao fato do algoritmo ser de fácil entendimento e modelamento, além de possuir ampla aplicação. Três tipos de desvios vocais são considerados: rugosidade, sopro e tensão.

1.1 Estado da Arte

Vários trabalhos têm sido desenvolvidos para a discriminação entre sinais de voz saudáveis e desviados.

Na dissertação de mestrado de Pinho (2017) foram empregadas técnicas de processamento digital de sinais baseadas na análise dinâmica não linear para analisar alterações vocais causadas por patologias laríngeas e desvios vocais. No referido trabalho foi utilizado o classificador MLP (*Multilayer Perceptron*) em conjunto com quatro métodos de extração de características: o método da contagem de caixas, o método da diferença, o método da similaridade e o método da contagem de caixas ponderadas. Os métodos da contagem de caixas ponderadas e da similaridade proporcionaram os melhores resultados, tanto com medidas individuais como também combinadas, com taxas de acurácia de 99% na classificação de vozes patológicas.

Na pesquisa de Queiroz (2017) foram empregadas medidas não lineares, baseadas na teoria do caos em conjunto com medidas de quantificação de recorrência para a análise discriminativa de desvios vocais. Por meio de testes estatísticos, foi

avaliado o potencial de cada característica em discriminar entre sinais de vozes saudáveis e sinais com desvios vocais (rugosidade, sopro e tensão). A pesquisa utilizou a rede neural MLP com o algoritmo de aprendizado supervisionado Gradiente Conjugado Escalonado no processo de classificação. Utilizando as medidas, de forma individual e combinada, foram obtidas taxas de acurácia entre de 91,17% e 94,5%, na discriminação dos desvios vocais.

Souza (2017), em seu trabalho de conclusão de curso, utiliza três algoritmos variantes do PSO: *New Binary PSO*, *Vector Evaluated PSO* e *Multiobjective PSO* para seleção de características. A referida pesquisa emprega características extraídas de sinais de vozes saudáveis e com desvios vocais. Os sinais foram divididos em quatro classes (saudáveis, tensos, rugosos e soprosos) e as simulações de otimização foram realizadas utilizando 18 medidas provenientes da Análise de Quantificação de Recorrência sobre os sinais de voz. Os resultados obtidos apresentam taxas de até $95 \pm 2,5\%$ na acurácia e 100% de sensibilidade com redução de até 72,3% no número de características utilizadas.

Em Lopes *et al.* (2017), são utilizadas técnicas de processamento de sinais de voz baseadas em modelos não lineares e a utilização de classificadores com medidas acústicas isoladas e combinadas. O objetivo é a obtenção de uma combinação linear das características observadas que apresente maior potencial de discriminação. Os resultados demonstram taxas de acurácia máxima de 83,27% e comprovam que as medidas de recorrência, isoladas ou combinadas, apresentaram bom desempenho na classificação.

Dentre os algoritmos bioinspirados, o uso do algoritmo ABC para seleção de características, surge na literatura como solução para aplicações de diversas naturezas, como mineração de dados e aplicações médicas. Entretanto, não foi possível a identificação do uso do algoritmo ABC para aplicações voltadas à seleção de características em sinais de voz, especificamente sinais de voz com desvios e/ou afetados por patologias laríngeas.

Schiezaro (2014) utiliza uma versão binária do algoritmo ABC para a seleção de características em diferentes tipos de dados médicos, em que a adição de novas medidas ao subconjunto final é determinada por um parâmetro de perturbação proposto por Karaboga e Akay (2009). A acurácia obtida por um classificador K-NN é usada como critério para determinar o subconjunto ótimo de características, com resultados promissores, quando comparado a outras abordagens da literatura como PSO.

Subanya e Rajalaxmi (2014) propuseram um método para a seleção de características empregando o algoritmo ABC binário na seleção de características para auxiliar 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 presença de patologias com um número de características reduzidas.

Rajamohana e Maheswari (2016) empregaram o algoritmo colônia artificial de abelhas binário em conjunto com K-NN para a seleção de características na classificação de satisfação de consumidores. Os resultados experimentais mostraram que o método proposto seleciona características mais relevantes em comparação com o algoritmo PSO.

Forsati *et al.* (2012) propuseram a otimização do algoritmo ABC, para a seleção de características em sinais médicos extraídos a partir da íris, coração, mama, voz, entre outros. A comparação dos resultados foi feita com outros algoritmos bioinspirados, tais como: os baseados em colônia de formiga, FS (*Feature Selection*) baseado no método MLP (MLPFS - *Multilayered Perceptron Based Feature Selection*) e ANNIGMA (*Artificial Neural Net Input Gain Measurement Approximation*), algoritmo híbrido e genético para FS (HGAFS - *Hybrid Genetic Algorithm for FS*). Neste trabalho, percebeu-se que para a seleção de características, a melhor abordagem em termos de acurácia e número de características selecionadas é a aplicação do algoritmo baseado em colônia de abelhas.

Sumathi *et al.* (2014), empregaram o algoritmo ABC para seleção de características em mineração de dados. Os resultados do método proposto foram comparados com a técnica conhecida como IDE (*Inverse Document Frequency*). Uma medida estatística que tem o intuito de indicar a importância de uma palavra de um documento em relação a uma coleção de documentos ou em um conjunto linguístico. A referida pesquisa fez uso dos algoritmos classificadores: *Naive Bayes*, RIDOR (*Ripple Down Rule Learner*) e FURIA (*Fuzzy Unordered Rule Induction Algorithm*). A pesquisa usou a base de dados IMDb (*Internet Movie Database*). Os resultados experimentais mostraram que a acurácia dos métodos classificadores apresenta uma melhoria que varia entre 1,63% e 3,81% quando o ABC é utilizado. A seleção de características com ABC melhora a acurácia entre 1,3% a 3,99%.

Palanisamy e Kanmani (2012a) propuseram a utilização de um algoritmo híbrido ABCE, composto pela combinação do algoritmo ABC, conjunto classificador (CE),

Support Vector Machine (SVM), *Árvore de Decisão* e método *Naive Bayes*, para aumentar a acurácia na tarefa de classificação. Os dados utilizados como referência para avaliação do algoritmo foram obtidos da base de dados da UCI (Universidade da Califórnia, Irvine), compostos por 10 tipos diferentes de dados médicos, como: coração, dermatologia, hepatite, câncer de pulmão, diabetes, íris, câncer de mama. Os resultados apontaram um aumento de até 12% na precisão da classificação em comparação a outros métodos baseados no algoritmo ACO.

Palanisamy e Kanmani (2012b), em outro trabalho, apresentaram um novo método de seleção de características que usa o algoritmo ABC para reduzir a dimensionalidade de sinais médicos. O algoritmo proposto foi implementado e testado usando-se 10 conjuntos de dados de campos da medicina. Os conjuntos de dados são da UCI, repositório de dados Irvine. Os resultados experimentais mostraram que a aplicação do algoritmo resultou em um tamanho do subconjunto de características reduzido, com acurácia de classificação superior às aborgagens que utilizam o algoritmo ACO.

Na Tabela 1 é apresentado o resumo do estado da arte, aplicado na pesquisa, apresentando também trabalhos que tiveram como base o uso do algoritmo ABC.

1.2 Objetivo Geral

Aplicar o algoritmo bioinspirado em colônia artificial de abelhas na seleção de características para detecção de desvios vocais.

1.3 Objetivos Específicos

- Realizar estudo teórico sobre o algoritmo ABC e como o mesmo pode ser empregado na seleção de características;
- Implementar e/ou otimizar o algoritmo baseado no comportamento das abelhas para seleção de características em sinais de voz;
- Avaliar o potencial discriminativo das medidas baseadas na análise de quantificação de recorrência através da incidência das características selecionadas;
- Avaliar e comparar com outras técnicas, o desempenho do sistema de classificação implementado.

Quadro I - Resumo do estado da arte.

Autoria	Metodologia	Resultados e Conclusão
PINHO (2017)	<ul style="list-style-type: none"> • Análise dinâmica não linear; • Classificador MLP; • Método da contagem de caixas; • Método da diferença; • Método da similaridade; • Método da contagem de caixas ponderadas. 	<ul style="list-style-type: none"> • O melhor desempenho: métodos da contagem de caixas ponderadas e da similaridade; • Acurácia de 99% na classificação.
QUEIROZ (2017)	<ul style="list-style-type: none"> • Testes estatísticos; • Rede neural MLP; • Algoritmo de aprendizado supervisionado Gradiente Conjugado Escalonado. 	<ul style="list-style-type: none"> • Taxa de acurácia entre 91,17% e 94,5%.
SOUZA (2017)	<ul style="list-style-type: none"> • Algoritmos variantes do PSO: <i>New Binary PSO</i>, <i>Vector Evaluated PSO</i> e <i>Multiobjective PSO</i>. 	<ul style="list-style-type: none"> • Taxas de até $95 \pm 2,5\%$ na acurácia.
LOPES (2017)	<ul style="list-style-type: none"> • Classificadores com medidas acústicas isoladas e combinadas. 	<ul style="list-style-type: none"> • Taxas de acurácia máxima de 83,27%
FORSATI (2012)	<ul style="list-style-type: none"> • Uso do algoritmo ABC binário; • Sinais médicos: Íris, coração, mama, etc. 	<ul style="list-style-type: none"> • Comparação com: ACO, MLP e ANNIGMA, algoritmo híbrido e AG; • Resultado: ABC superior.
PALANISAMY (2012)	<ul style="list-style-type: none"> • Uso do algoritmo ABC binário; • Problemas computacionais de grau elevado. 	<ul style="list-style-type: none"> • Comparação com ACO; • Resultado: subconjunto de característica reduzido com precisão de classificação melhorada em até 12%;
SUMATHI (2014)	<ul style="list-style-type: none"> • Utiliza uma versão ABC binária; • Aplicado à mineração de dados; • Classificadores: <i>Naive Bayes</i>, RIDOR e FURIA. 	<ul style="list-style-type: none"> • Comparação com IDF; • Resultados: melhoria entre 1,63% e 3,81% com ABC.
SCHIEZARO (2014)	<ul style="list-style-type: none"> • Utiliza uma versão ABC binária; • Diferentes tipos de dados, entre as quais dados biomédicos; • Classificador K-NN. 	<ul style="list-style-type: none"> • Comparação com: PSO, ACO; • Resultados: Acurácia igual ou superior ao ABC.
SUBANYA (2014)	<ul style="list-style-type: none"> • Uso do algoritmo ABC binário; • Detecção de patologias cardíacas; • Classificador <i>Naive Bayesian</i>. 	<ul style="list-style-type: none"> • Resultados: Classificação efetiva da doença com um número de características reduzidas.
RAJAMOHANA (2016)	<ul style="list-style-type: none"> • Algoritmo ABC binário; • Classificação de satisfação de consumidores como positivos ou negativos; • Classificador K-NN. 	<ul style="list-style-type: none"> • Comparação com: PSO e ABC Original; • Resultado: maior precisão de classificação e redução de complexidade.

Fonte: Autoria própria

1.4 Organização do Documento

Este documento está organizado da seguinte forma: o Capítulo I trata da introdução, estado da arte e objetivos da pesquisa. O Capítulo II é composto pela fundamentação teórica. No Capítulo III refere-se aos materiais e métodos empregados na pesquisa. O Capítulo IV contém os resultados obtidos e, finalmente, no Capítulo V, são apresentadas as conclusões da pesquisa.

Capítulo II – Fundamentação Teórica

Neste capítulo é apresentada a fundamentação teórica das técnicas e abordagens que são objeto de estudo desta pesquisa, como: dimensionalidade dos vetores de características, seleção de características, o algoritmo ABC e o algoritmo ABC binário.

2.1 Dimensionalidade dos Vetores de Características

Um vetor de características é uma representação mais compacta de um dado sinal. Essa representação geralmente é utilizada no processo de análise e processamento do sinal. A dimensionalidade ou tamanho de um vetor de característica é medida pela quantidade de atributos que o referido vetor possui.

A redução da dimensionalidade do vetor de características do sinal auxilia na simplificação do modelo dos dados e facilita o melhor entendimento de sua natureza, aumenta a eficiência em termos de espaço de armazenamento e de tempo de execução no processo de classificação.

Seja um dado conjunto de soluções de vetores de características que representam um sinal em um espaço de conhecimento, o processo de busca por um subconjunto, pertencente ao original e que seja composto apenas pelas características mais relevantes na representação do dado sinal é o que se conhece por redução de dimensionalidade.

A dimensionalidade elevada pode aumentar consideravelmente a complexidade computacional. A solução para o problema exposto pode ser encontrada nas técnicas de seleção de características que buscam como resultado um subconjunto composto apenas por medidas significativas em que as características redundantes, irrelevantes e ruidosas, presentes no conjunto original, são excluídas.

Os métodos de redução de dimensionalidade podem ser divididos em:

- Métodos de transformação de características – são aqueles que alteram o conjunto original de características resultando na formação de um novo conjunto. A Análise em Componentes Principais (*Principal Component Analysis* - PCA) (JOLLIFFE, 2002) é um exemplo deste método.
- Métodos de seleção de características – não modificam o conjunto original de dados, apresentando como resultado subconjuntos de características pertencentes ao conjunto original. Os algoritmos genéticos, o ABC e o PSO são exemplos de algoritmos bioinspirados utilizados em métodos de seleção de características.

2.2 Seleção de Características

A seleção de características tem como objetivo identificar o subconjunto de características B, oriundo de um universo inicial A de características de um dado conjunto, que forneçam a melhor representação de um sinal. O processo de busca pelo subconjunto B pode ser formalizado como uma busca em um espaço de estados. Realizar uma busca completa em um conjunto de características de tamanho N significa avaliar $2^N - 1$ estados, o que pode dificultar o processo de busca ou mesmo torná-lo inviável para um conjunto com um grande número de características. Uma solução para o problema exposto é a aplicação de técnicas heurísticas por meio de algoritmos de seleção de características (NAGHIBI, HOFFMANN e PFISTER, 2013).

No processo de seleção de características faz-se necessário percorrer todo o espaço de estados. O problema aparece quando o espaço a ser percorrido possui dimensões elevadas, o que pode tornar o processo de seleção impraticável até mesmo na esfera computacional.

No processo de seleção das características mais relevantes podem ser aplicadas estratégias de busca, de acordo com a natureza de inicialização, sendo divididas em três categorias (LIU e YU, 2005):

- *Forward*: trabalha com o subconjunto de características inicializado vazio e, durante o processo de busca, novas características são adicionadas ao subconjunto. Esta abordagem foi escolhida para ser utilizada na pesquisa já que a finalidade é descobrir a melhor solução e que utilize o menor número de características possíveis.
- *Backward*: quando o subconjunto é inicializado contendo todas as características e, durante o processo de busca, características consideradas irrelevantes são removidas.
- *Bidirectional*: quando as características são adicionadas ou removidas simultaneamente durante o processo de busca.

Na seleção de características, métricas para avaliação das possíveis soluções (subconjuntos) são utilizadas na identificação da importância de cada uma delas. Esse procedimento auxilia e direciona o processo da estratégia de busca empregada e pode ser do tipo:

- *Wrapper*: abordagem focada na representação da classificação e busca heurística para escolher o melhor subconjunto de características, usando o

desempenho do processo de classificação como função objetivo do subconjunto (KOHAVI e JOHN, 1997).

