



RAPHAEL NAVES

**UM ESTUDO DE RECONHECIMENTO DE
SONS PULMONARES BASEADO EM
TÉCNICAS DE INTELIGÊNCIA
COMPUTACIONAL**

LAVRAS – MG

2015

RAPHAEL NAVES

**UM ESTUDO DE RECONHECIMENTO DE SONS PULMONARES
BASEADO EM TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

Orientador

Dr. Bruno Henrique Groenner Barbosa

Coorientador

Dr. Danton Diego Ferreira

LAVRAS – MG

2015

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Naves, Raphael.

Um estudo de reconhecimento de sons pulmonares baseado em técnicas de inteligência computacional / Raphael Naves. – Lavras : UFLA, 2015.

94 p. : il.

Dissertação(mestrado acadêmico)–Universidade Federal de Lavras, 2015.

Orientador: Bruno Henrique Groenner Barbosa.

Bibliografia.

1. Sons Pulmonares. 2. Reconhecimento de Padrões. 3. Estatísticas de Ordem Superior. 4. Algoritmos Genéticos. I. Universidade Federal de Lavras. II. Título.

RAPHAEL NAVES

**UM ESTUDO DE RECONHECIMENTO DE SONS PULMONARES
BASEADO EM TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

APROVADA em 03 de agosto de 2015.

Dr. Danton Diego Ferreira UFLA

Dr. Ricardo Rodrigues Magalhães UFLA

Dr. Augusto Santiago Cerqueira UFJF

Dr. Bruno Henrique Groenner Barbosa
Orientador

LAVRAS – MG

2015

Aos meus pais Sebastião e Irene.
Aos meus irmãos Regis e Natália.
Aos meus sobrinhos Tainá e Derek.
A minha tia Nazaré.

DEDICO

AGRADECIMENTOS

A Deus, por ter guiado meus passos e me dado forças para a realização deste trabalho.

Aos meus pais Irene e Sebastião, por todo amor, apoio e incentivo.

Aos meus irmãos Regis e Natália, por toda compreensão e apoio nas horas difíceis.

Aos meus sobrinhos Tainá e Derek, pela alegria de sempre.

À minha tia Nazaré, por toda a ajuda e apoio.

Ao Professor Bruno, pela excelente orientação, paciência, amizade, pelos seus ensinamentos que foram de grande relevância para a realização deste trabalho e meu crescimento profissional e pessoal.

Ao Professor Danton, pelos ensinamentos repassados a mim.

Agradeço à Universidade Federal de Lavras (UFLA) e ao Departamento de Engenharia (DEG), pela oportunidade concedida para a realização do mestrado.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos.

A todos que direta ou indiretamente contribuíram para a realização deste trabalho, o meu muito obrigado.

RESUMO

Este trabalho descreve o uso de técnicas da Inteligência Computacional visando à classificação de sons pulmonares em sons normais e adventícios. Os sons normais são auscultados em indivíduos saudáveis. Os sons adventícios são auscultados em indivíduos que possuem algum tipo de doença pulmonar e são classificados em duas categorias: sons contínuos (sibilos e roncos) e descontínuos (estertores). Cada um desses sons se relaciona com disfunções pulmonares fazendo com que sua classificação seja importante no auxílio ao diagnóstico clínico. Além disso, os sons pulmonares são sinais não-estacionários, o que os tornam difíceis de analisar e distinguir quando é utilizado um método de ausculta tradicional como o estetoscópio. Assim, o desenvolvimento de uma técnica que permita a classificação automática desses sons oferece uma alternativa para o profissional, podendo auxiliar no seu diagnóstico. Dessa forma, neste estudo, propõe-se o desenvolvimento de um classificador de sons pulmonares, utilizando Estatísticas de Ordem Superior (EOS) para extrair características, Algoritmos Genéticos e Análise Discriminante Linear para redução da dimensionalidade e Árvores de Decisão, k-vizinhos mais próximos, Classificador Bayesiano e Máquinas de Vetores Suporte para a classificação. As classes de sons pulmonares utilizadas são: normais, estertores finos, estertores grossos, sibilos monofônicos e sibilos polifônicos. Os resultados obtidos mostram que o uso de uma abordagem dividir para conquistar, utilizando os classificadores bayesiano e k-vizinhos mais próximos é mais adequada ao propósito de classificação de sons pulmonares, pois alcançou um melhor desempenho em comparação com o uso de apenas um classificador para resolver todo o problema. O resultado médio de acerto de classificação obtido pela abordagem foi de 91,1%, o que mostra a eficiência do método proposto.

Palavras-chave: Sons Pulmonares. Reconhecimento de Padrões. Estatísticas de Ordem Superior. Algoritmos Genéticos.

ABSTRACT

This work describes the use of Computational Intelligence techniques to classify pulmonary sounds from normal to adventitious. Normal sounds are auscultated in healthy subjects. Adventitious sounds are auscultated in subjects with lung disease, and are divided into two categories: continuous sounds (wheezes and rhonchus) and discontinuous sounds (crackles). Each is related to pulmonary dysfunctions, making it important to classify these sounds to support clinical diagnosis. In addition, pulmonary sounds are non-stationary signals, which makes them difficult to analyze and hard to distinguish when using traditional auscultation methods such as a stethoscope. Thus, the development of a technique to classify these sounds may aid professionals in performing clinical diagnosis. This study proposes the development of a pulmonary sound classifier using higher-order statistics (HOS) to extract features, Genetic Algorithms (GA) and Linear Discriminant Analysis to reduce dimensionality and Decision Trees, k-Nearest Neighbor, Bayesian Classifier and Support Vector Machines in order to classify pulmonary sound events. The pulmonary sound classes are: normal, fine crackles, coarse crackles, monophonic wheezes and polyphonic wheezes. The results obtained in this work revealed that the divide-and-conquer approach, employing k-Nearest Neighbor and Bayesian classifier, is most appropriate for the purpose of pulmonary sound classification, given that this approach achieved better performance in comparison with the use of only one classifier. The mean validation classification accuracy obtained by the divide-and-conquer approach was of 91.1%, which shows the efficiency of the proposed method.

Keywords: Pulmonary Sounds. Pattern Recognition. Higher-Order Statistics. Genetic Algorithm.

LISTA DE FIGURAS

Figura 1	Ausculta feita diretamente sobre o tórax	18
Figura 2	Criações de Laënnec. (1819). (a) estetoscópio, (b) tratado sobre sons pulmonares	19
Figura 3	Versão moderna do estetoscópio. (a) estetoscópio, (b) resposta em frequência	20
Figura 4	Sistema respiratório	22
Figura 5	Pontos de ausculta sobre o tórax. (a) Face anterior e (b) Face posterior	23
Figura 6	Sensibilidade limiar (medida em decibéis) do ouvido humano	24
Figura 7	Estertor grosso no domínio do tempo. 2CD: two-cycle duration; IDW: initial deflection width	27
Figura 8	Principais áreas e subáreas que englobam a Inteligência Computacional	32
Figura 9	Roleta viciada criada com base na avaliação de cada indivíduo	38
Figura 10	Operador de cruzamento em um ponto de corte	40
Figura 11	Etapas de um sistema de Reconhecimento de Padrões	42
Figura 12	Estrutura de dados baseada em árvore de decisão	49
Figura 13	Hiperplano de separação	50
Figura 14	Esquema de classificação pelo k-NN	52
Figura 15	Som pulmonar estertor grosso. Fases inspiratórias e expiratórias	61
Figura 16	Som pulmonar estertor grosso. Fases inspiratórias concatenadas	62
Figura 17	Som pulmonar estertor grosso. Segmentos de tamanho igual a 320 amostras	63
Figura 18	Segmentos de sinais pulmonares com 1600 amostras. (a) Sibilos Polifônicos e (b) Som Normal	64