- Filtros: abordagem de seleção de características realizada na fase de pré-processamento do sinal. Nesta abordagem as propriedades essenciais do sinal são analisadas durante a seleção. Essa abordagem é independente do algoritmo de classificação e ordenam as características de acordo com um limiar de seleção. Valores superiores ao limiar são selecionados e valores inferiores são descartados (LIU e SETIONO, 1996).
- Híbrida: como o próprio nome indica, é uma combinação das duas anteriores, Filtro e *Wrapper* (DAS, 2001). Essa abordagem procura minimizar erros de seleção como o descarte de características que, isoladamente, são identificadas como de baixa relevância e que, quando analisadas em conjunto, podem apresentar relevância.

A seleção de características com *Wrapper* geralmente produz melhores resultados em termos de acurácia em relação à abordagem com filtros, entretanto o custo de treinamento de algoritmos que a utilizam geralmente é maior que aqueles que usam a abordagem filtros (FERREIRA e JORGE, 2007).

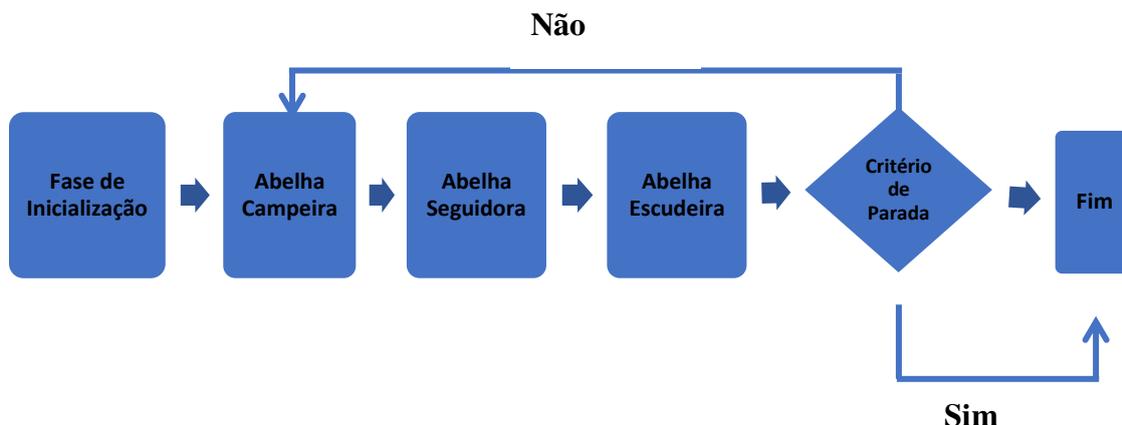
2.3 Algoritmo ABC

Os algoritmos bioinspirados fazem uso do processo biológico e comportamento de seres vivos traduzidos por meio de operações e linguagem matemática. Fazem parte da classe de algoritmos metaheurísticos e estocásticos que trabalham com o objetivo de buscar soluções para problemas cujo espaço de busca possui dimensionalidade de grau elevado.

O algoritmo ABC, considerado algoritmo de inteligência de enxames, simula o comportamento das abelhas na busca por alimento (KARABOGA, 2009). No processo por busca de alimento, diversos fatores são considerados: odor, localizações (abelha, flores, colmeia), presença de outras abelhas, qualidade do mel e vizinhança (fontes de alimento conhecidas). Muitas dessas informações são passadas entre as abelhas por meio de movimentos (FRISH, 1953; SEELEY, 1985; LINDAUER e FRISCH, 1956).

Na Figura 1 está ilustrado o fluxograma do algoritmo ABC.

Figura 1 – Fluxograma do algoritmo ABC.



Fonte: Autoria própria, modificado de KARABOGA (2009).

No algoritmo ABC, o processo de busca por alimento e seleção das melhores fontes pelas abelhas é composto pelos elementos (ZENG e BAO, 2009):

- **Fonte de alimento:** provável solução do problema.
- **Abelhas campeiras:** responsáveis por encontrar, avaliar, armazenar e transmitir informações sobre as fontes de alimento para as abelhas seguidoras.
- **Abelhas seguidoras:** recebem informações das abelhas campeiras e por meio dessas informações calculam a probabilidade das fontes de alimento (visitadas na fase da abelha campeira) ter sua vizinhança explorada. Com base na probabilidade resultante, as abelhas seguidoras escolhem as melhores fontes, cuja vizinhança será explorada. Quando as fontes de alimento vizinhas foram todas exploradas a fonte original se esgota, ou seja, nenhuma fonte de alimento vizinha terá melhor qualidade que a fonte original, a fonte de alimento em questão (fonte original) será abandonada.
- **Abelhas escudeiras:** responsável por verificar se existe e quantas são as fontes de alimentos abandonadas. Para cada fonte de alimento abandonada na fase da abelha seguidora uma nova fonte de alimento é criada (aleatoriamente sem nenhuma ligação com as fontes abandonadas).

O algoritmo desenvolvido por Karaboga e Akay (2012), propõe a criação de fontes de alimento (possíveis soluções do problema). A criação das fontes é definida

matematicamente pela Equação (1), em que x_{ij} representa a fonte de alimento, $i = 1, \dots, N$ (quantidade de fontes iniciais), $j = 1, \dots, M$, sendo N o número de fontes de alimento e M o número de parâmetros de otimização.

$$x_{ij} = x_j^{min} + \text{rand}(0,1)(x_j^{max} - x_j^{min}). \quad (1)$$

Para o método proposto nesta pesquisa, os parâmetros de otimização serão representados por vetores de bits. Assim, a Equação (1) não será empregada na definição das fontes de alimento iniciais.

A exploração da vizinhança de uma fonte de alimento pela abelha campeira é definida pela Equação (2), em que v_{ij} corresponde à vizinhança a ser explorada.

$$v_{ij} = x_{ij} + \Phi_{ij}(x_{ij} - x_{kj}). \quad (2)$$

Os índices j e k são variáveis aleatórias. O valor de k pode variar de 1 até N e deve ser diferente de i . A variável Φ_{ij} é um número aleatório entre -1 e 1. Sempre que uma nova fonte de alimento for produzida v_{ij} , a qualidade da fonte de alimento deverá ser calculada através da função *fitness*, Equação (3), em que f_i é a função custo. O método proposto não utilizará a Equação (2), que opera apenas com valores reais e não valores binários.

Para o método proposto, a função de custo será utilizada diretamente com os valores do *fitness*, que será representada pelo valor da acurácia determinado pelo classificador utilizando o vetor de bits e a Equação (3) não será aplicada no método proposto.

$$fitness_i = \begin{cases} \frac{1}{1+f_i}, & \text{se } f_i \geq 0 \\ 1 + |f_i|, & \text{se } f_i < 0 \end{cases}. \quad (3)$$

A probabilidade de uma abelha seguidora, a partir das informações obtidas da abelha campeira, escolher uma fonte de alimento para ser explorada está diretamente relacionada ao *fitness* da fonte. Essa probabilidade está definida pela Equação (4), em que F é o número de fontes.

$$p_i = \frac{fitness_i}{\sum_{n=1}^F fitness_i}. \quad (4)$$

Por fim, o algoritmo confere se existe alguma fonte de alimento para ser abandonada. Esse critério é definido pelo número de iterações pré-definido. A fonte de alimento abandonada é substituída por uma nova fonte de alimento que será criada pela abelha escudeira. O processo se repete até que o número de iterações seja atendido.

Neste trabalho, é empregada uma versão binária do algoritmo ABC para a seleção de características, descrito a seguir.

2.4 Algoritmo ABC Binário

Na versão binária do algoritmo ABC, as características são representadas pelas fontes de alimento e um espaço de busca discreto é considerado. As características selecionadas são rotuladas como auxílio de um classificador e avaliadas de acordo com o valor da acurácia obtido (B. e RAJALAXMI, 2014; RAJAMOHANA e MAHESWARI, 2016).

O ABC binário aplica a técnica *forward*, na qual são adicionadas novas características ao subconjunto inicial. A aplicação da técnica se justifica pela natureza do algoritmo, em que as fontes de alimento começam com apenas uma característica selecionada e, à medida que a aplicação é executada, novas características são selecionadas e adicionadas à fonte de alimento inicial. Essa abordagem foi escolhida com o objetivo de encontrar as melhores soluções para o problema.

Quando as fontes de alimento são criadas é feito o cálculo da qualidade de cada uma (*fitness*), através do classificador. Para o cálculo, o subconjunto de características é submetido a um processo de treinamento e classificação. Após o cálculo da qualidade de todas as fontes de alimento criadas, aquela com melhor qualidade é armazenada. Caso existam duas com a mesma qualidade, armazena-se aquela com menor número de características em seu subconjunto.

No processo de seleção de características, uma fonte de alimento vizinha, associada aos subconjuntos recém-modificados, é criada a partir do vetor de bits da fonte de alimento anteriormente explorada. A nova fonte é submetida ao treinamento e classificação e tem seu *fitness* calculado. Se o *fitness* da fonte de alimento vizinha, recém-criada, for superior ao *fitness* da fonte de alimento que a originou, então a fonte de alimento vizinha é armazenada e passa a ser considerada como possível solução do problema. Caso contrário, a variável, que representa o número de iterações é incrementada. Quando o número de iterações chega ao seu limite, a fonte de alimento explorada é abandonada.

O algoritmo verifica se existem fontes de alimento que foram abandonadas em fases anteriores. Se existirem, para cada fonte de alimento abandonada, novas fontes de alimento são criadas aleatoriamente que também serão submetidas ao treinamento e à classificação e terão seus *fitness* calculados e avaliados, conforme explicado anteriormente. O algoritmo é executado até que a condição de parada, número de ciclos, seja atendida satisfatoriamente.

De forma simplificada, o algoritmo ABC binário consiste das seguintes etapas:

1. Inicialmente, são criados os vetores de características (de acordo com a quantidade inicial de fontes de alimento). Para cada fonte criada, uma abelha campeira será associada e os parâmetros da aplicação são definidos.
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 0. Cada fonte criada deve ser avaliada pelo valor da acurácia obtida por meio do classificador.
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 estabelecido (KARABOGA e AKAY, 2012).
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 e uma abelha campeira será criada e associada a esta nova fonte.
5. Abelhas seguidoras: analisam as informações de qualidade coletadas na fase da abelha campeira e decidem quais são as melhores fontes a serem exploradas de acordo com a probabilidade, mostrada na Equação (5).

$$p_i = \frac{fitness_i}{\sum_{j=1}^N fitness_j}. \quad (5)$$

Caso a qualidade da nova fonte seja maior do que a qualidade da fonte de alimento existente, ela será explorada; caso contrário, ela não será.

6. Abelhas escudeiras: verificam se fontes de alimentos foram abandonadas na fase da abelha campeira e para cada fonte de alimento abandonada, a abelha escudeira cria uma nova fonte de alimento de forma aleatória e sem

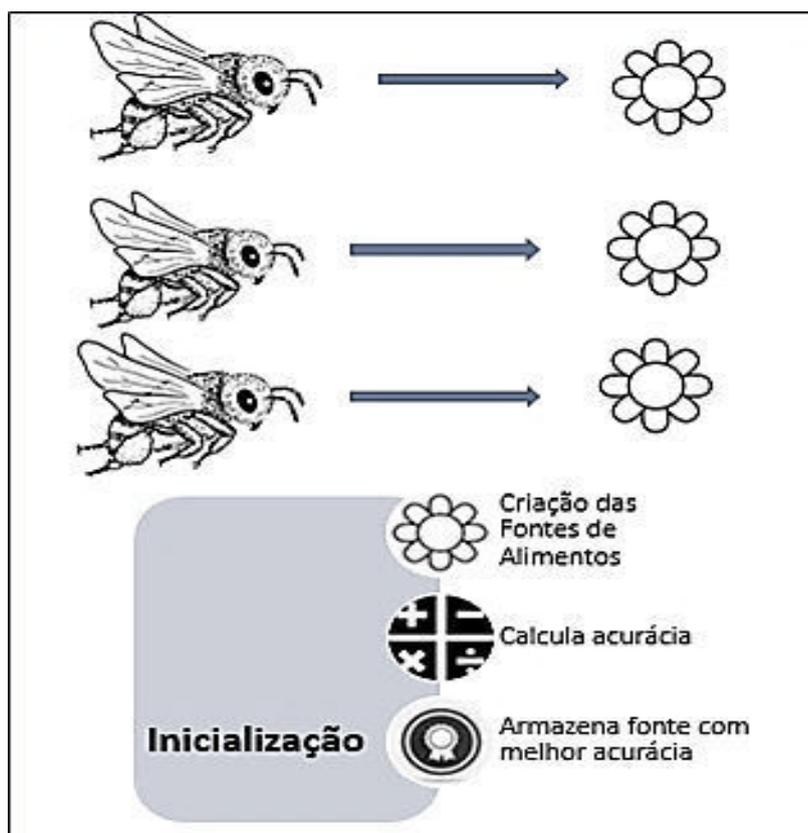
nenhuma ligação com a original. Essas novas fontes serão exploradas pelas abelhas campeiras.

7. 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. Ao final, a melhor fonte de alimento (melhor solução) é retornada.

Nas Figuras de 2 a 7 está ilustrado o processo de inicialização, bem como o comportamento e a responsabilidade das abelhas campeiras, seguidoras e escudeiras dentro do algoritmo ABC binário.

Na Figura 2 está apresentado o processo de inicialização das primeiras fontes de alimentos, e suas etapas de criação, inicialização, cálculo da acurácia e armazenamento da melhor fonte de alimento.

Figura 2 - Processo de inicialização.

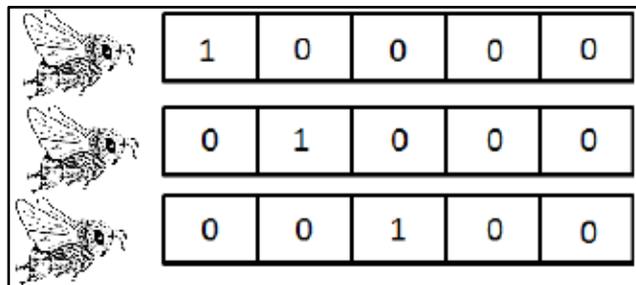


Fonte: Autoria Própria.

A disposição dos valores binários iniciais referentes aos vetores, fontes de alimentos, está ilustrada Figura 3. Cada vetor, inicialmente, contém apenas uma de suas

posições marcada com 1 e as demais marcadas com 0. Essa distribuição é feita de forma que todos os vetores sejam diferentes entre si.

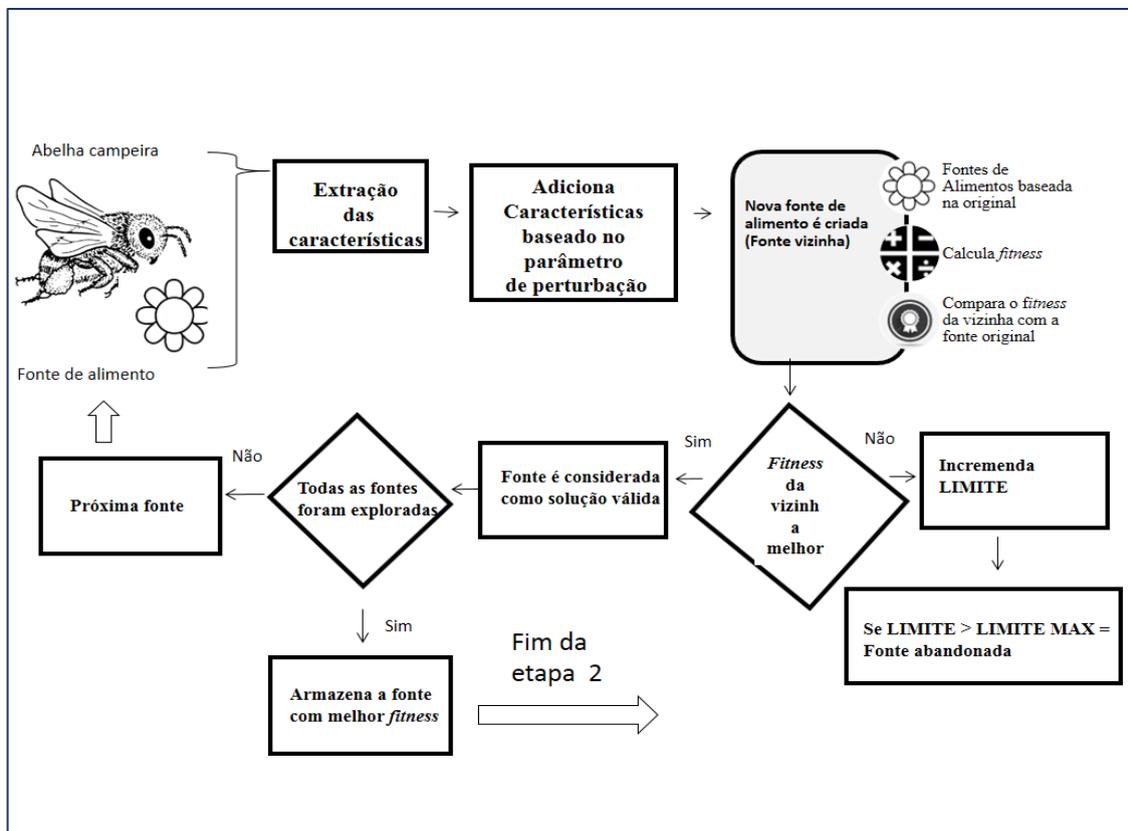
Figura 3 – Vetores e seus valores iniciais



Fonte: Autoria Própria.

Na Figura 4 está a ilustração das responsabilidades que devem ser executadas pela abelha campeira. Nesta fase cada fonte de alimento terá suas características exploradas, terá características adicionadas ou ainda se tornarão fontes abandonadas, dependendo dos critérios de avaliação.

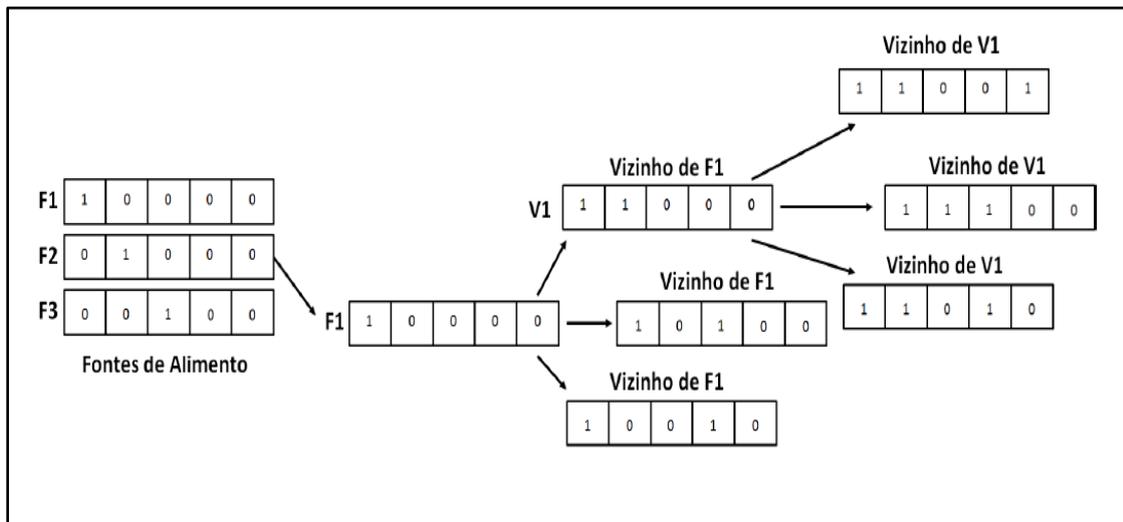
Figura 4 - Processo executado pela abelha campeira.



Fonte: Autoria Própria

Na Figura 5 apresentamos o processo de exploração e criação das fontes de alimentos vizinhas, criadas com base na fonte de alimento original. Esta etapa é realizada pela abelha campeira.

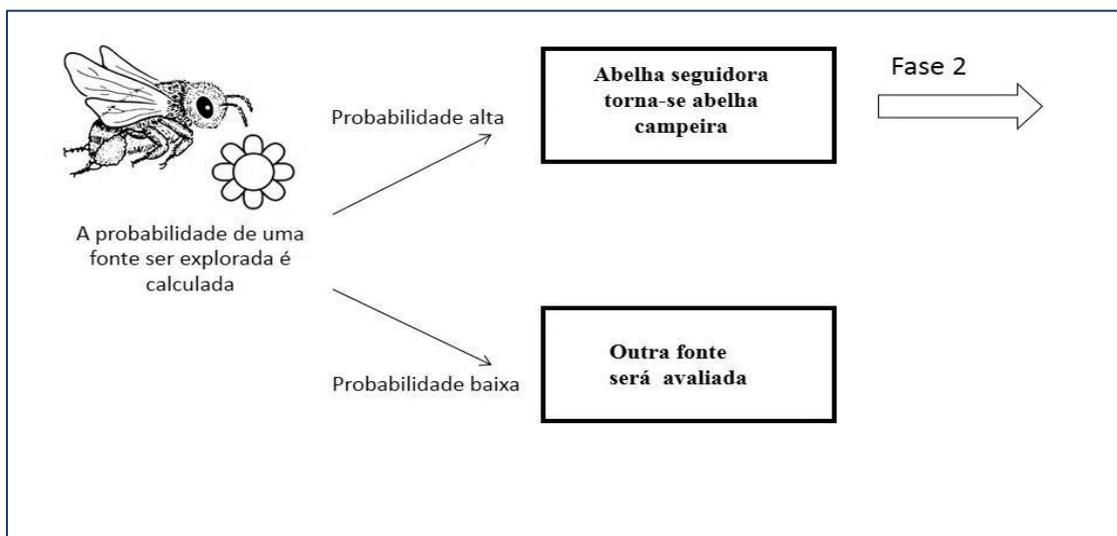
Figura 5 - Exploração e criação das fontes de alimentos (vizinhas)



Fonte: (SCHIEZARO, 2014)

Na Figura 6 é apresentado o processo de execução da fase da abelha seguidora. Nesta etapa é feito o cálculo da probabilidade de uma determinada fonte de alimento ser explorada.

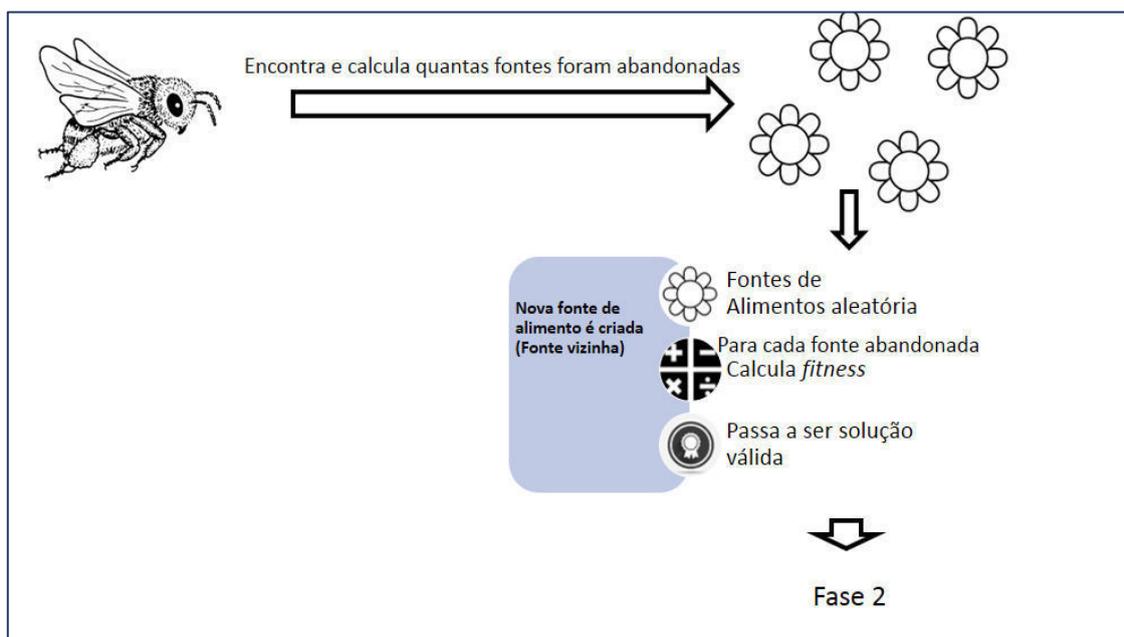
Figura 6 - Processo executado pela abelha seguidora.



Fonte: Autoria Própria

Já na Figura 7 é demonstrado o processo executado pela abelha escudeira. Nesta fase é observado quantas e se existem fontes de alimentos abandonadas durante a fase da abelha campeira. Para cada fonte abandonada uma nova fonte é criada.

Figura 7 - Processo executado pela abelha escudeira.



Fonte: Autoria Própria.

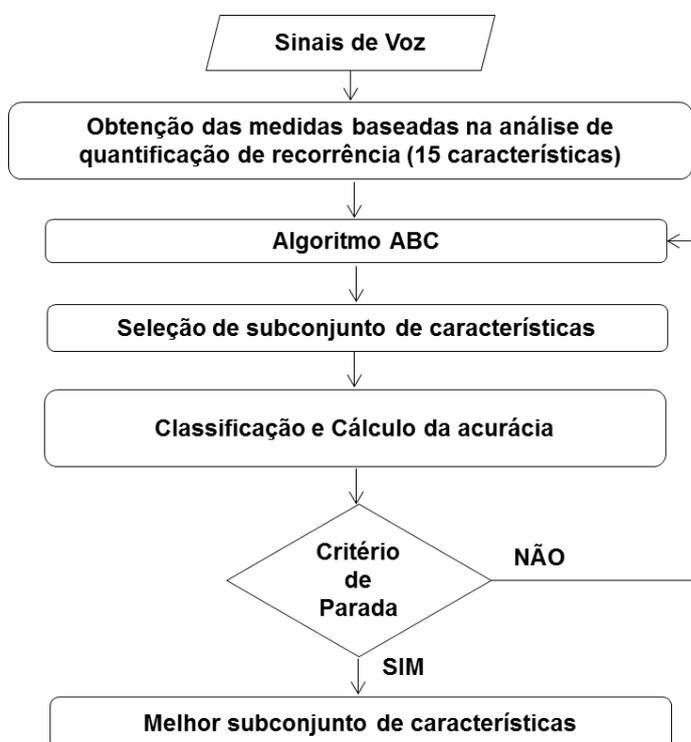
Capítulo III – Materiais e Métodos

A seguir são descritos os materiais e métodos usados na pesquisa, bem como a base de dados utilizada, o método de extração de características aplicado, seleção de características empregando o algoritmo ABC e uma breve abordagem sobre classificadores.

O algoritmo implementado é baseado no método utilizado por Schiezero (2014) e será aplicado na seleção de características para detecção de sinais de voz com desvios vocais.

O fluxograma, apresentado na Figura 8, 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 por um classificador. Quando o critério de parada é atingido (todas as fontes de alimento foram exploradas), são determinadas as medidas que, em conjunto, fornecem melhor acurácia na classificação.

Figura 8 - Fluxograma da metodologia empregada.



Fonte: Autoria Própria

3.1 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 (LOPES *et al.*, 2016).

Foram gravados dos pacientes, com idade entre 18 e 65 anos, sinais de vozes referentes à pronúncia da vogal sustentada /É/ (“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 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.

3.2 Extração de Características

Foram extraídas, de cada sinal, 15 características através do método de análise de Quantificação de Recorrência (VIEIRA, 2014). A escolha de tais medidas se justifica por pesquisas já realizadas, as quais se mostram promissoras (LOPES *et al.*, 2016; VIEIRA, 2014; SOUZA, 2017).

O Gráfico de Recorrência (*Recurrence Plot* – RP) é uma representação m -dimensional, através de uma representação bidimensional, utilizando uma ferramenta proposta e definida por Marwan (2003) e Eckmann, Kamphorst e Ruelle (1987), representado pela Equação (6).

$$\mathcal{R}_{i,j}^{m,\varepsilon} = \Theta (\varepsilon - \|\vec{\xi}_i - \vec{\xi}_j\|), \quad \vec{\xi}_i \in \mathcal{R}^m, i, j = 1 \dots N, \quad (6)$$

em que: N é o número de estados $\vec{\xi}_i$; ε 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 atual do sistema e o estado a ser

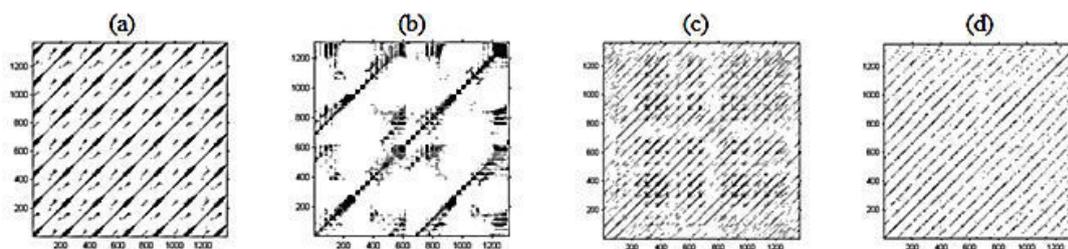
comparado for menor que o raio de vizinhança ε (VIEIRA, 2014; ECKMANN, KAMPHORST e RUELLE, 1987).

Para a reconstrução do espaço de fases é necessário determinar o tempo de atraso ótimo ou passo de reconstrução, τ . Em Takens (1981) é esclarecido 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 (7).

$$\vec{\xi}_i = \{x(n_i), x(n_i + \tau), \dots, x(n_i + (m - 1)\tau)\}. \quad (7)$$

Na Figura 9 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 e 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 (COSTA, 2012).

Figura 9 - Gráficos de recorrência para sinais (vogal sustentada /É/ (“é”)), classificados como: (a) saudáveis; (b) com rugosidade; (c) com sopro; (d) com tensão.



Fonte: QUEIROZ (2017).

As medidas de quantificação de recorrência, extraídas dos gráficos, por outro lado, fornecem uma avaliação quantitativa, possibilitando resultados de avaliação mais confiáveis. Nesta pesquisa, 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 (VIEIRA, 2014; COSTA, 2012; JIANG, ZHANG e MCGILLIGAN, 2006).