Figura 19	Eventos de Sons Pulmonares. (a) Normal, (b) Estertor Fino, (c) Estertor Grosso, (d) Sibilos Monofônicos e (e) Sibilos Polifônicos.....	65
Figura 20	Cumulantes de 2ª, 3ª e 4ª ordem. (a) Normal, (b) Estertor Fino, (c) Estertor Grosso, (d) Sibilos Monofônicos e (e) Sibilos Polifônicos.....	67
Figura 21	Avaliação do indivíduo	69
Figura 22	Seleção dos cumulantes pela LDA (abordagem uma classe contra todas).....	74
Figura 23	Teste de Tukey (95% de confiança) dos resultados obtidos pelos classificadores: árvore de decisão, classificador bayesiano e k-NN. Os cumulantes foram selecionados por meio do AG.....	75
Figura 24	Árvore de classificação	79
Figura 25	Árvore de classificação SVM hierárquica.....	83

LISTA DE TABELAS

Tabela 1	Nomenclatura proposta pela ILSA para os diferentes sons adventícios em vários idiomas	26
Tabela 2	Sons adventícios	29
Tabela 3	Sons normais	30
Tabela 4	Tipos de representação cromossômica	37
Tabela 5	Classes utilizadas pela LDA	72
Tabela 6	Testes realizado com os classificadores: árvore de decisão, classificador bayesiano e k-NN. Resultados mostram acerto de classificação em porcentagem e seus respectivos desvios padrões	73
Tabela 7	Testes realizados com os classificadores: árvore de decisão, classificador bayesiano e k-NN	77
Tabela 8	Testes realizados entre as classes de sinais adventícios	78
Tabela 9	Matriz de confusão de desempenho em dados de validação	80
Tabela 10	Cumulantes selecionados	81
Tabela 11	Matriz de confusão de desempenho em dados de validação. Os resultados mostram o número de eventos e o respectivo desvio padrão classificado em cada classe. S. N. – som normal, E. F. – estertor fino, E. G. – estertor grosso, S. M. – sibilo monofônico, S.P. – sibilo polifônico, D.G. – desempenho geral	84

LISTA DE SIGLAS

AG	Algoritmos Genéticos
ATS	American Thoracic Society
CART	Classification and Regression Trees
COPD	Chronic Obstructive Pulmonary Disease
DS	Deterministic Sampling
EOS	Estatísticas de Ordem Superior
FD	Fractal Dimension
FOT	Forced Oscillation Technique
GAL	Grow and Learn
GARD	Global Alliance against Chronic Respiratory Diseases
GMM	Gaussian Mixture Model
HHS	Hilbert–Huang spectrum
HHT	Hilbert Huang Transform
ICA	Independent Component Analysis
IDW	Initial deflection width
ILSA	International Lung Sounds Association
k-NN	k Nearest Neighbor
LDA	Linear Discriminant Analysis
MAR	Multivariate Autoregressive Models
MFCC	Mel Frequency Cepstral Coefficients
MLP	Multilayer Perceptron
OMS	Organização Mundial da Saúde
PCA	Principal Component Analysis
PSD	Power Spectral Density
RF	Random Forest

RNA	Redes Neurais Artificiais
ROC	Receiver Operating Characteristic
SAOS	Síndrome da apneia obstrutiva do sono
SSA	Singular Spectrum Analysis
SVD	Singular Value Decomposition
SVM	Support Vector Machines
TFR	Time–Frequency Representation
2CD	Two cycle duration

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Contextualização e Motivação	14
1.2	Objetivos	16
1.3	Estrutura do trabalho	17
2	REFERENCIAL TEÓRICO	18
2.1	Sons Pulmonares	18
2.1.1	O sistema respiratório e a ausculta pulmonar	21
2.1.2	Classificação dos sons pulmonares	25
2.2	Inteligência Computacional	30
2.2.1	Computação Evolucionária	33
2.2.1.1	Algoritmos Genéticos	35
2.3	Reconhecimento de Padrões	41
2.3.1	Pré-processamento dos dados	43
2.3.2	Extração de características	43
2.3.3	Redução da Dimensionalidade	45
2.3.4	Classificação	48
2.3.4.1	Árvores de Decisão	48
2.3.4.2	Máquinas de Vetores Suporte	49
2.3.4.3	k-vizinhos mais próximos – k-NN	51
2.3.4.4	Classificador Bayesiano	52
2.3.4.5	Dividir para conquistar	53
2.3.5	Trabalhos relacionados	55
3	METODOLOGIA DE DESENVOLVIMENTO	60
3.1	Materiais	60
3.2	Métodos	66
4	RESULTADOS E DISCUSSÃO	71
4.1	Abordagem dividir para conquistar	76
4.2	Uma abordagem SVM hierárquica	82
5	CONCLUSÃO	86
	REFERÊNCIAS	88

1 INTRODUÇÃO

1.1 Contextualização e Motivação

As doenças respiratórias consistem em uma das principais causas de morte no mundo, estando entre as prioridades globais propostas pela Organização Mundial da Saúde (OMS). Segundo a Aliança Global contra Doenças Respiratórias Crônicas (*Global Alliance against Chronic Respiratory Diseases - GARD*), das 36 milhões de mortes ocorridas no mundo em 2008, estima-se que 12% foram em razão das doenças respiratórias crônicas como asma, bronquite crônica, bronquiectasia, entre outras. Presume-se que essas doenças constituirão na quarta maior causa de mortes em 2030 (GLOBAL ALLIANCE AGAINST CHRONIC RESPIRATORY DISEASES, 2014).

Os sons respiratórios são ruídos produzidos, em razão da turbulência aérea da respiração juntamente com a vibração das estruturas pulmonares e são classificados em sons normais e adventícios (DALMAY et al., 1995). Os sons normais são produzidos pelo fluxo normal do ar que percorre as vias respiratórias. Os sons adventícios são superpostos aos sons normais e são produzidos, em decorrência de algum tipo de patologia ou doença pulmonar (LEHRER, 2004).

A ausculta, escuta dos sons internos do corpo, é uma técnica antiga que vem sendo empregada por médicos, desde vários séculos antes de Cristo (LEHRER, 2004). Alguns sinais físicos que hoje são reconhecidos foram observados primeiro pelos gregos, por meio dessa prática.

Em 1816, para auscultar os sons pulmonares, René Theophile Laënnec enrolou uma folha de papel como um cilindro e colocou uma extremidade no tórax do paciente e seu ouvido na outra. Laënnec chamou a invenção de estetoscópio, do grego *stethos*, "peito" e *skopein*, "olhar" (LAËNNEC, 1819).

Desde sua invenção, o estetoscópio foi definitivamente incorporado à prática médica. Por fornecer um exame rápido, não invasivo e de baixo custo, é o primeiro método utilizado para avaliar doenças respiratórias (LEHRER, 2004). Por outro lado, a ausculta dos pulmões, por meio desse aparelho, apresenta limitações, pois exige que o examinador seja treinado para ouvir e distinguir os sons normais e anormais gerados pelo corpo humano. Além disso, esse procedimento deve ser realizado em um ambiente com baixo nível de ruídos sonoros. É, portanto, um processo considerado subjetivo e impreciso que depende da experiência do especialista (GARCIA, 2002).

Por sua vez, os sons pulmonares são sinais cujas características variam no tempo (sinais não-estacionários), são considerados difíceis de analisar e distinguir, em decorrência dos diferentes níveis de intensidade do fluxo de ar que entra pelas vias aéreas, além da interferência dos sons cardíacos. Portanto, a identificação desses sons é de extrema importância em um diagnóstico, pelo fato de estarem relacionados às doenças pulmonares fatais como bronquite crônica, asma e pneumonia.

Dessa forma, em razão das limitações do estetoscópio e as dificuldades para detecção e reconhecimento dos sons pulmonares adventícios, vários pesquisadores têm aprimorado ou desenvolvido técnicas para classificar e separar esses sons, visando a um melhor diagnóstico e orientações para pacientes, contribuindo para um tratamento eficaz de doenças que podem acometer adultos e crianças (EARIS; CHEETHAM, 2000).

Neste contexto, têm sido propostas na literatura diferentes técnicas para filtragem, extração de características, separação e classificação de sons pulmonares, como k -vizinhos mais próximos (k *Nearest Neighbor* – k -NN) (ALSMADI; KAHYA, 2008; AMARAL et al., 2015; QUANDT et al., 2012; SERBES et al., 2013), Máquinas de Vetores Suporte (*Support Vector Machines* - SVM) (AMARAL et al., 2015; IÇER; GENGEÇ; 2014; JIN; SATTAR; GOH,

2014; KAHYA, 2015; LEE et al., 2012; SEN; SARAÇLAR), Análise Discriminante Linear (*Linear Discriminant Analysis - LDA*) (QUANDT et al., 2012), Redes Neurais Artificiais (KANDASWAMY et al., 2004; SERBES et al., 2013; SEZGIN et al., 2001), Transformada Wavelet (KANDASWAMY et al., 2004; QUANDT et al., 2012; SEZGIN et al., 2001; XIAO GUANG; BAHOURA, 2008) entre outros.

Visando a contribuir para uma melhor caracterização de sons pulmonares, propõe-se, neste trabalho, a pesquisa, análise e proposição de técnicas que visem à classificação automática desses sons. Assim, este estudo poderá auxiliar na tarefa de identificação dos sons pulmonares adventícios, estes que são considerados os mais relevantes no auxílio ao diagnóstico de problemas respiratórios.

1.2 Objetivos

Neste trabalho objetivou-se classificar os sons pulmonares em sons respiratórios normais e adventícios. Visa, assim, a contribuir para a obtenção menos subjetiva de informações sobre o estado clínico de pacientes.

Os objetivos específicos deste trabalho são relacionados a seguir:

- a) implementar e comparar diferentes ferramentas da Inteligência Computacional para a classificação de sons pulmonares;
- b) analisar o uso de Estatísticas de Ordem Superior – EOS (MENDEL, 1991) para a extração de características;
- c) propor um algoritmo para a redução do vetor de características de cada tipo de som pulmonar;
- d) desenvolver um sistema para auxiliar no diagnóstico dos pacientes que seja possível de implementação em um sistema embarcado.

1.3 Estrutura do trabalho

No Capítulo 2, é apresentado o referencial teórico, destacando o histórico dos sons pulmonares, sistema respiratório e sua classificação. Também, neste capítulo, serão apresentadas ferramentas de reconhecimento de padrões. No Capítulo 3, são apresentados os materiais e métodos, descrevendo o uso das ferramentas e técnicas utilizadas para a classificação dos sons pulmonares. No Capítulo 4, são apresentados os resultados. No Capítulo 5, são apresentadas as conclusões e trabalhos futuros.

2 REFERENCIAL TEÓRICO

Este capítulo é dedicado a uma revisão de alguns dos conceitos mais importantes para a compreensão dos sons pulmonares. Assim, são apresentados aspectos históricos, fisiológicos e patológicos relacionados a esses sons. Ainda, neste capítulo, são apresentadas algumas ferramentas da Inteligência Computacional e ferramentas para Reconhecimento de Padrões.

2.1 Sons Pulmonares

Desde a antiguidade, os médicos auscultam os sons de dentro do tórax em busca de sinais de doenças (LEHRER, 2004). Os primeiros sons característicos de patologias foram observados pelos gregos e até o século XIX eram detectados por meio do posicionamento do ouvido contra a parede torácica.

Até o século XIX, essa técnica foi a única forma de diagnosticar doenças pulmonares, por meio do posicionamento do ouvido diretamente sobre o tórax do paciente (Figura 1), mas esse método, além de inibir os pacientes, deixava o examinador em uma situação de desconforto (LEHRER, 2004; ROGUIN, 2006; YERNAULT; BOHADANA, 1995).



Figura 1 Ausculta feita diretamente sobre o tórax

Fonte: Pintura de Théobald Chartran (1849-1907).

Em 1816, o médico francês René Theophile Laënnec, para auscultar os sons pulmonares de uma paciente muito obesa fez uso de um cilindro de papel e colocou uma extremidade no tórax da paciente e seu ouvido na outra, percebendo que os sons se tornavam mais altos que a ausculta direta (WELSBY; PARRY; SMITH, 2003). Laënnec chamou a invenção de estetoscópio (LAËNNEC, 1819).

Posteriormente, a partir do aparelho de papel foi desenvolvido um estetoscópio cilíndrico de madeira com um orifício central (Figura 2a) e, em 1819, Laënnec publicou um tratado (Figura 2b), relacionando os sons pulmonares auscultados com os diagnósticos obtidos em necropsias (ROGUIN, 2006; SAKULA, 1981; WELSBY; PARRY; SMITH, 2003).

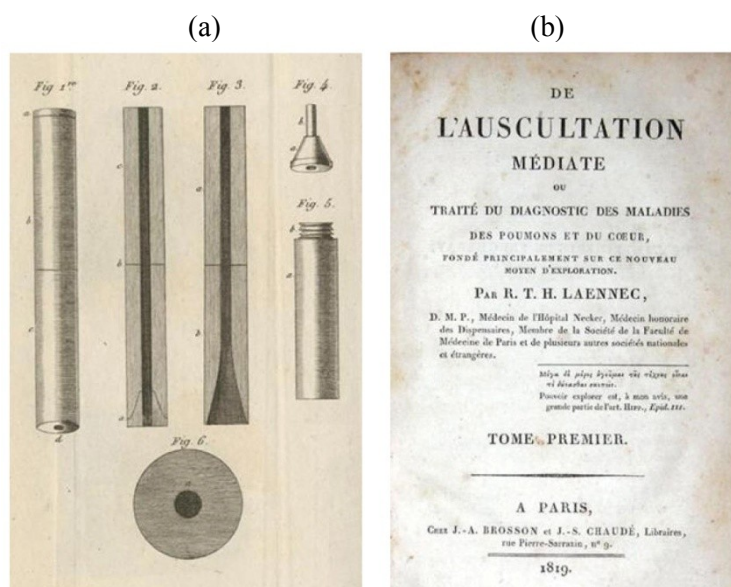


Figura 2 Criações de Laënnec. (1819). (a) estetoscópio, (b) tratado sobre sons pulmonares

Desde a sua invenção, o estetoscópio evoluiu muito no tempo. Na Figura 3, ilustra-se a versão moderna do estetoscópio e sua resposta em frequência. Ele

é formado por uma combinação de tubos (1), haste auricular dupla (2) com olivas para os ouvidos (3), diafragma (4) e campânula (5), descartando, assim, o modelo de cilindro mono auricular (LEHRER, 2004; ROGUIN, 2006).