- **Passo de Reconstrução:** No cálculo que determina o passo de reconstrução ótimo, τ , é comum o uso do método da informação mútua média (SOUZA, 2008), que é baseado na teoria da informação. Esse método afirma que pode-se garantir a reconstrução de vetores com o menor nível de informação redundante, linearmente independentes e correlacionados. A teoria da informação procura identificar o quanto de informação se pode ter de uma medida realizada em um determinado instante de tempo t , quando se observa outra medida, do mesmo sinal, em um tempo posterior $t + \tau$ (SOUZA, 2008, VIEIRA, 2017).
- **A dimensão de imersão, m :** Deve respeitar a condição $m \geq 2d + 1$, em que d é a dimensão fractal do atrator (OTT, SAUER e A., 1994). A aplicação da relação entre m e d é especialmente difícil por nem sempre sabermos os valores da dimensão fractal, com isso duas teorias podem ser aplicadas na solução desta problemática: A primeira uma é a aplicação da observação do comportamento do sistema quando se aumenta gradativamente a dimensão de imersão. A segunda é realizada através do um método conhecido como “falsos vizinhos”, no qual é alterado gradativamente o valor de m e constatado quais os pontos que se distanciam (vizinhos verdadeiros sempre permanecem vizinhos) e que a dimensão de imersão ideal é considerada como sendo o menor valor para o qual se tenha o menor percentual de falsa vizinhança (SOUZA, 2008, VIEIRA, 2017). A extração dos valores de m neste trabalho utilizou o dos “falsos vizinhos”.
- **Raio da Vizinhança:** O raio da Vizinhança pode ser entendido como sendo à distância (raio) ε , fixada no centro do estado corrente e que determina se um ponto é recorrente, ou seja, se o referido ponto será colocado na matriz de recorrência com coordenadas i e j somente se o estado $\vec{\xi}_i$ for suficientemente próximo ao estado $\vec{\xi}_j$, ou seja, se a distância entre estado corrente do sistema e o estado a ser comparado for menor que certa distância ε (ECKMANN et al., 1987).
- **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 por:

$$Det = \frac{\sum_{l=l_{min}}^N l \times P^\varepsilon(l)}{\sum_{ij}^N R_{ij}^{m,\varepsilon}}, \quad (8)$$

em que $P^\varepsilon = \{l_i, i = 1 \dots N_l\}$, representa a distribuição de frequência dos comprimentos l das N_l estruturas diagonais e l_{min} o número mínimo de pontos para formar uma linha diagonal dentro do gráfico de recorrência.

- **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:

$$Lmed = \frac{\sum_{l=l_{min}}^N l \times P^\varepsilon(l)}{\sum_{l=l_{min}}^N P^\varepsilon(l)}. \quad (9)$$

- **Comprimento máximo das linhas diagonais (*Lmax*):** É o tempo máximo em que dois segmentos de uma trajetória estão próximos um do outro, dado pela seguinte equação:

$$Lmax = \max(\{l_i: i = 1 \dots N_l\}), \quad (10)$$

em que, l_i refere-se às linhas diagonais e N_l o número de linhas diagonais.

- **Entropia de Shannon (*Entr*):** Dada pela Equação (11), 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, em que l_{min} é o comprimento mínimo das linhas diagonais, $p(l)$ é a distribuição de frequência das linhas diagonais.

$$Entr = - \sum_{l=l_{min}}^N p(l) \ln p(l), \quad (11)$$

em que $p(l) = \frac{P^\varepsilon(l)}{\sum_{l=l_{min}}^N P^\varepsilon(l)}$.

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

$$LAM = \frac{\sum_{v=v_{min}}^N v \times P^\varepsilon(v)}{\sum_{v=1}^N v \times P^\varepsilon(v)}. \quad (12)$$

- **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:

$$TT = \frac{\sum_{v=vmin}^N v \times P^\varepsilon(v)}{\sum_{v=vmin}^N P^\varepsilon(v)}, \quad (13)$$

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, dado por:

$$Vmax = \max(\{V_l: l = 1 \dots N_v\}), \quad (14)$$

em que N_v é o número de linhas verticais e V_l o comprimento da linha vertical.

Tempo de recorrência tipo 1 (T^1): indica a distância entre um ponto recorrente e o ponto referência do raio de vizinhança:

$$T_j^1 = |\{i, j: \vec{\xi}_i, \vec{\xi}_j \in \mathcal{R}_i\}|. \quad (15)$$

- **Tempo de recorrência tipo 2 (T^2):** é a distância entre o primeiro ponto recorrente e o ponto de referência do raio de vizinhança:

$$T_j^2 = |\{i, j: \vec{\xi}_i, \vec{\xi}_j \in \mathcal{R}_i, \vec{\xi}_{j-1} \notin \mathcal{R}_i\}|. \quad (16)$$

- **Entropia do tempo recorrência do tipo 1 (*RPDE- Recurrence Probability Density Entropy*):** é medida pela seguinte equação:

$$RPDE = \frac{-\sum_{i=1}^{T^1max} P(i) \cdot \ln P(i)}{\ln T^1max}, \quad (17)$$

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

- **Transitividade (*Trans*):** é uma espécie de taxa de recorrência local, que pode ser utilizada em conjunto com o raio vizinhança para a construção do gráfico de recorrência:

$$Trans = \frac{\sum_{i,j,k=1}^N R_{i,j}^{m,\varepsilon} R_{i,k}^{m,\varepsilon} R_{k,i}^{m,\varepsilon}}{\sum_{i,j,k=1}^N R_{i,j}^{m,\varepsilon} R_{k,i}^{m,\varepsilon}}. \quad (18)$$

- **Divergência (*Div*):** é o inverso de *Lmax*:

$$Div = \frac{1}{Lmax}. \quad (19)$$

A dimensão de imersão m e o passo de reconstrução τ foram obtidos por meio da *toolbox CRP (Cross Recurrence Plot)*, implementada como *software MatLab*[®]7.9, com o qual também foram extraídas as MQR's (Medidas de Quantificação de Recorrência), utilizando-se a taxa de recorrência $REC < 1\%$.

3.3 Seleção de Características Empregando o Algoritmo ABC

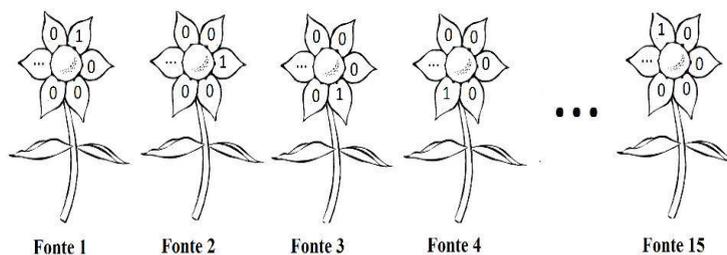
Para a seleção de características, a fonte de alimento é representada por um vetor V composto por bits de tamanho T , em que T é o número de características a serem avaliadas. Cada posição do vetor corresponde a uma determinada característica. O valor 1 corresponde a características classificadas como relevantes e o valor 0 a características a serem descartadas. Na Tabela 1 é mostrado o posicionamento inicial dos bits que representam os vetores de características. A Figura 10 ilustra as fontes de alimento iniciais.

Tabela 1 - Representação dos vetores de características (fonte de alimento) inicial.

Fonte 1	Fonte 2	Fonte 3	...	Fonte 15
1	0	0	0	0
0	1	0	0	0
0	0	1	0	0
...
0	0	0	0	1

Fonte: Autoria própria.

Figura 10 - Representação das fontes de alimento (inicialização).



Fonte: Autoria própria

Cada fonte de alimento também conterá a informação da sua qualidade, aqui denominada *fitness*. A qualidade de cada fonte de alimento é dada pela acurácia do classificador que utiliza os dados do subconjunto de características contido no vetor de bits. A acurácia pode ser definida de acordo com a Equação (20).

$$ACC = \frac{VP+VN}{P+F}. \quad (20)$$

Em que ACC é a acurácia do classificador, VP é o número de verdadeiros positivos, VN é o número de verdadeiros negativos, P é o número de instâncias com rótulos marcados como verdadeiros e F é o número de instâncias com rótulos marcados como falsos (SCHIEZARO, 2014).

Durante o processo da classificação faz-se uso da metodologia de validação cruzada. A validação cruzada, resumidamente, funciona da seguinte forma: o subconjunto de características avaliado é aleatoriamente dividido em 10 partições de tamanhos iguais. A primeira partição é reservada para ser utilizada como simulação e as outras nove partições são usadas para treinamento do classificador. Passo de reconstrução processo é repetido 10 vezes e em cada repetição uma partição diferente é usada para simulação a cada iteração. Quando o processo de validação é finalizado, a estimativa de acurácia do classificador é feita pela média dos 10 resultados.

3.4 Classificadores

Um algoritmo cujo objetivo é executar a tarefa de classificação de um dado conjunto de dados é denominado classificador. A utilização de classificadores precisos e eficientes é primordial e decisivo na seleção de características. Por este motivo, quatro técnicas (algoritmos) foram estudadas de forma a garantir bons resultados em termos de

acurácia, convergência e processamento da aplicação. Nas próximas seções, é apresentada uma breve descrição dos classificadores: K-NN, *Naïve Bayes*, SVM e MLP, utilizados na pesquisa. A escolha destes classificadores se justifica pela larga utilização na literatura, inclusive entre os trabalhos apresentados no estado da arte dessa pesquisa e, também por serem algoritmos com implementação na biblioteca *weka*.

3.4.1 K-NN

O classificador K-NN, método dos K vizinhos mais próximos, é encontrado frequentemente na literatura como meio de resolução de problemas de classificação de dados, possui regra de decisão simples em que um rótulo de uma classe é associado a um determinado dado de acordo com os rótulos associados aos K vizinhos mais próximos ao referido dado (SCHIEZARO, 2014). Esse classificador funciona essencialmente com o armazenamento das amostras do conjunto de treino, chamado de rótulo do problema. Quando uma nova amostra é submetida ao classificador, ele gera uma resposta baseada no relacionamento da nova amostra com o conjunto de treino (MITCHELL, 1997).

3.4.2 Naïve Bayes

O classificador *Naïve Bayes* classifica os indivíduos tomando como base a probabilidade de uma nova amostra pertencer ou não a uma das classes já conhecidas. É um método probabilístico que determina que quanto mais próxima for a distribuição das amostras da distribuição ótima, melhor será considerado o resultado da classificação (GONZALEZ e WOODS, 2010). O *Naïve Bayes*, de regra, apresenta uma boa eficiência computacional e aplicabilidade. Entretanto, possui como desvantagem depender da distribuição das informações adquiridas pelos descritores, no qual o classificador busca em sua função de decisão a hipótese de que os dados possuem distribuição ótima.

3.4.3 Support Vector Machine

O classificador *Support Vector Machine*, conhecido SVM, utiliza conceitos de linearidade para separar os indivíduos tidos como positivos dos negativos. Os modelos de linearidade criados são usados para definir as regiões onde ocorre cada uma das classes. Sendo assim, quando se recebe uma nova amostra, ela será classificada de acordo com o posicionamento da mesma em relação ao limiar divisor. O diferencial desse classificador está no seu objetivo de maximizar a generalização da classificação e

não de ser focado em maximizar o desempenho como os classificadores acima mencionados (ABE, 2010).

3.4.4 *Multilayer Perceptron (MLP)*

O classificador *Multilayer Perceptron* é uma rede neural que usa aprendizagem supervisionada para aprimorar seus resultados. É um método baseado no funcionamento do sistema nervoso humano, o qual processa os dados fazendo uso de neurônios interconectados. A ideia utilizada pelo MLP consiste em uma rede *feed-forward*, em que as informações caminham da entrada para a saída, passando por múltiplas camadas intermediárias. Com exceção da camada de entrada, cada nó do MLP é considerado como um neurônio, com uma função de ativação não linear, que é treinada com a técnica de retropropagação, fazendo uma otimização iterativa dos pesos que conectam os neurônios minimizando a taxa média de erro quadrático da classificação (RUMELHART e MCCLELLAND, 1986). A retropropagação faz com que após a rede ser submetida a um novo padrão, produza respostas que serão comparadas com uma resposta ideal. Se a resposta produzida não for compatível com a resposta ideal o erro é calculado. Os valores do erro são propagados da saída para a entrada combinando os pesos até que se obtenha uma resposta próxima ou quase idêntica à resposta ideal.

Os resultados obtidos por cada um dos classificadores serão descritos e analisados a seguir.

IV Resultados

Neste Capítulo, estão apresentados os resultados das simulações realizadas com a aplicação proposta, demonstrando a avaliação dos classificadores e parâmetros de configuração do algoritmo ABC, a incidência das características selecionadas pelo algoritmo proposto e análise estatística individual das medidas utilizadas.

O computador usado nas simulações foi um *Intel Core i7-4510U* com 2.0 GHz, 16 GB de RAM e sistema operacional *Windows*, versão 7.

O método proposto para seleção de características dos sinais de voz foi implementado em um ambiente de desenvolvimento formado, essencialmente, pela linguagem de programação *JAVA*, com o auxílio da biblioteca *Weka*, versão 3.9 (HALL, FRANK, *et al.*, 2016). *Weka* é um *software* livre largamente utilizado para mineração de dados. Foi desenvolvido por um grupo de pesquisadores da universidade de *Waikato* da Nova Zelândia. Contêm um conjunto de algoritmos implementados para aprendizado de máquina, direcionada ao auxílio à mineração de dados e ao reconhecimento de padrões. A aplicação utiliza a referida biblioteca por meio de chamadas de código com base na linguagem de programação *Java*.

Quatro casos de classificação foram considerados para a discriminação entre sinais de vozes saudáveis (SDL) e com desvios vocais soproso (SPR), Rugosos (RUG) e tensos (TEN). Os casos de classificação são: SDLxSPR, SDLxRUG, SDLxTEN e SDLxDESV (Saudável X Desviada), em que Desviadas, corresponde às classes de sinais com os desvios soproso, rugosidade e tensão em uma única classe.

4.1 Avaliação dos Classificadores

Com a finalidade de se escolher o classificador mais adequado, em termos de taxas de acurácia e tempo de resposta, as 15 medidas utilizadas na pesquisa foram submetidas à classificação. Quatro classificadores foram avaliados: *Naïve Bayes*, K-NN, SVM e MLP. A Tabela 2 apresenta os valores da acurácia para três casos de classificação: SDLxRUG, SDLxSPR e SDLxTEN. Observa-se que, com o classificador K-NN, que é um algoritmo de classificação mais simples, obtêm-se valores de acurácia superiores ou equivalentes às demais abordagens com exceção para o caso de classificação SDLxTEN. Quanto à convergência, o KNN, o MLP e *Naïve Bayes* se mostraram equivalentes, ao contrário do SVM que teve tempo de resposta lento em todas as simulações.

Pela simplicidade, resultados das taxas de acurácia, tempo de convergência e facilidade de implementação, optou-se pelo uso do K-NN nos demais experimentos.

Tabela 2 - Comparação entre os classificadores avaliados.

Classificadores	Acurácia		
	SDLxRUG (%)	SDLxSPR (%)	SDLxTEN (%)
<i>Naïve Bayes</i>	78,33	85	58
K-NN	81,66	85	51
SVM	78,33	85	65
MLP	75	83	51,66

Fonte: Autoria própria

4.2 Parâmetros de Configuração do Algoritmo ABC

O algoritmo ABC possui três parâmetros que precisam ser configurados para obtenção dos melhores resultados em termos de acurácia, subconjunto de características mais representativo e menor custo de processamento.