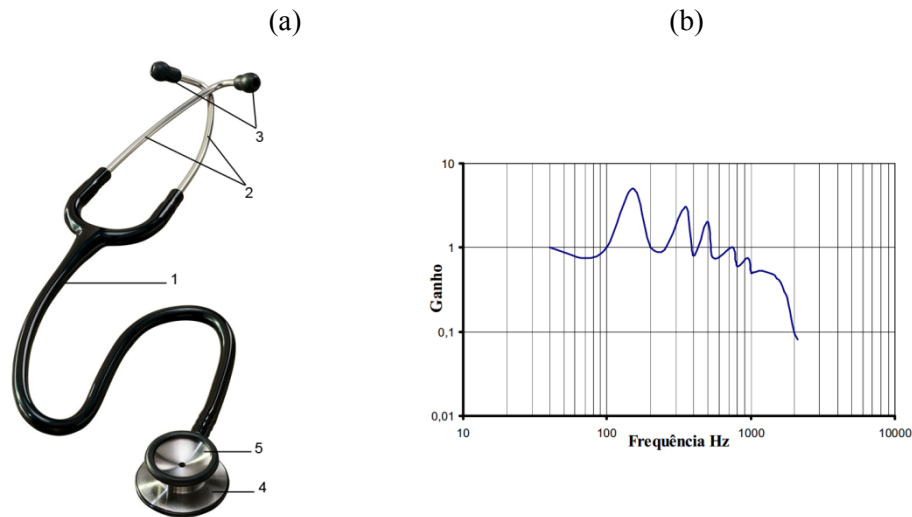


Figura 3 Versão moderna do estetoscópio. (a) estetoscópio, (b) resposta em frequência

Atualmente, o uso do estetoscópio em um consultório médico faz parte da rotina do especialista e é o primeiro método utilizado para avaliar doenças respiratórias (LEHRER, 2004). É um exame rápido que apresenta baixo tempo de resposta, é não invasivo e de baixo custo. Mas, por outro lado, apresenta muitas limitações, sendo considerado subjetivo e impreciso que depende da capacidade auditiva do especialista, pois se o mesmo não tiver treinamento adequado não será capaz de distinguir entre os sons normais e anormais gerados pelo corpo humano (GARCIA, 2002).

A limitação gerada pelo estetoscópio para diagnosticar doenças pulmonares faz com que muitos médicos utilizem de exames complementares

como raios-x, mas estes, de certa forma, deixam os pacientes expostos à radiação oferecendo riscos à saúde, mesmo que pequenos.

Portanto, o aperfeiçoamento de técnicas que podem ser utilizadas em equipamentos de baixo custo para diagnosticar doenças pulmonares tem motivado pesquisadores a desenvolver estratégias que visem a facilitar o diagnóstico clínico, contribuindo, assim, para um tratamento rápido e eficiente.

2.1.1 O sistema respiratório e a ausculta pulmonar

A principal função do sistema respiratório humano consiste na oxigenação dos tecidos e na retirada de gás carbônico do organismo (GUYTON; HALL, 2006).

Esse sistema é composto por um aparelho complexo que é formado pelas vias aéreas e pulmões e é responsável em levar o oxigênio das cavidades nasais até a estrutura pulmonar, onde ocorrem as trocas gasosas (GARCIA, 2002). Na Figura 4, ilustram-se as principais estruturas desse sistema: os pulmões, a traqueia, a glote e outras.

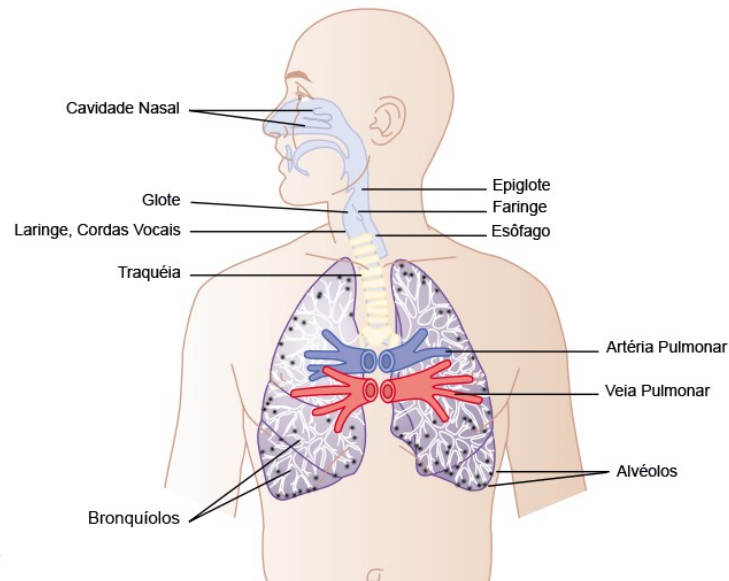


Figura 4 Sistema respiratório

Fonte: Adaptado de Guyton e Hall (2006).

Através da laringe as vias aéreas superiores (boca, cavidades nasais e faringe) são conectadas à traqueia. Nessa estrutura, encontram-se a epiglote, glote e as cordas vocais. Os alvéolos que se encontram por todo o pulmão, são minúsculos sacos cheios de ar localizados nas extremidades dos bronquíolos. Nessas estruturas, ocorre a hematose, que é o processo de trocas gasosas que consiste em transformar o sangue venoso (rico em gás carbônico) em arterial (rico em oxigênio) (GUYTON; HALL, 2006).

A respiração é dividida em dois movimentos, a inspiração e a expiração do ar atmosférico. Na inspiração, o ar penetra pelo nariz e chega aos pulmões fazendo com que os alvéolos se expandam, e na expiração o ar é forçado para fora dos alvéolos até a parte exterior (GUYTON; HALL, 2006).

Os sons pulmonares são ruídos produzidos durante a respiração (inspiração e expiração) e se originam, por meio das vibrações das estruturas

pulmonares e das vias aéreas que são transmitidas para a parede torácica. Essa parede é relativamente dura e heterogênea por conter músculos e também ossos, o que contribui de forma negativa para a transmissão dos sons (CARVALHO; SOUZA, 2007).

Para analisar esses sons, deve-se utilizar da ausculta, esta que consiste em examinar o tórax e tem por finalidade detectar sons normais e anormais produzidos pelos pulmões e vias aéreas. A técnica é realizada com o auxílio de um estetoscópio e deve-se movimentá-lo para frente e para trás entre as regiões de segmentos pulmonares comparáveis em cada lado do tórax (Figura 5) (LEHRER, 2004).




Figura 5 Pontos de ausculta sobre o tórax. (a) Face anterior e (b) Face posterior

Fonte: Lehrer (2004).

A sequência da auscultação deve ser realizada conforme é ilustrado na Figura 5. Primeiramente, deve-se realizar a ausculta na face anterior do tórax e, em seguida, na parte posterior, devendo ainda ser realizada de cima para baixo. Os números repetem-se do lado direito e do lado esquerdo, pois é fundamental

realizar sempre uma comparação, detectando assim possíveis anomalias respiratórias.

Cada região deve ser auscultada cuidadosamente, deve ser realizada com o paciente com o tórax desnudo para evitar a captação de sons produzidos pelas roupas e deve ser realizada em ambiente silencioso. A respiração deve ser realizada profundamente pela boca, e o examinador deve concentrar primeiro na fase da inspiração, analisando seus componentes normais e adventícios e, posteriormente, realizar a mesma análise na fase da expiração (LEHRER, 2004).

Porém, a maioria dos sons respiratórios cai em uma faixa de frequência na qual o ouvido humano é pouco sensível. O ouvido mediano jovem pode detectar vibrações sonoras com frequências entre 16 e 16000 Hz, podendo a sensibilidade variar muito nessa faixa. Na Figura 6, ilustra-se a sensibilidade limiar (medida em decibéis) do ouvido humano.




Figura 6 Sensibilidade limiar (medida em decibéis) do ouvido humano

Fonte: Adaptado de Lehrer (2004).

A sensibilidade máxima está na região de 1000 a 2000 Hz e abaixo de 1000 Hz ela cai drasticamente. Por exemplo, para ser audível, um tom com

frequência de 100 Hz deve ter uma pressão de som 100 vezes maior que a de um tom de 1000 Hz. Em decorrência do fato de a grande maioria dos sons respiratórios estar abaixo de 500 Hz, o ouvido humano torna-se pouco sensível a esses sons, não sendo escutados (LEHRER, 2004).

Dessa forma, o ouvido humano não consegue capturar o fenômeno sonoro em sua totalidade, pois a percepção de um som não depende apenas de sua frequência, mas também da intensidade com a qual o som é emitido, pois os sons mais graves necessitam ser mais intensos para serem audíveis.

Os pesquisadores Fletcher e Munson estudaram o fenômeno que se refere às características de resposta de frequência do ouvido humano. De acordo com os pesquisadores, quando os sons reproduzidos possuem frequências muito graves ou muito agudas é mais provável que esses sons sejam percebidos pelo ouvido como tendo menos intensidade do que os sons de frequências médias próximos da voz humana (LEHRER, 2004).

Ao ouvir os sons pulmonares, esse fenômeno não é um fator interferente quando se faz uso de um estetoscópio. No entanto, o fenômeno afeta a percepção dos sons registrados quando reproduzidos em um alto falante. Os sons parecerão para o ouvido como graves e estrondosos se comparados com os mesmos sons ouvidos pelo estetoscópio. Dessa forma, o estetoscópio torna-se parte indispensável na análise de sons pulmonares (LEHRER, 2004).

2.1.2 Classificação dos sons pulmonares

Como já mencionado anteriormente, no ano de 1819, foi publicado por Laënnec um tratado relacionando os sons pulmonares auscultados com os diagnósticos obtidos em necropsias que estabelecia relação entre os sons auscultados e enfermidades (ROGUIN, 2006; SAKULA, 1981; WELSBY; PARRY; SMITH, 2003).

Contudo, ao serem traduzidos em diferentes idiomas, os termos descritos por Laënnec foram modificados e surgiram diferentes terminologias. Logo, a necessidade de uma padronização das terminologias médicas foi necessária, em razão da ausência de uma nomenclatura comum. Isso fez com que, em 1987, a *International Lung Sounds Association* – ILSA, padronizasse uma nomenclatura respiratória para sons adventícios (Tabela 1) (MIKAMI et al., 1987).

Tabela 1 Nomenclatura proposta pela ILSA para os diferentes sons adventícios em vários idiomas

Tipo	Inglês	Português	Descrição
Descontínuo	<i>Fine Crackle</i>	Estertor Fino	Alta tonalidade, baixa amplitude e curta duração
Descontínuo	<i>Coarse Crackle</i>	Estertor Grosso	Baixa tonalidade, alta amplitude e longa duração
Contínuo	<i>Wheeze</i>	Sibilo	Alta tonalidade
Contínuo	<i>Rhonchi</i>	Ronco	Baixa tonalidade

Os sons estertores (*crackles*) podem ser definidos no domínio do tempo, em que se estabelece a duração do primeiro semiciclo positivo (*initial deflection width- IDW*) e a duração de dois ciclos (*two-cycle duration- 2CD*). Assim, os estertores podem ser classificados em grossos (sons de longa duração) e finos (sons de curta duração) (MIKAMI et al., 1987; SOVIJÄRVI et al., 2000). De acordo com a *American Thoracic Society* (AMERICAN THORACIC SOCIETY, 1977), a duração média do IDW e 2CD para estertores finos são 0,7ms e 5ms, respectivamente, e, para os estertores grossos, a duração é de 1,5ms e superior a 10ms para o IDW e 2CD, respectivamente. Na Figura 7, apresenta-se um estertor grosso com a representação dos parâmetros definidos pela ATS.




Figura 7 Estertor grosso no domínio do tempo. 2CD: two-cycle duration; IDW: initial deflection width

Fonte: Adaptado de Sovijärvi (2000).

Além dessa classificação, os estertores ainda podem ser descritos em relação à quantidade (escassos ou profusos) e em relação à fase (inspiratórios ou expiratórios, precoces ou tardios). São observados nos seguintes tipos de doenças respiratórias: bronquite crônica, bronquiectasia, fibrose intersticial, asbestose (LEHRER, 2004).

Esses sons são mais visíveis e intensos na inspiração e são produzidos, em decorrência da abertura repentina e explosiva de pequenas vias aéreas até então fechadas. Na expiração, eles ocorrem, em razão do fechamento dessas pequenas vias e podem ser ouvidos pela parede torácica e, algumas vezes, pela boca (LEHRER, 2004).

Laënnec observou que os sons estertores são semelhantes àqueles produzidos ao se esquentar sal em uma frigideira. Segundo Lehrer (2004), comparando a forma de onda dos dois sons, nota-se que são muito semelhantes.

Uma das causas mais aceitas de sua origem é quando uma seção das vias aéreas está fechada e se abre, abruptamente, em razão de uma rápida equalização de pressão do gás entre dois compartimentos do pulmão (FORGACS, 1967).

Já, os sibilos (*wheezes*) são, de acordo com a ATS, sons contínuos, musicais (combinações de ondas sonoras com um padrão definido) e definidos como sons agudos com frequência dominante acima de 400 Hz. Quando o sibilo possui uma única frequência, é denominado monofônico, se possui mais de uma frequência é denominado polifônico (SOVIJÄRVI et al., 2000).

Além dessa classificação, os sibilos ainda podem ser inspiratórios ou expiratórios, curtos ou longos e únicos ou múltiplos. O som característico dos sibilos se assemelha a um assobio e é chamado de contínuo pela sua duração superior a 100ms. Esses sons são observados nas seguintes doenças: asma, asbestose e fibrose intersticial.

Os sibilos são produzidos quando as vias aéreas se estreitam quase no ponto de fechamento, fazendo com que ocorram vibrações nas estruturas pulmonares, em decorrência da passagem do ar. Seu aparecimento ocorre, pela velocidade do ar que, quanto maior for, maiores serão as vibrações produzidas, e mais agudo será o som (FIZ et al., 2002).

Os sons do tipo roncos (*rhonchus*) são definidos pela ATS como sons graves com frequência dominante de 200 Hz ou menos. Podem ser ouvidos durante a inspiração e expiração e originam-se, em razão do estreitamento das paredes brônquicas da via aérea com secreção (SOVIJÄRVI et al., 2000). Esse tipo de som pode ser sintoma da síndrome da apneia obstrutiva do sono (SAOS), que se caracteriza pela parada respiratória com duração de pelo menos dez segundos nos adultos, e dois ou três segundos nas crianças.

Em relação aos sons respiratórios normais, é possível distinguir entre três tipos que podem ser ouvidos no tórax (VISICH, 1981):

- a) murmúrio vesicular: esse tipo de som é caracterizado como um suspiro ou murmúrio leve, é suave, possui baixa frequência e a fase inspiratória é mais longa que a fase expiratória;
- b) brônquico: esse tipo de som lembra o ar soprado em um tubo oco, é intenso e agudo e com uma pausa distinta entre as fases inspiratória e expiratória;
- c) broncovesicular: esse tipo de som é a mistura de sons brônquicos e vesiculares e suas fases inspiratória e expiratória são, praticamente, iguais.

Nas Tabelas 2 e 3, apresenta-se um resumo de todos os sons pulmonares descritos, assim como as doenças a eles relacionadas. Na Tabela 2, apresenta-se um resumo dos sinais adventícios. Na Tabela 3, apresenta-se um resumo dos sinais normais.

Tabela 2 Sons adventícios

SONS ADVENTÍCIOS			
Sons contínuos		Sons descontínuos	
Sibilos	Roncos	Estertores Finos	Estertores Grossos
*Musicais	*Baixa	*Alta tonalidade	*Baixa tonalidade
*Agudos	Tonalidade	*Baixa amplitude	*Alta amplitude
*Monofônico	*Graves	*Curta duração	*Longa duração
*Polifônico		*Explosivos	*Explosivos
*Inspiratórios		*Escassos	*Escassos
*Expiratórios		*Profusos	*Profusos
*Curtos		*Inspiratórios	*Inspiratórios
*Longos		*Expiratórios	*Expiratórios
*Únicos		*Precoces	*Precoces
*Múltiplos		*Tardios	*Tardios

“Tabela 2, conclusão”

SONS ADVENTÍCIOS			
Sons contínuos		Sons descontínuos	
Doenças: asma, asbestose, fibrose intersticial, pneumonia.	Doenças: síndrome da apneia obstrutiva do sono.	Doenças: asbestose, fibrose, pneumonia.	Doenças: bronquiectasia, bronquite, bronquite crônica.