- **Parâmetro de perturbação:** controla a alteração do valor de uma determinada posição dentro de um vetor em análise, durante o espaço de busca na exploração da vizinhança. Esse parâmetro também ajusta a taxa de convergência do algoritmo, definindo quantas características serão adicionadas ao vetor a cada iteração, ou seja, é gerado um número aleatório uniforme entre 0 e 1, para cada posição do vetor de bits. Se o valor do número aleatório criado for menor que o parâmetro de perturbação, então a característica é inserida no subconjunto a ser avaliado, caso contrário, o valor no vetor de bits não é modificado.
- **Limite Máximo:** critério de parada do algoritmo. Parâmetro que evita que a aplicação fique presa a uma solução ótima local, evitando *loop* e processamento desnecessário. Indica o número máximo de vezes em que a vizinhança de uma fonte de alimento é explorada e que não foi encontrada uma melhor solução, quando comparada com a fonte original.
- **Iterações:** número de vezes que o algoritmo repete os processos principais – abelhas campeiras, seguidoras e escudeiras.

Os parâmetros de configuração da aplicação foram aleatoriamente testados e seus valores foram escolhidos de forma empírica, com o objetivo de localizar a melhor solução composta pelo mais alto índice de acurácia com o menor número de características e baixo custo de processamento. Na Tabela 3 estão mostrados os valores de parametrização aplicados na pesquisa. Foram realizadas 100 simulações para cada caso de classificação, totalizando 400 simulações.

Tabela 3 - Valores dos parâmetros do algoritmo ABC.

Parâmetro	Valores / Variação
Quantidade das fontes	15 a 32732
Parâmetro de Perturbação	Entre 0,005 e 10
Limite Máximo	Entre 2 e 50
Iteração	Entre 2 e 100

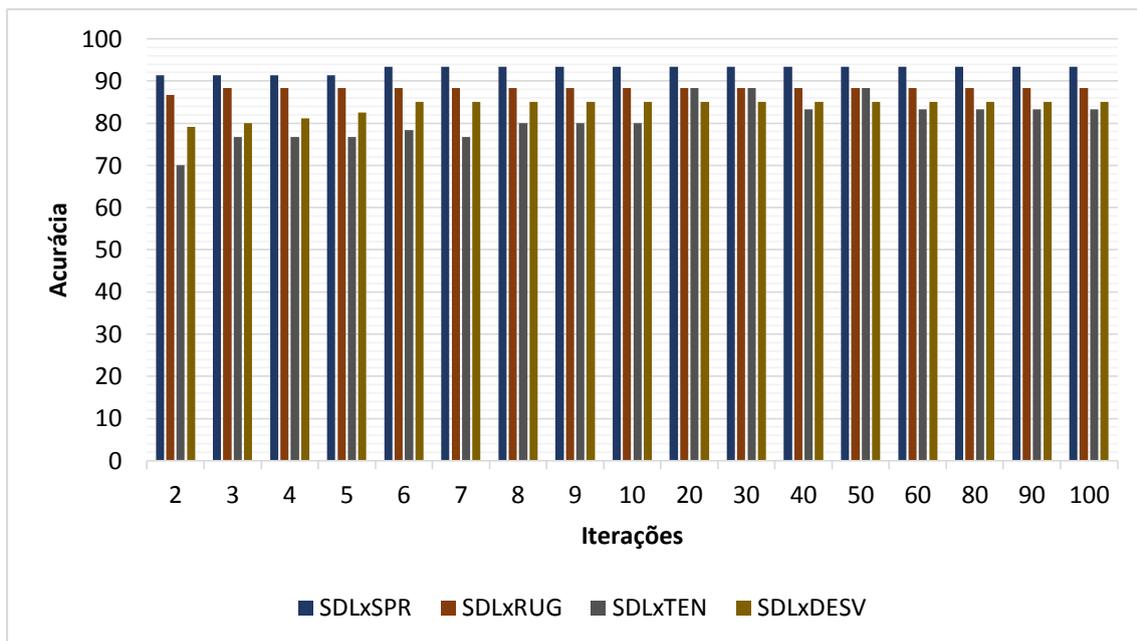
Fonte: Autoria própria

Nas Figuras de 11 a 16 são mostrados os resultados obtidos para cada caso de classificação dos sinais de voz processados. Os resultados são traduzidos através das seguintes instâncias: o número de características selecionadas após a execução da aplicação, os valores de acurácia do classificador e a posição do vetor selecionado (características). As Figuras 11 e 12 representam os resultados baseados no parâmetro da aplicação (Iteração); as Figuras 13 e 14 ilustram os resultados protagonizados pelo parâmetro da aplicação (Limite Máximo); as Figuras 15 e 16 mostram os resultados associados ao parâmetro da aplicação (Parâmetro de Perturbação).

4.2.1 Iteração

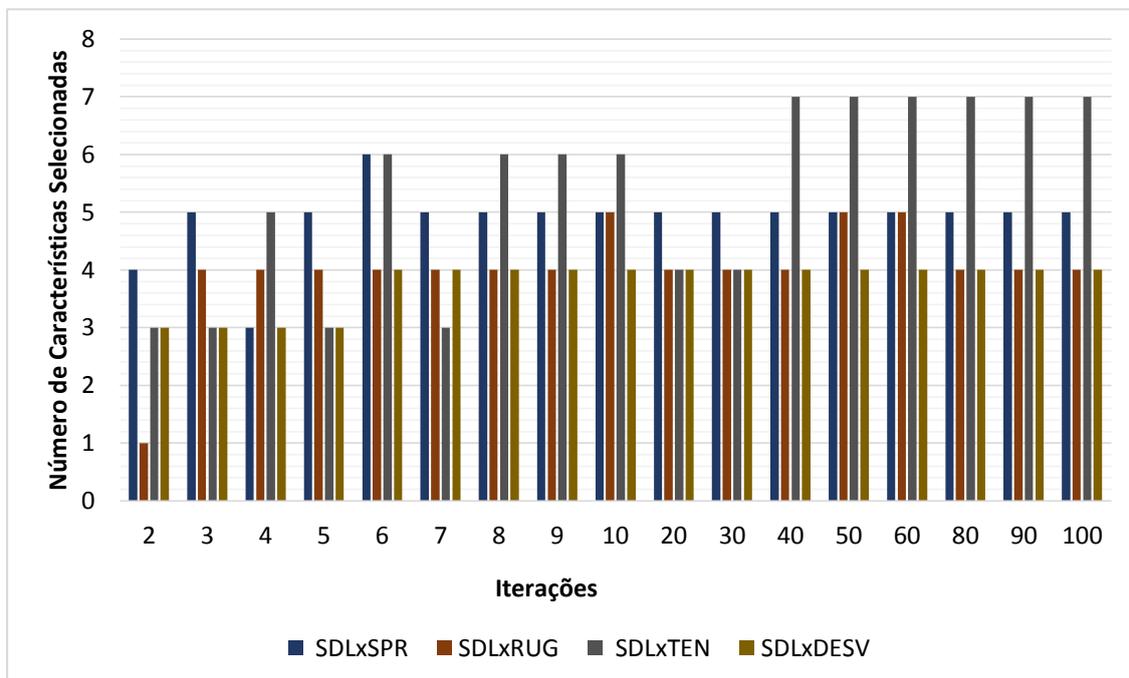
Os resultados obtidos para os casos de classificação: SDLxSPR, SDLxRUG, SDLxTEN e SDLxDESV, referente à abordagem baseada no parâmetro da aplicação Iteração estão apresentados nas Figuras 11 e 12. Quanto menor o número de iterações necessário para atingir a acurácia máxima com o menor número de iterações necessário para atingir a acurácia máxima com o menor subconjunto de características na classificação, menor será o custo de processamento da aplicação.

Figura 11 - Acurácia em termos do Parâmetro Iteração



Fonte: Autoria Própria

Figura 12 - Número de características selecionadas em termos de Iterações.



Fonte: Autoria Própria

Observando-se as Figuras 11 e 12, nota-se que com 7 iterações obtém-se a acurácia máxima de 93,33%, com um subconjunto de 5 características, na classificação SDLxSPR.

Já na discriminação entre sinais saudáveis e com rugosidade (SDLxRUG), verificamos que com apenas 3 iterações alcançamos a melhor taxa de acurácia 93,33%, com o número mínimo de 4 características selecionadas.

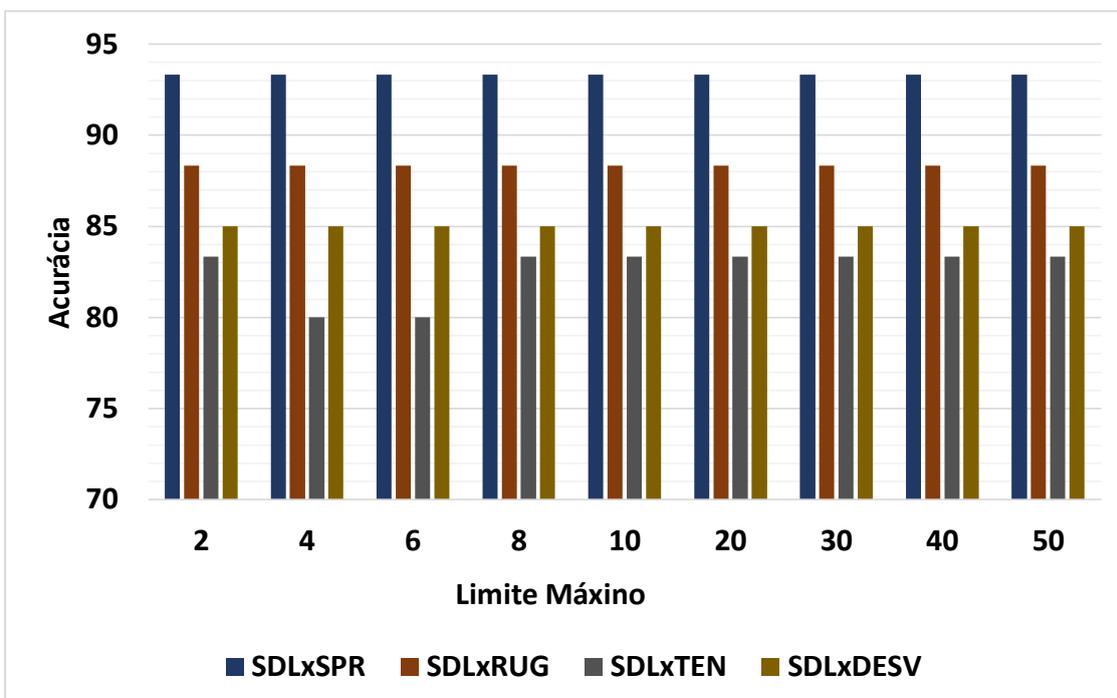
Na discriminação (SDLxTEN) observa-se que na discriminação entre sinais saudáveis e com rugosidade (SDLxRUG), com 20 iterações obtém-se a melhor taxa de acurácia 88,33%, com o número mínimo de 4 características selecionadas.

Para a classificação entre vozes saudáveis e desviadas (SDLxDESV), verifica-se que com 6 iterações é possível atingir 85% de taxa de acurácia, com 4 características selecionadas.

4.2.2 Limite Máximo

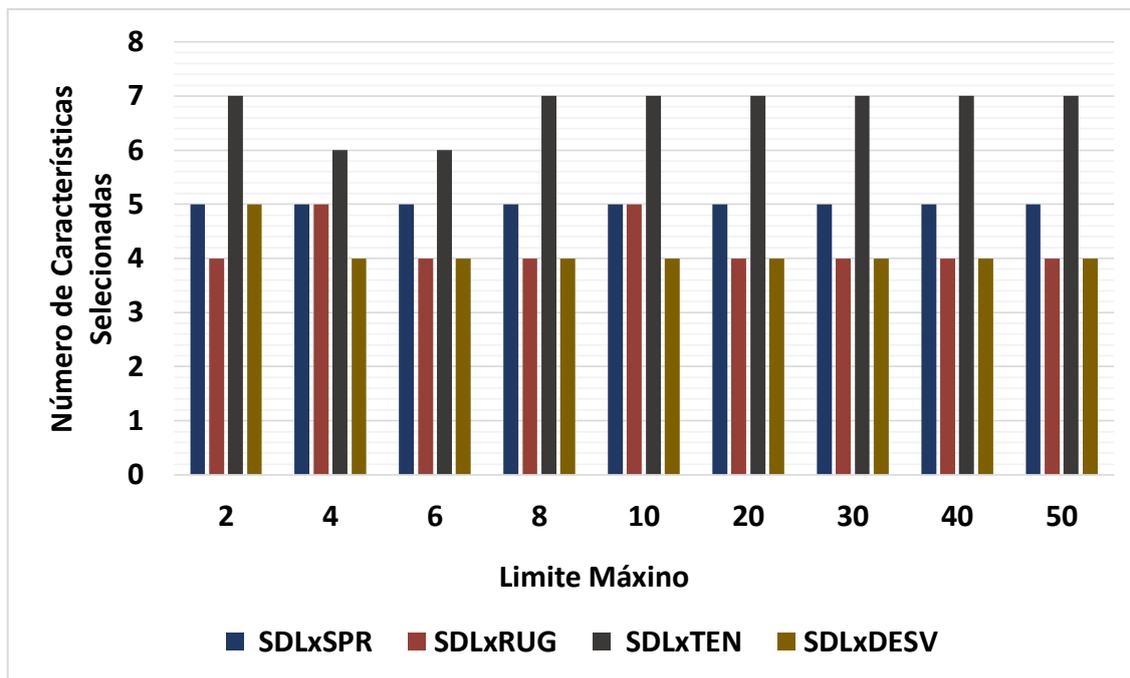
Os resultados obtidos para os quatro casos de classificação: SDLxSPR, SDLxRUG, SDLxTEN e SDLxDESV referente à abordagem baseada no parâmetro da aplicação Limite Máximo está explicitado nas Figuras 13 e 14.

Figura 13 - Acurácia em termos do Parâmetro Limite Máximo.



Fonte: Autoria Própria.

Figura 14- Número de Características em termos do Parâmetro Limite Máximo.



Fonte: Autoria Própria.

Figura 13 estão os resultados dos valores de acurácia obtidos para os quatro casos de classificação entre os sinais de vozes saudáveis e com desvio.

Na Figura 14 são ilustrados os resultados do número de características selecionadas nos quatro casos de classificação entre os sinais avaliados.

Para a discriminação SDLxSPR, os valores de acurácia permanecem constantes e iguais a 93,33% em todas as simulações associadas a este parâmetro. Logo, o melhor resultado, 93,33% de acurácia e menor custo de processamento, ocorre no valor de parametrização de Limite Máximo igual a 2 (melhor índice), quando 5 características são selecionadas (o número de características selecionadas também permaneceu constante em todas as análises realizadas).

Para a classificação SDLxRUG, os valores da acurácia permanecem constantes e iguais a 88,33% em todas as simulações associadas a este parâmetro. Portanto, o melhor resultado, 88,33% de acurácia e menor custo de processamento, ocorre no valor de parametrização de Limite Máximo igual a 2 quando 4 características são selecionadas.