Tabela 3 Sons normais

SONS NORMAIS		
Murmúrio Vesicular	Brônquico	Broncovesicular
*Suspiro/murmúrio leve *Suave *Baixa frequência *Fase inspiratória mais longa que fase expiratória	*Intenso *Agudo	*Mistura dos sons brônquicos e vesiculares

2.2 Inteligência Computacional

A Inteligência Computacional é um paradigma que compreende a teoria e aplicação de técnicas computacionais inspiradas na natureza. Esse modelo possui habilidades de aprender ou de lidar com novas situações, nas quais o sistema possui habilidades de reação, como generalizar, descobrir e abstrair. Isto é, procura desenvolver sistemas que apresentam formas de inteligência semelhantes aos apresentados por certos sistemas biológicos.

Esses sistemas tentam resolver problemas matemáticos e computacionais, utilizando a mesma estratégia que a natureza utiliza. Desse modo, surgiram então vários paradigmas que compõem a inteligência computacional baseados em computação natural, como as Redes Neurais

Artificiais (BISHOP, 1995), Lógica *Fuzzy* (COX, 1994) e Computação Evolucionária (EIBEN, 2002).

As Redes Neurais Artificiais (RNA) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura do neurônio do cérebro. Os neurônios artificiais recebem esse nome, pois foram originados com base em um modelo matemático de um neurônio biológico. As Redes Neurais se destacam por sua capacidade de aproximação universal e aprendizado, a partir de exemplos, simulando uma estrutura computacional paralela e interconectada, formada por vários elementos de processamento (BISHOP, 1995).

A Lógica *Fuzzy* é a lógica baseada no conceito de conjunto *fuzzy*. Esses conjuntos surgiram como uma maneira diferente de representar conceitos de imprecisão e incerteza. Os sistemas *fuzzy*, além de trabalhar com dados numéricos, também processam dados simbólicos, por meio de um conjunto de regras *fuzzy*. Diferente da lógica tradicional, a lógica *fuzzy* dá espaço ao meio termo, permitindo assim mensurar o nível de aproximação da solução exata e deduzir algo que seja necessário (COX, 1994).

A Computação Evolucionária é uma técnica que se baseia na teoria da evolução natural de Charles Darwin (EIBEN, 2002). Essa técnica tem sido muito aplicada em problemas de otimização e compreende diversos algoritmos inspirados no princípio da evolução das espécies. Esses algoritmos se baseiam em probabilidades e possuem um mecanismo de busca paralela e adaptativa baseado na reprodução das espécies e no princípio de sobrevivência dos mais aptos. O campo da computação evolucionária inclui algoritmos genéticos, programação evolutiva e estratégias evolutivas. Na Figura 8, ilustra-se o universo que incorpora as áreas de pesquisa da Inteligência Computacional.

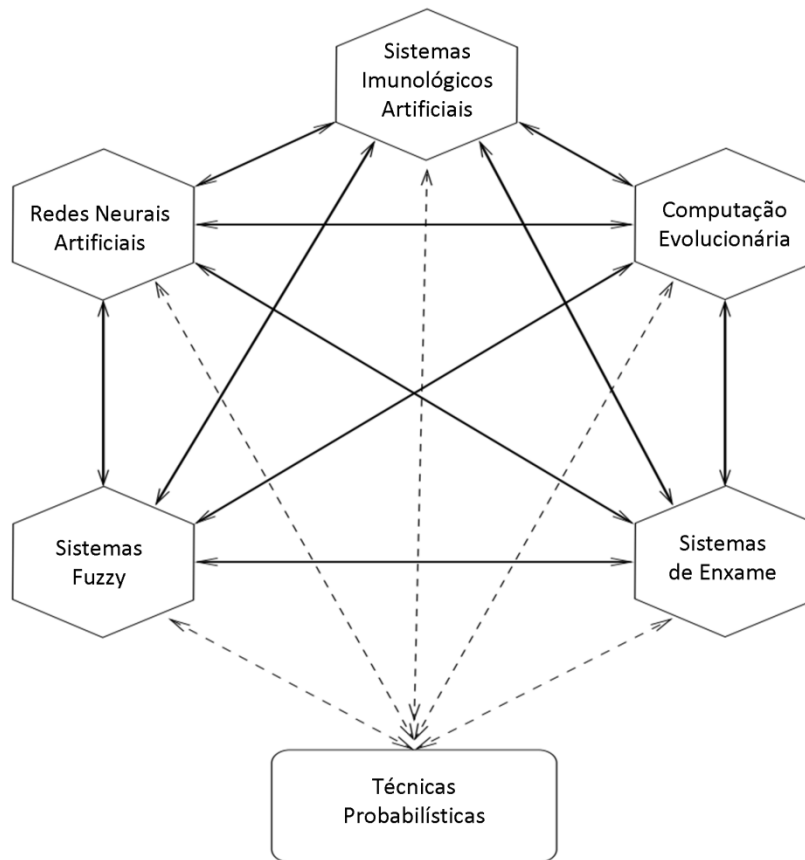


Figura 8 Principais áreas e subáreas que englobam a Inteligência Computacional

Fonte: Engelbrecht (2007).

Os paradigmas descritos acima vêm sendo utilizados com a finalidade de desenvolver sistemas eficientes, fáceis de manipular, robustos e com a capacidade de fornecer boas soluções para problemas complexos. São muito utilizados no desenvolvimento de sistemas inteligentes para previsões, reconhecimento de padrões, otimização, controle, etc., além de serem aplicados em diversos setores.

A seguir, alguns dos paradigmas da Inteligência Computacional que serão utilizados neste trabalho serão mais detalhados.

2.2.1 Computação Evolucionária

A computação evolucionária é um ramo da computação natural que surgiu nos anos 50 para propor uma forma eficiente de utilizar o processo de evolução natural como um paradigma de solução de problemas complexos, que apresentam um elevado espaço de busca. Nessa abordagem, objetivou-se a inspiração dos fenômenos que ocorrem na natureza, como a evolução das espécies e o comportamento adaptativo, ambos formalizados por Charles Darwin em sua teoria da evolução (EIBEN, 2002).

Os primeiros passos dados na área de computação evolucionária foram de biólogos e geneticistas atraídos pela ideia de simular os processos vitais de forma computadorizada, o que recebeu, na época, o nome de "processos genéticos". Dentre esses estudiosos, o biólogo Rosenberg realizou a simulação de uma população de seres unicelulares com cromossomos de 20 genes e 16 alelos em sua tese de doutorado no ano de 1967 (GOLDBERG, 1989).

Várias abordagens foram propostas para sistemas baseados na evolução, estas diferem uma da outra em relação aos operadores genéticos utilizados. As principais, segundo Gabriel e Delbem (2008) são: algoritmos genéticos, estratégias evolutivas e programação evolutiva.

Em cada um desses métodos, é inicializada uma população de indivíduos que evolui de forma sucessiva para melhores regiões no espaço de busca, por meio de um processo aleatório de seleção, mutação e cruzamento. Os métodos diferem entre si com relação à forma de mutação e seleção.

Ao passo que os algoritmos genéticos evidenciam os operadores cromossômicos de cruzamento e mutação, as estratégias evolutivas e a

programação evolutiva enfatizam a diversidade e a adaptação do comportamento dos pais para os seus descendentes em sucessivas gerações (NOGUEIRA; SAAVEDRA, 1999).

Os algoritmos genéticos (AG), propostos por Holland (1975), são modelos computacionais inspirados na teoria da evolução de Darwin, seguindo os princípios de seleção natural e reprodução das espécies. Esses algoritmos utilizam uma estrutura de dados como a de um cromossomo para modelar uma solução para um problema específico. Nesses algoritmos, operadores de recombinação são aplicados com a finalidade de preservar informações críticas. Os AG são muito utilizados para resolver problemas de otimização complexos ou que possuam espaço de busca muito grande.

As estratégias evolutivas, desenvolvidas por Rechenberg (1973) e Schwefel (1995), foram propostos para resolver problemas de otimização, sendo estendidas para tratamento de problemas discretos. Nesse paradigma, cada gene no cromossomo representa uma parte do problema e a geração de um novo descendente é feita, por meio da aplicação de um operador de mutação que possui distribuição de probabilidade Gaussiana, com a média zero e desvio padrão similar no pai (GABRIEL; DELBEM, 2008).

A programação evolutiva, desenvolvida por Fogel (1994), foi proposta para desenvolver uma forma alternativa de inteligência artificial. Nessa abordagem, cada indivíduo da população é denotado por um autômato (máquina de estados finitos), que consiste em processar uma sequência de símbolos. No decorrer do processo de avaliação, esses indivíduos são analisados por uma função de acordo com as saídas desse autômato e da solução esperada do problema. O processo de reprodução é realizado de forma assexuada, pois a reprodução se dá apenas por operadores de mutação. Assim, todos os indivíduos pertencentes à população atual geram novos descendentes (GABRIEL; DELBEM, 2008).

Essas abordagens evolutivas descritas acima possuem um algoritmo que apresenta uma estrutura comum que, de forma geral, pode ser representado, algoritmicamente, por meio dos passos, conforme ilustrado no Algoritmo 1 (MICHALEWICZ; SCHOENAUER, 1996).

Algoritmo 1 Modelo básico de um Algoritmo Evolutivo

Entrada: Um problema T .

Saída: Possíveis soluções para T , próximas do resultado ótimo.

1. $t = 0$
 2. Inicializar $P(t)$, sendo P a população
 3. Avaliar $P(t)$
 4. **enquanto** (não (condição de parada)) **faça**
 5. $t = t + 1$
 6. Selecionar $P(t)$ a partir de $P(t - 1)$
 7. Aplicar os operadores genéticos a $P(t)$
 8. Avaliar $P(t)$.
 9. **fim enquanto**
 10. **retorna** P .
-

2.2.1.1 Algoritmos Genéticos

Os Algoritmos Genéticos são uma classe de algoritmos pertencentes ao ramo dos algoritmos evolucionários e são definidos como uma técnica de busca baseada no processo biológico de evolução natural (LINDEN, 2006).

O primeiro trabalho envolvendo AG foi apresentado por John Holland (1975), mas somente a partir dos anos 80 é que começaram a se popularizar. São meta - heurísticas que se baseiam no processo de recombinação e seleção natural de Charles Darwin.

Esses algoritmos buscam uma solução ótima para o problema proposto, manipulando uma população de soluções candidatas. Nesse sentido, a população

é avaliada e as melhores soluções são selecionadas com a finalidade de se reproduzirem e produzir a próxima geração (LINDEN, 2006).

O indivíduo é uma codificação de uma possível solução para o problema proposto. Essa solução é incorporada em uma estrutura semelhante a de um cromossomo em que são aplicados os operadores de seleção, cruzamento e mutação, com o objetivo de manter informações relativas à solução do problema (LINDEN, 2006).

Os cromossomos são frequentemente implementados como vetores, em que cada componente desse vetor é um gene. Alguns dos prováveis valores que um gene qualquer pode assumir são denominados alelos.

De forma geral, um algoritmo genético deve possuir os seguintes componentes (LINDEN, 2006):

a) Definição do tipo de problema a ser otimizado

O primeiro passo consiste em determinar em que tipo de problema serão aplicados os Algoritmos Genéticos. Como dito anteriormente, os AG são aplicados para resolver problemas complexos de otimização, dentre eles: problemas que possuem vários parâmetros que necessitam serem combinados para obter a melhor solução; problemas que apresentam um conjunto amplo de restrições, estas que não podem ser representadas de forma matemática; e problemas que possuem grandes espaços de busca.

b) Representação e codificação dos indivíduos

Ao utilizar AG, deve-se definir o tipo de representação das possíveis soluções pertencentes ao espaço de busca, definindo, assim, a estrutura do cromossomo a ser manipulado.

Sabendo-se que cada indivíduo em uma população pode ser representado como um candidato em potencial para a solução do problema, a

representação cromossômica, então, depende do tipo do problema e da informação que se deseja manipular geneticamente. Desse modo, os tipos de representação podem ser definidos conforme apresentados na Tabela 4.

Tabela 4 Tipos de representação cromossômica

Representação	Problemas
Binária	Inteiro, numérico
Números Reais	Numérico

Em termos de comparação, a representação binária é mais simples, mais fácil de ser transformada em inteiro ou real, facilita provar determinados teoremas e facilita a manipulação dos cromossomos por meio dos operadores genéticos. Já, a representação por números reais (ponto flutuante) oferece melhor desempenho em relação à representação binária.

Esta etapa, codificação dos indivíduos, é uma das etapas mais críticas ao se definir um AG, pois a definição inapropriada pode fazer com que o algoritmo convirja prematuramente ou encontre soluções ineficazes.

c) Definição da população inicial

Esta etapa consiste na criação dos indivíduos para o primeiro passo do algoritmo. A geração aleatória desses indivíduos é um dos métodos mais comuns utilizados para definir a população inicial. Essa população inicial aleatória pode ser originada a partir de bons cromossomos (sementes), para uma evolução mais rápida.

d) Avaliação dos indivíduos

A etapa de avaliação dos indivíduos consiste em definir uma função que melhor represente o problema, fornecendo uma medida que visa a determinar a aptidão de cada um dos indivíduos da população atual.

A classificação de cada um desses indivíduos é realizada de acordo com esta função, denominada de função *fitness*. Na função de avaliação, deve-se considerar as restrições do problema a ser otimizado de forma a garantir que soluções infactíveis sejam penalizadas.

e) Seleção dos indivíduos para a reprodução

Esta etapa consiste em selecionar os indivíduos para a reprodução, sendo que o critério de seleção é baseado na aptidão dos indivíduos, ou seja, os indivíduos mais aptos, aqueles com melhores valores da função *fitness* têm maior probabilidade de serem escolhidos para reprodução.

O tipo mais simples de seleção adotado é o método da roleta viciada. Nesse método, é criada uma roleta (virtual) na qual cada cromossomo recebe um pedaço proporcional à sua avaliação. Depois roda-se a roleta e o selecionado será o indivíduo sobre o qual ela parar. Um exemplo de seleção por roleta viciada é ilustrado na Figura 9.




Figura 9 Roleta viciada criada com base na avaliação de cada indivíduo

A roleta viciada da Figura 9 possui 20 segmentos e foi criada com base na avaliação de 4 indivíduos. Cada um desses indivíduos recebe um pedaço da roleta proporcional a sua aptidão. Os indivíduos 1, 2, 3 e 4 recebem respectivamente 2, 4, 5 e 9 segmentos da roleta. O indivíduo com maior número de segmentos na roleta tem mais chances de ser sorteado. Quando a roleta girar e, por exemplo, cair sobre o 8º segmento da roleta, significa que o indivíduo 3 será selecionado.

Existem outros métodos para selecionar os melhores indivíduos. Esses métodos de seleção são: torneio, estocástico uniforme, roleta uniforme, *Deterministic Sampling* (DS) entre outros.

f) Definição dos operadores genéticos

Os operadores genéticos mais utilizados nesta etapa são o cruzamento (*crossover*) e a mutação. Após os indivíduos serem selecionados, os mesmos são recombinados pelo operador de cruzamento.