Na discriminação entre os sinais saudáveis e tensos, SDLxTEN, os valores da acurácia permanecem constantes e iguais a 83,33% nas simulações associadas a este parâmetro. Portanto o melhor índice do parâmetro Limite Máximo é de 2, quando 7

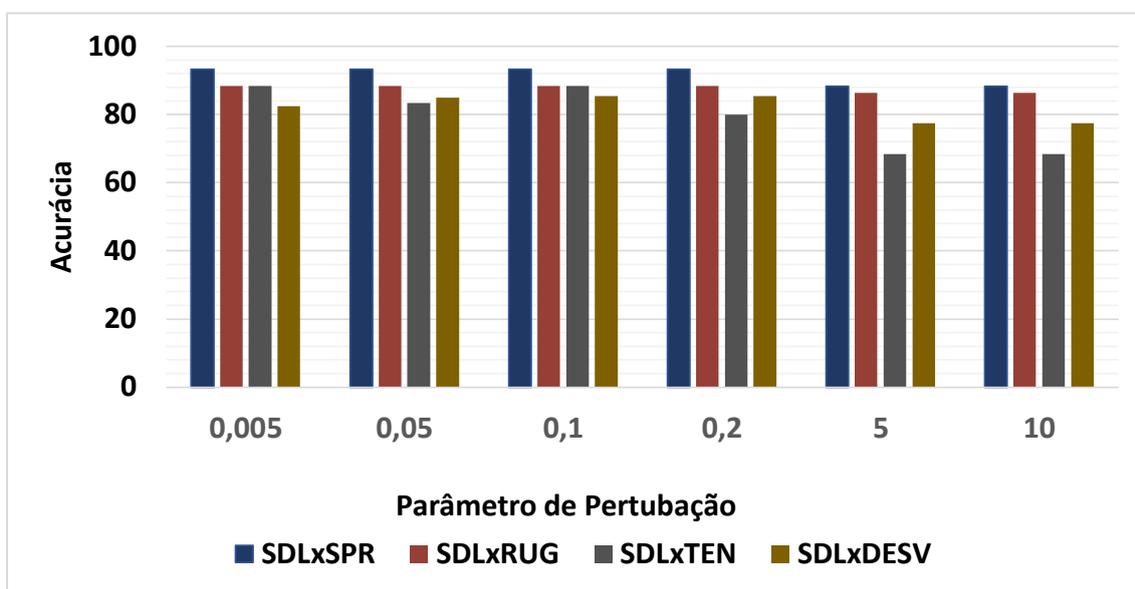
características são selecionadas.

Para a discriminação SDLxDESV, o resultado no valor da acurácia permanece constante e igual a 85%. Com isso, o melhor resultado, 85% de acurácia e menor custo de processamento, ocorre no valor de parametrização de Limite Máximo igual a 4, quando 4 características são selecionadas.

4.2.3 Parâmetro de Perturbação

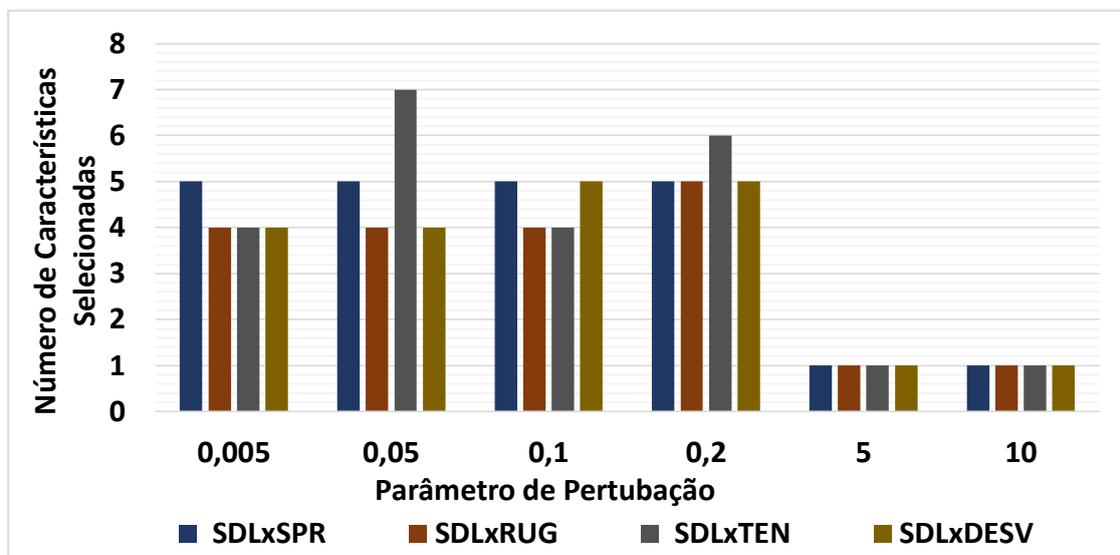
Os resultados obtidos para os quatro casos de classificação dos sinais: SDLxSPR, SDLxRUG, SDLxTEN e SDLxDESV, referente ao parâmetro da aplicação Parâmetro de Perturbação, estão apresentados nas Figuras 15 e 16 a seguir.

Figura 15 - Acurácia x Parâmetro de Perturbação.



Fonte: Autoria Própria.

Figura 16 - Número de Características x Parâmetro de Perturbação.



Fonte: Autoria Própria

Para a classificação SDLxSPR, os valores de acurácia permanecem constantes e iguais a 93,33% (melhor resultado) nos intervalos de 0,005 a 0,2 de valor para o Parâmetro de Perturbação (Fig. 15). Para este mesmo intervalo de parametrização 5 características são selecionadas (Fig. 16), o que permite concluir que o melhor índice de parametrização para este caso de classificação é de 0,2 pelo critério de menor custo de processamento da aplicação.

Na discriminação SDLxRUG, os valores de acurácia permanecem constantes e iguais a 88,33% (melhor taxa) nos intervalos de 0,005 a 0,2 de valor para o Parâmetro de Perturbação (Fig. 15). Observa-se, também que quando o Parâmetro de Perturbação está no intervalo de valores de 0,05 a 0,1 apenas 4 características são selecionadas (Fig. 16), o que permite concluir que o melhor índice de parametrização para este caso de classificação é de 0,1.

Já para a discriminação SDLxTEN, os valores de acurácia permanecem constantes e iguais a 88,33% (melhor taxa) nos intervalos de 0,005 a 0,1 de valor para o Parâmetro de Perturbação (Fig. 15). Quando o valor deste parâmetro é de 0,1 são selecionadas apenas 4 características (Fig. 16), concluindo-se que o melhor índice de parametrização, para este caso de classificação, é de 0,1.

Para o caso de classificação SDLxDESV, para valores de Parâmetro de Perturbação igual a 0,2 ou 0,1 obtém-se as melhores taxas de acurácia de 85,5% (Fig. 15) e 5 características são selecionadas (Fig. 16), concluindo-se que o melhor índice de parametrização para este caso de classificação é de 0,2.

4.3 Avaliação das Características

As características obtidas a partir da análise de quantificação de recorrência foram avaliadas quanto ao seu grau de relevância na discriminação entre os sinais de vozes saudáveis e com desvios vocais. Para tanto, foram calculados a porcentagem de ocorrência de cada uma das quinze medidas empregadas, considerando as 400 simulações.

Na Figura 17 é apresentada a porcentagem de ocorrência das características nas simulações realizadas. No caso da classificação para a classe de sinais SDLxRUG, as medidas selecionadas como mais significativas foram: passo de reconstrução (τ) com 41% de incidência; dimensão de imersão (m) com 72% de incidência; determinismo com 69% de incidência e; entropia de Shannon com 66% de incidência nas simulações.

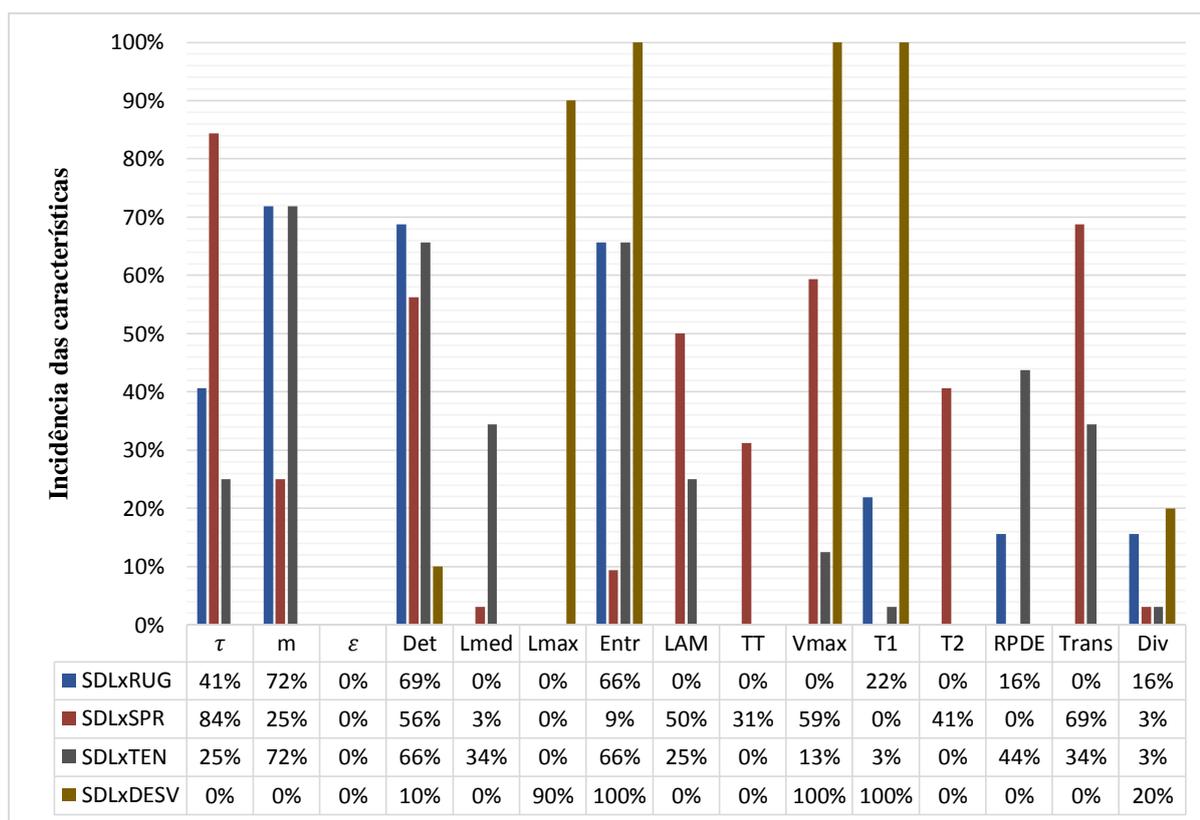
Na discriminação SDLxSPR, as medidas selecionadas como mais significativas são: passo de reconstrução (τ) com 84% de incidência, transitividade com 68% de incidência, determinismo com 56% de incidência, comprimento máximo das estruturas verticais com 59% de incidência e laminaridade com 50% de incidência nas simulações.

Já para separação das classes de sinais SDLxTEN, observa-se que as medidas selecionadas como mais significativas são: dimensão de imersão (m) com 72% de incidência; determinismo com 66% de incidência; entropia de Shannon com 66% de incidência e; entropia do tempo recorrência do tipo 1 com 44% de incidência nas simulações.

Para a classe de sinal SDLxDESV as características mais significativas são: comprimento máximo das linhas diagonais com 90% de incidência; entropia de Shannon com 100% de incidência; comprimento máximo das estruturas verticais com 100% de incidência e; tempo de recorrência tipo 1 com 100% de incidência nas simulações.

Observa-se que a medida do raio de vizinhança (ϵ) não ocorre em nenhum dos casos de classificação, podendo ser retirada do vetor de características.

Figura 17 - Incidência das características.



Fonte: Autoria Própria

4.4 Análises Estatísticas das Características

O *boxplot*, ou gráfico de caixa, é um gráfico utilizado para avaliar a distribuição empírica de dados. A caixa do *boxplot* é construída paralelamente ao eixo da escala dos dados (pode ser horizontal ou vertical). Essa caixa vai desde o primeiro quartil até o terceiro quartil e nela forma-se uma linha na posição da mediana na qual está contida os 50% dos dados centrais da distribuição. O *boxplot* é constituído por:

- Valor mínimo;
- Primeiro quartil (Q1);
- Mediana (segundo quartil Q2);
- Terceiro quartil (Q3);
- Valor máximo.

Nesta pesquisa, gráficos do tipo *boxplot* foram produzidos com o objetivo de realizar a análise individual da relevância em termos de representatividade e poder discriminativo das medidas de quantificação de recorrência aqui trabalhadas. Com isso será possível comprovar a representatividade das características selecionadas como mais relevantes pelo algoritmo ABC. Na Figura 18 estão ilustrados os valores médios das 15

medidas (isoladas) de quantificação de recorrência aplicadas na pesquisa.

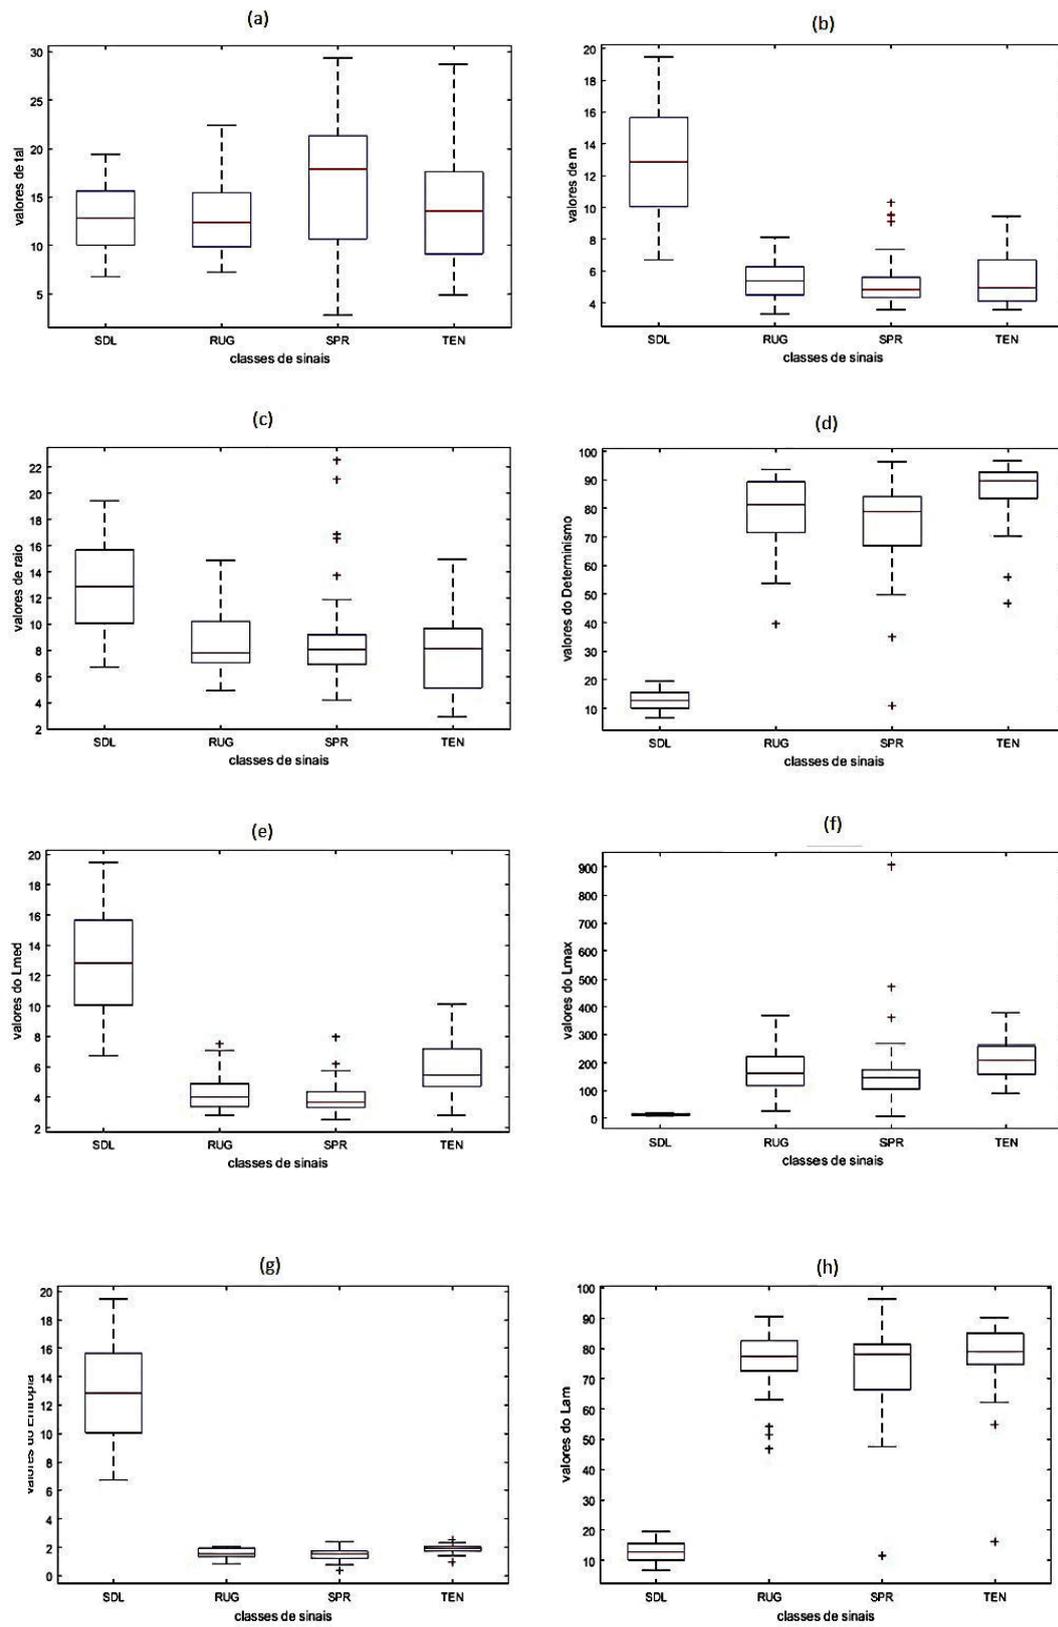
A Figura 18 é composta pelos *boxplots*, para todas as classes de sinais analisadas, das seguintes medidas: (a) Passo de reconstrução (τ); (b) Dimensão de imersão; (c) Raio de vizinhança; (d) Determinismo; (e) Comprimento médio das linhas diagonais; (f) Comprimento máximo das linhas diagonais; (g) Entropia de Shannon; (h) Laminaridade; (i) Comprimento médio das estruturas verticais; (j) Comprimento máximo das estruturas verticais; (l) Tempo de Recorrência do Tipo 1; (m) Tempo de Recorrência do Tipo 2; (n) Entropia do tempo de recorrência do tipo 1; (o) Transitividade e (p) Divergência.

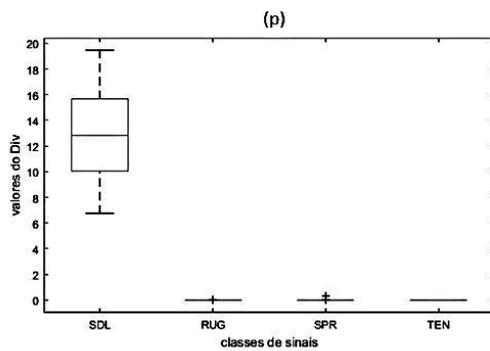
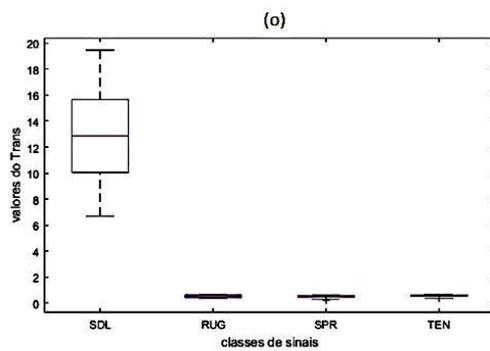
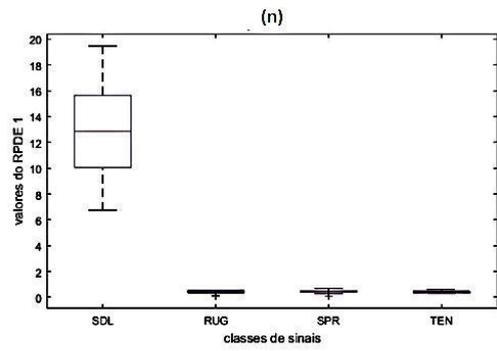
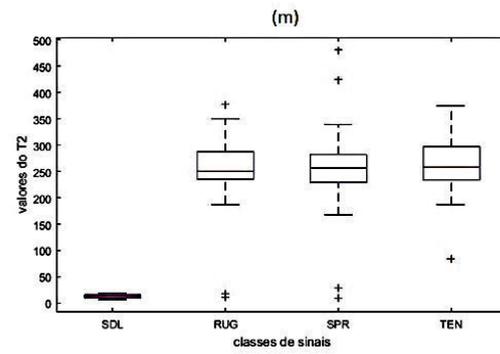
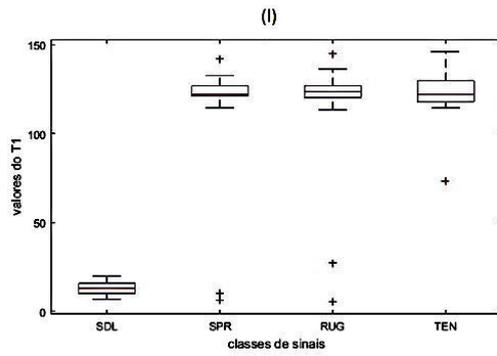
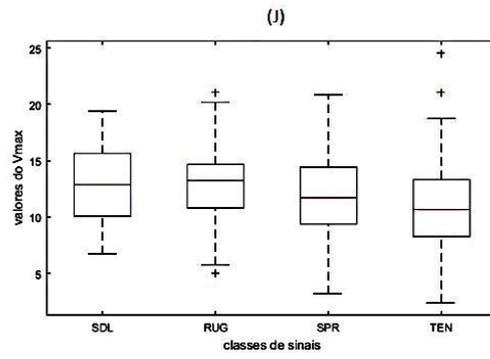
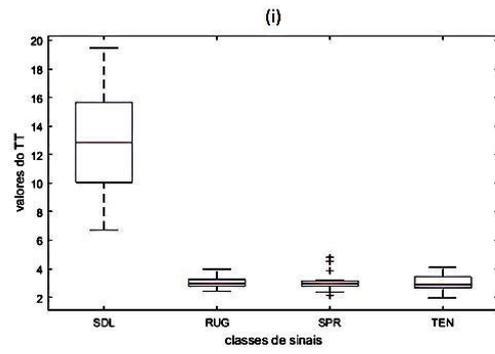
Para separação entre sinais de vozes saudáveis e sinais com vozes com desvio vocal, apenas as características de passo de reconstrução (τ) (ver Figura 15 (a)) e comprimento máximo das estruturas verticais (ver Figura 15 (i)), não mostram diferenças estatísticas que possam discriminar os sinais como saudáveis ou patológicos.

Observa-se nos gráficos da Figura 15 (*d* a *g*), que as características determinismo, comprimento máximo das linhas diagonais, comprimento médio das linhas diagonais e entropia de Shannon apresentam relevância classificatória para as classes de sinais compostas por sinais rugosos e tensos.

As medidas: passo de reconstrução e comprimento máximo das estruturas verticais, isoladamente analisadas, não são capazes de discriminar os sinais de vozes saudáveis dos sinais com desvios vocais. Entretanto, quando analisadas em conjunto por meio do algoritmo ABC, a medida comprimento máximo das estruturas verticais apresenta-se como perfeitamente capaz de discriminar casos de classificação de sinais de vozes saudáveis e com desvios vocais. Isso é explicado pelo fato de características de um dado sinal apresentar potencial de discriminação diferenciado quando avaliadas de forma isolada ou em conjunto. Ou seja, uma característica quando trabalhada isoladamente pode parecer relevante, mas quando analisada em conjunto com outras características pode se tornar irrelevante. Por outro lado, uma característica analisada de forma isolada, pode apresentar pouco ou nenhum poder de discriminação, mas quando analisadas em conjunto com determinadas características pode se tornar potencialmente discriminatória, quando suas informações se complementam, sem ou com pouca redundância.

Figura 18 - Gráficos *Boxplot* das características individuais.





Fonte: Autoria Própria.

4.5 Comparação com outros Métodos

A Tabela 4 mostra a comparação entre a acurácia obtida quando é aplicado o algoritmo ABC com a acurácia obtida pelo classificador K-NN. O algoritmo ABC melhora a acurácia de classificação em 11,66% para os casos de classificação SDLxRUG, em 3,33% para os casos de classificação SDLxSPR e 36,66% para os casos de classificação SDLxTEN.

Tabela 4 - Comparação entre os resultados de classificação sem e com o algoritmo ABC.

Casos de classificação	Acurácia (%)		Características Seleccionadas com ABC
	Sem ABC	Com ABC	
SDLxRUG	81,67	93,33	5
SDLxSPR	85,00	88,33	4
SDLxTEN	51,67	88,33	4

Fonte: Autoria Própria.

Com as características seleccionadas, foi avaliado o desempenho do classificador SVM. Na Tabela 5 é apresentada a comparação com os resultados de índices de acurácia referentes a três casos de classificação: SDLxSPR, SDLxRUG e o SDLxTEN, com o classificador KNN e o classificador SVM. A análise usando o classificador SVM foi realizada junto à biblioteca *weka*. A comparação foi realizada levando em consideração os melhores índices adquiridos para cada tipo de caso de classificação, tanto com o classificador KNN como para o classificador SVM.

Os resultados demonstram a superioridade do KNN em relação ao SVM, uma vez que os índices de acurácia adquiridos com SVM se igualam aos índices adquiridos pelo KNN somente no caso de classificação SDLXSPR.

Tabela 5 - Comparação entre os classificadores KNN e SVM.

Classificadores	Acurácia	Acurácia	Acurácia
	SDLXRUG (%)	SDLXSPR (%)	SDLXTEN (%)
KNN	93,33	88,33	88,33
SVM	78,33	88,33	70,00

Fonte: Autoria Própria.

Com o objetivo de comparar o algoritmo ABC proposto com outros métodos que também realizaram a seleção de características em sinais de voz, é apresentada, a seguir, uma explicação sucinta a respeito dos trabalhos escolhidos para comparação.

Nas Tabelas 6, 7 e 8 é mostrada a comparação dos resultados obtidos na pesquisa com Souza (2017).

Para a classificação SDLxSPR, mostrado na Tabela 6, a aplicação com o algoritmo ABC reduz a dimensionalidade do vetor de características de 15 para no máximo 5 e mínimo de 1, o que indica a superioridade do método ABC para redução de dimensionalidade, em relação ao NBPSO. Quanto ao valor da acurácia, o método ABC apresenta valores superiores ou competitivos em relação ao método comparado.

Tabela 6 - Classe de sinais SDLxSPR- Comparação com Souza (2017).

Método	Acurácia (%)	Quantidade de Características selecionadas
ABC	88,33 a 93,33	1 a 5
NBPSO	93,33 ± 3,7	10

Fonte: Autoria Própria.

Para a classificação SDLxRUG, mostrado na Tabela 7, a aplicação com ABC reduz a dimensionalidade do vetor de características de 15 para no máximo 5 e no mínimo de 1 característica selecionada, o que indica que o método ABC é mais eficiente que o método NBPSO. Quanto ao valor da acurácia, o método ABC apresenta valores inferiores em relação ao método comparado.

Tabela 7 - Classe de sinais SDLxRUG - Comparação com Souza (2017).

Método	Acurácia (%)	Quantidade de Características selecionadas
ABC	86,66 a 88,33	1 a 5
NBPSO	93,33 ± 3,7	10

Fonte: Autoria Própria.

Para o caso de discriminação SDLxTEN, mostrado na Tabela 8, a aplicação com ABC reduz a dimensionalidade do vetor de características de 15 para máximo 7 e mínimo de 1, o que indica que o método ABC é superior ou competitivo em relação ao método NBPSO. Quanto ao valor da acurácia, o método ABC apresenta valores superiores ou competitivos em relação ao método comparado.

Tabela 8 - Classe de sinais SDLxTEN - Comparação com Souza (2017).

Método	Acurácia (%)	Quantidade de Características selecionadas
ABC	68,33 a 88,33	1 a 7
NBPSO	75,00 ± 2,8	7

Fonte: Autoria Própria.

De forma geral, pode ser observado que o método proposto apresenta resultados semelhantes ou superiores quando comparados com o método NBPSO.

Na Tabela 9 é apresentada a comparação dos resultados da aplicação com ABC e com Lopes *et al.* (2016). Na discriminação entre vozes saudáveis e desviadas, quando comparados os resultados desta pesquisa e os resultados obtidos em Lopes, *et al.* (2016), observa-se que os valores de acurácia obtidos com a aplicação proposta foram competitivos ou superiores, com taxas máximas de acurácia até 85,5% e 4 características selecionadas. Lopes *et al.* (2016) atingiu acurácia máxima de 83,27%, selecionando 8 características.

Tabela 9 - Sinais saudáveis x Sinal com Patologia – Comparação com Lopes *et al.* (2016).

Método	Acurácia (%)	Quantidade de Características selecionadas
ABC	68,33 a 88,33	1 a 7
Lopes et al. (2016)	71,59 a 87,30	8 a 14

Fonte: Autoria Própria.

V Conclusões

A seleção de características pode proporcionar melhores condições de reconhecimento de padrões, melhora a acurácia da classificação e de processamento do sinal preservando-se as características mais relevantes e eliminando aquelas que são redundantes.

Na literatura são encontradas diversas abordagens de seleção de características, entre elas os métodos bioinspirados, tais como Inteligência de enxames. O algoritmo de otimização Colônia Artificial de Abelhas é um promissor método para seleção de características e reconhecimento de padrões além de se mostrar de simples entendimento e de fácil implementação, relativamente aos outros algoritmos utilizados na literatura.

Observou-se que para sinais analisados, até o momento, especificamente com dimensionalidade de grau baixo, a configuração dos parâmetros de execução tornou-se pouco sensível.

A comparação com o trabalho de Souza (2017) mostrou que o algoritmo ABC apresenta resultados promissores, em termos de acurácia, sendo superiores ou no mínimo, competitivos. Em termos de redução de dimensionalidade do vetor de características, a abordagem proposta reduz significativamente o número de características necessárias para classificação do sinal entre saudável e sinal acometido por desvios vocais. Souza (2017) necessita de 10 características para classificação enquanto o método proposto utiliza apenas entre 4 e 7 características para atingir os mesmos objetivos com taxas de acurácia semelhantes. Com isso conclui-se também que a abordagem proposta apresenta custo de treinamento igual ou menor à abordagem de comparação.

Do mesmo modo, a comparação com o trabalho Lopes *et al.* (2016) confirmou a superioridade do método proposto, tanto em termos de acurácia como de redução da dimensionalidade do vetor de características.

A abordagem proposta também produz como resultado a incidência das características nas simulações realizadas, que traduz o nível de representatividade de cada uma das medidas para discriminação entre as classes de sinais propostas. Para esta análise não foi possível fazer comparação por que as demais pesquisas encontradas na literatura não trataram especificamente da incidência de cada característica, limitando-se apenas nos resultados de acurácia e número de medidas selecionadas.

Pode-se verificar que, para a classificação entre as classes de sinais SDLxRUG as características passo de reconstrução (τ), dimensão de imersão, determinismo e entropia de Shannon são suficientes e necessárias na classificação entre sinais saudáveis e patológicos. Neste caso de classificação a parametrização mais indicada corresponde a Iteração igual a 3, Limite Máximo igual a 2 e Parâmetro de Perturbação igual a 0,1.

Na discriminação entre as classes de sinais SDLXSPR, as características passo de reconstrução (τ), determinismo, comprimento máximo das estruturas verticais, laminaridade e transitividade são as mais relevantes e satisfatórias na discriminação dos sinais. Neste caso de classificação a parametrização mais indicada corresponde a Iteração igual a 7, Limite Máximo igual a 2 e Parâmetro de Perturbação igual a 0,2.

Para a separação das classes de sinais SDLxTEN, observou-se que as medidas mais importantes na determinação de classificação são as medidas de dimensão de imersão, determinismo, entropia de Shannon e entropia do tempo recorrência do tipo 1. Neste caso de classificação a parametrização mais indicada corresponde a Iteração igual a 20, Limite Máximo igual a 2 e Parâmetro de Perturbação igual a 0,1.

Já para a classificação SDLxDESV as características mais significativas e suficientes para determinar se um sinal de voz é saudável ou patológico são as características: comprimento máximo das linhas diagonais, entropia de Shannon, comprimento máximo das estruturas verticais e tempo de recorrência tipo 1. Neste caso de classificação a parametrização mais indicada corresponde a Iteração igual a 6, Limite Máximo igual a 4 e Parâmetro de Perturbação igual a 0,2.

A pesquisa demonstra que as características selecionadas para casos de classificação entre sinais saudáveis e sinais desviados, mesmo analisados de forma individual, apresentam potencial estatístico discriminativo entre as classes envolvidas e são verdadeiramente relevantes.

Neste trabalho, quinze medidas da análise de quantificação de recorrência, foram avaliadas por meio do método de seleção de características baseado no algoritmo Colônia Artificial de Abelhas para otimizar o diagnóstico de desvios vocais. De forma geral, houve uma redução na quantidade de características utilizadas na classificação, de 15 para até 7 (pior caso), com taxas de acurácia superiores a 85%, taxas consideradas pelos fonoaudiólogos como índice confiável de classificação.

5.1 Contribuições da Pesquisa

1. Aplicação do Algoritmo ABC em sinais de voz para seleção de características;
2. Obtenção da incidência das características em sinais de voz, o que norteia a importância de cada uma para avaliação da qualidade vocal;
3. Redução da dimensionalidade do vetor de características em sinais de voz;
4. Obtenção de índices de acurácia satisfatório na classificação das características dos sinais de voz.

Como trabalhos futuros sugere-se: o desenvolvimento de sistema automático de classificação vocal voltado ao estudo e ao diagnóstico de desordens vocais com base nas características selecionadas como mais relevantes; a utilização de outras características dos sinais de vozes obtidas da análise linear ou não linear de sinais de voz, com abordagens tanto no domínio do tempo quanto da frequência, com o intuito de aumentar a precisão no diagnóstico.

Referências

- ABE, S. **Support Vector Machines**. 2^a. ed. New York: Springer, 2010.
- AL-NASHERI, A. et al. An investigation of Multidimensional Voice Program Parameters in three different databases for voice pathology detection and classification. **Journal of Voice**, v. 31, n. 1, p. 113-118, January 2017.
- B., S.; RAJALAXMI, R. R. Artificial Bee Colony based Feature Selection for Effective Cardiovascular Disease Diagnosis. **International Journal of Scientific & Engineering Research**, v. 5, n. 5, p. 606-612, May 2014.
- BRANDI, E. A qualidade vocal. In: BRANDI, E. **Educação da voz falada – a terapêutica da conduta vocal**. São Paulo: Atheneu, v. 4, 2002. p. 157-92.
- COELHO, L. D. S.; COELHO, A. A. R. Algoritmos Evolutivos em Identificação e Controle de Processos. **SBA Controle & Automação**, v. 10, n. 01, p. 13-30, Janeiro 1999.
- COLTON, R. H.; CASPER, J. K.; LEONARD, R. **Understanding voice problems: A physiological perspective for diagnosis and treatment**. [S.l.]: Wolters Kluwer Health, v. 4, 2006.
- COSTA, S. L. D. N. C. **Análise Acústica, Baseada no Modelo Linear de Produção da Fala, para Discriminação de Vozes Patológicas**. Tese (Doutorado em Eng. Elétrica) - Dep. de Engenharia Elétrica, Universidade Federal de Campina Grande. Campina Grande, p. 161. 2008.
- COSTA, W. C. D. A. **Análise dinâmica não linear de sinais de voz para detecção de patologias laríngeas**. Tese (Doutorado em Eng. Elétrica) - Dep. de Engenharia Elétrica, Universidade Federal de Campina Grande. Campina Grande, p.176 . 2012.
- COSTA, W. C. D. A. et al. 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, n. 1, p. 3-14, Março 2013.
- DAS, S. Filters, Wrappers and a Boosting-Based Hybrid for Feature Selection. **18th International Conference on Machine Learning**, Williamstown, MA, 01 June/July 2001. 74–81.
- DING, C. Spectral and wavelet-based feature selection with particle swarm optimization

for hyperspectral classification. **Journal of Software**, v. 6, n. 7, p. 1248-1256, July 2011.

ECKMANN, J. P.; KAMPHORST, S. O.; RUELLE, D. Recurrence plots of dynamical systems. **Europhys Letters**, v. 56, n. 5, p. 973–977, 1987.

FECHINE, J. M. **Reconhecimento Automático de Identidade Vocal Utilizando Modelagem Híbrida: Paramétrica e Estatística**. Tese (Doutorado em Processamento da Informação) - Centro de Ciências e Tecnologia Campus II, Universidade Federal da Paraíba. Campina Grande, p. 237. 2000.

FERREIRA, E. J.; JORGE, L. A. D. C. Seleção de Características Aplicadas ao Processamento de Imagens Digitais. **Embrapa Instrumentação Agropecuária**, v. 33, Nov 2007. ISSN 1518-7179.

FORSATI, R.; MOAYEDIKIA, A.; KEIKHA, A. A novel approach for feature selection based on the bee colony optimization. **International Journal of Computer Applications (IJCA)**, v. 43, n. 8, p. 30–34, April 2012.

FRISH, V. K. **The Dancing Bees: An Account of the Life and Senses of Honey Bee**. Harcourt: Brace, 1953.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**. 3^a. ed. [S.l.]: Pearson, 2010.

HALL, M. et al. Weka. The University of Waikato. **Weka**, 2016. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 10 Junho 2017.

JARBOUI, B. et al. Combinatorial particle swarm optimization (CPSO) for partitional clustering problem. **Applied Mathematics and Computation**, v. 192, n. 2, p. 337–345, Sept. 2007.

JIANG, J. . Z. Y. . M. C. Chaos in voice, from modeling to measurement. **Journal of Voice**, v. 20, n. 1, p. 2–17, 2006.

JOLLIFFE, I. T. **Principal Component Analysis**. [S.l.]: Springer, 2002.

KARABOGA, D. A. A. B. A comparative Study of Artificial Bee Colony algorithm. **Applied Mathematics and Computation**, v. 214, p. 108–132, 2009.

KARABOGA, D.; AKAY, B. A Modified Artificial Bee Colony Algorithm for Real Parameter Optimization. **Information Sciences**, v. 192, p. 120–142, June 2012.

KOHAVI, R.; JOHN, G. H. Wrappers for Feature Subset Selection. **Artificial**

- Intelligence - Special issue on relevance**, v. 97, n. 1-2, p. 273–324, Dec. 1997.
- LINDAUER, M.; FRISCH, V. The Language and Orientation of the Honey Bee. **Annual Review of Entomology**, v. 1, p. 45–58, January 1956.
- LIU, H.; SETIONO, R. A Probabilistic Approach to Feature Selection - A Filter Solution. **13th International Conference on Machine Learning**, 1996. 319-327.
- LIU, H.; YU, L. Toward Integrating Feature Selection Algorithms for Classification and Clustering. **IEEE Transactions on Knowledge and Data Engineering**, v. 17, n. 4, p. 491– 502, March 2005.
- LIU, Y. et al. An improved particle swarm optimization for feature selection. **Journal of Bionic Engineering**, v. 8, n. 2, p. 191-200, June 2011.
- LOPES, L. W. et al. Effectiveness of recurrence quantification measures in discriminating patients with and without voice disorders. **10th International Conference on Voice Physiology and Biomechanics**, Viña del Mar, 2016. 14-17.
- MARWAN, N. **Encounters with Neighbours - Current Developments of Concepts Based on Recurrence Plots and Their Applications**. University of Potsdam. [S.l.], p. 159. 2003.
- MITCHELL, T. **Machine Learning**. [S.l.]: McGraw Hill, 1997.
- NAGHIBI, T.; HOFFMANN, S.; PFISTER, D. Convex Approximation of the NP-Hard Search Problem in Feature Subset Selection. **IEEE International Conference on Acoustics, Speech and Signal Processing**, Vancouver, 26-31 May 2013. 3273–3277.
- OTT, E.; SAUER, T.; A.,. **Coping With Chaos: Analysis of Chaotic Data and the Exploitation of Chaotic Systems**. 6. ed. Tallahassee: IIE Transactions, v. 28, 1994.
- PALANISAMY, S.; KANMANI, S. Artificial Bee Colony Approach for Optimizing Feature Selection. **International Journal of Computer Science**, v. 9, n. 3, p. 432-438, May 2012a.
- PALANISAMY, S.; KANMANI, S. Classifier Ensemble Design using Artificial Bee Colony based Feature Selection Ensemble. **International Journal of Computer Science (IJCSI)**, v. 9, n. 2, p. 522–529, May 2012b.
- QUEIROZ, G. K. L. P. D. **Análise Dinâmica não Linear e Análise de Quantificação de Recorrência Aplicadas na Classificação de Desvios Vocais**. Dissertação (Mestrado em Eng. Elétrica) - Dep. de Engenharia Elétrica, Instituto Federal da Paraíba. João

Pessoa, p. 105. 2017.

RAJAMOZHANA, S. P.; UMAMAHESWARI, D. K. Feature Selection using Binary Artificial Bee Colony for Sentiment Classification. **International Research Journal of Engineering and Technology**, v. 3, n. 12, p. 510-514, Dec 2016.

ROSA, M. D. O. **Laringe Digital**. Tese (Doutorado em Eng. Elétrica) - Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, p. 279. 2002.

RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel distributed processing: explorations in the microstructure of cognition**, vol. 1. [S.l.]: Cambridge, v. 1, 1986.

S., S. P. A. K. Artificial Bee Colony Approach for Optimizing Feature Selection. **International Journal of Computer Science (IJCSI)**, v. 9, n. 3, p. 432–438, 2012.

SCHIEZARO, M. **Seleção de Características Baseada no Algoritmo de Colônia Artificial de Abelhas**. Dissertação (Mestrado em Ciência da Computação) - Instituto de Computação, Universidade Estadual de Campinas. Campinas, p. 65. 2014.

SEELEY, T. D. **Honeybee Ecology: A Study of Adaptation in Social Life**. Princeton University Press. Princeton, p. 212. 1985.

SEIJAS, L. M. et al. Metaheuristics for Feature Selection in Handwritten Digit Recognition. **Latin America Congress on Computational Intelligence**, Curitiba, 13-16 Oct 2015. 1-6.

SERAPIÃO, A. B. D. S. Fundamentos de Otimização por Inteligência de Enxames: uma Visão Geral. **Revista Controle & Automação**, Natal, v. 20, n. 3, p. 271 – 304, July/Sept 2009.

SHANTHI, S.; BHASHARAM, 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)**, v. 3, n. 6, p. 1664-1667, June 2014.

SHELOKAR, P. S.; JAYARAMAN, V. K.; KULKARNI, B. D. An ant colony approach for clustering. **Analytica Chimica Acta**, v. 509, n. 2, p. 187–195, May 2014.

SOUZA, E. G. **Caracterização de sistemas dinâmicos através de gráficos de recorrência**. Dissertação (Mestrado em Física) - Setor de Ciências Exatas, Universidade Federal do Paraná. Curitiba, p. 158. 2008.

SOUZA, E. G. **Caracterização de sistemas dinâmicos através de gráficos de**

recorrência. Dissertação (Mestrado em Física) - Setor de Ciências Exatas, Universidade Federal do Paraná. Curitiba, p. 105. 2008.

SOUZA, M. A. D. **Implementação de Algoritmos de Otimização Multiobjetivo baseados em PSO para a Seleção de Características.** Trabalho de conclusão de curso - Dep. de Engenharia Elétrica, Instituto Federal da Paraíba. João Pessoa. 2017.

SOUZA, T. A. et al. Feature selection based on binary particle swarm optimization and neural networks for pathological voice detection. **Latin America Congress on Computational Intelligence**, 2015. 1-6.

T. SUMATHI, S. K. A. M. M. Artificial bee colony optimization for feature selection in opinion mining. **Journal of Theoretical and Applied Information Technology (JTATIT)**, v. 66, n. 1, p. 368–379, Aug 2014.

TAKENS, F. Detecting strange attractors in turbulence, in Dynamical systems and turbulence. **Proceedings of a Symposium Held at the University of Warwick**, 1981. 366–381.

VARELLA, C. A. A. **Estimativa da produtividade e do estresse nutricional da cultura do milho usando imagens digitais.** Tese (Doutorado em Eng. Agrícola) - Dep. de Engenharia Agrícola, Universidade Federal de Viçosa. Viçosa, p. 106. 2004.

VIEIRA, V. D. J. **Avaliação de Distúrbios da Voz por meio de Análise de Quantificação de Recorrência.** Dissertação (Mestrado em Eng. Elétrica) - Dep. de Engenharia Elétrica, Instituto Federal da Paraíba. João Pessoa, p. 218. 2014.

ZENG, G.-C.; BAO, L. Comparison and Analysis of the Selection Mechanism in the Artificial Bee Colony Algorithm. **Ninth International Conference on Hybrid Intelligent Systems**, Shenyang, 1, 2-14 Aug 2009. 411–416.

ZHANG, C.; HU, H. Ant Colony Optimization Combining with Mutual Information for Feature Selection in Support Vector Machines. **18th Australian Joint Conference on Artificial Intelligence**, 2005. 918-921.