Os pais (pares de genitores) são escolhidos de forma aleatória da população, com base na aptidão. Então, novos indivíduos são criados trocando-se o material genético dos pais. Os descendentes gerados serão diferentes de seus genitores, mas possuirão características genéticas de seus pais.

O operador de cruzamento mais simples é o operador de cruzamento de um ponto de corte, aplicado, principalmente, quando a codificação do cromossomo é binária. Nesse método, depois de selecionados dois pares pelo módulo de seleção, os seus cromossomos a serem cruzados são particionados em um ponto, chamado *Ponto de Corte*, sorteado aleatoriamente. Dois novos indivíduos são gerados permutando-se a metade inicial de um cromossomo com a metade final do outro. Na Figura 10, ilustra-se o processo de cruzamento por um ponto de corte.

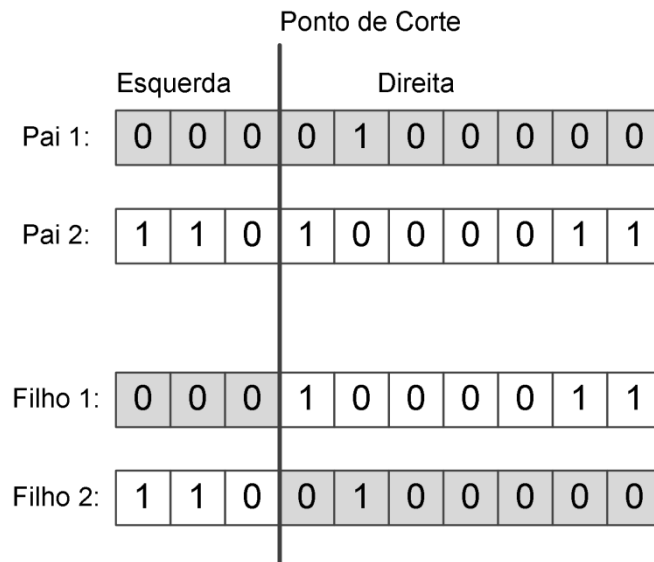


Figura 10 Operador de cruzamento em um ponto de corte

Após a etapa de cruzamento, os cromossomos são submetidos à operação de mutação que consiste em recuperar a diversidade perdida, alterando um ou mais componentes de uma estrutura escolhida. Por exemplo, o operador de mutação “escolha aleatória de bit”, escolhe uma posição aleatória do cromossomo e inverte o valor de um dado gene (de 0 para 1 ou de 1 para 0). Esse operador é compatível somente com codificações binárias.

Existem outros métodos para realizar o cruzamento entre os indivíduos selecionados. Esses métodos de cruzamento são: dois pontos de corte, uniforme, baseado na maioria, entre outros. Do mesmo modo, também existem outros métodos para realizar a mutação entre os indivíduos. Esses métodos são: uniforme, bit a bit, entre outros.

g) *Elitismo*

Ao se utilizar esta técnica, assume-se que os melhores indivíduos de cada geração não são descartados. Estes passam para a próxima geração, visando a garantir a preservação de seus genomas.

2.3 Reconhecimento de Padrões

O reconhecimento de padrões (do inglês *Pattern Recognition*) é uma ciência que trata da classificação e descrição de objetos em certo número de classes a partir da observação de suas características (THEODORIDIS; KOUTROUMBAS, 2009). Visa, ainda, a determinar uma representação mais simples de um conjunto de dados, por meio de suas características mais importantes, permitindo sua divisão em classes.

Existem muitas definições sobre reconhecimento de padrões. Esse termo surgiu no início da década de 60. Os pesquisadores Duda, Hart e Stork (2000) caracterizaram reconhecimento de padrões como um campo interessado no reconhecimento de regularidades significativas em ambientes ruidosos ou complexos.

Com o avanço dos recursos computacionais, o interesse na área de reconhecimento de padrões tem crescido, em decorrência das várias aplicações, pois, de certa forma, projetar e utilizar métodos de análise e classificação tornou-se uma tarefa fácil do ponto de vista computacional. São vários os exemplos de aplicação dessa ciência, como mostrado a seguir (KASABOV, 1996):

- a) diagnóstico médico;
- b) análise de imagens;
- c) classificação de doenças;
- d) reconhecimento de voz;

e) reconhecimento de faces;

Os procedimentos adotados para implementação de um sistema de reconhecimento de padrões se baseiam em técnicas matemáticas, estatísticas e/ou técnicas de Inteligência Computacional. De forma geral, um sistema de reconhecimento de padrões possui a sequência apresentada na Figura 11.

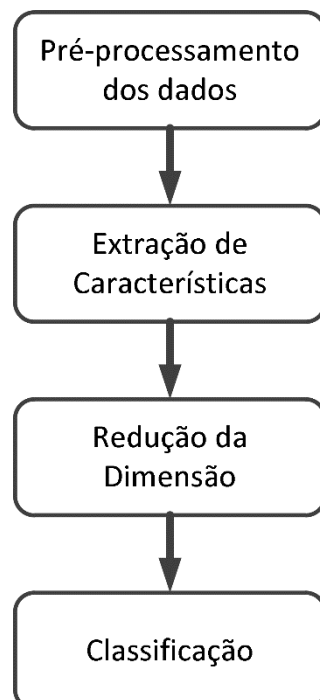


Figura 11 Etapas de um sistema de Reconhecimento de Padrões

Nas próximas seções, cada etapa do sistema de reconhecimento de padrões, apresentadas na Figura 11, será descrita.

2.3.1 Pré-processamento dos dados

O pré-processamento de dados se inicia quando os dados são coletados e organizados em um conjunto, podendo existir diversos objetivos nesta fase. Um desses objetivos consiste em solucionar problemas nos dados, como por exemplo, distinguir e tratar dados corrompidos, características irrelevantes e até mesmo valores desconhecidos.

Em outros casos, pode-se também estar interessado em aprender mais a respeito dos dados, analisando a correlação entre eles e aplicando esses resultados para, por exemplo, fazer previsões em séries temporais com uso de Redes Neurais Artificiais.

O conjunto de ações realizadas nesta fase tem por objetivo preparar os dados para a fase seguinte, ou seja, a fase de extração de informações, garantindo, assim, que esta seja mais efetiva.

Pode-se dizer que a fase de pré-processamento de dados depende da capacidade do usuário em identificar e utilizar métodos apropriados para encontrar a melhor solução para o problema proposto. Após a etapa de pré-processamento dos dados se inicia a etapa de extração de características desses dados.

2.3.2 Extração de características

A extração de características tem por objetivo capturar informações mais relevantes para classificar um dado fornecido como entrada, ou seja, é utilizada para extrair características necessárias para reconhecer um padrão (DEVIJVER; KITTLER, 1982). A técnica consiste em obter um conjunto de características de menor dimensão em relação ao dado original sem perder a capacidade de discriminar padrões, conseguindo classificá-los com um melhor desempenho.

Não existem regras para determinar as características mais relevantes de um problema, sendo a escolha das mesmas, determinada de acordo com a natureza dos dados, a aplicação a que se destina e, por último, a tecnologia que será utilizada para implementar o sistema.

Nesse sentido, para evitar informações redundantes, o processo de escolha de quais características são importantes se torna fundamental, pois as mesmas devem ser extraídas de modo a servir como elementos básicos de um padrão (DEVIJVER; KITTLER, 1982).

Uma técnica utilizada para extrair características consiste no uso de Estatísticas de Ordem Superior (EOS), detalhada a seguir.

a) Estatísticas de Ordem Superior (EOS)

Os cumulantes são medidas de EOS utilizados em técnicas de processamento de sinais e são adequados para lidar com processos não Gaussianos e sistemas não lineares (MENDEL, 1991).

Seja X um processo aleatório constituído pelo conjunto de variáveis aleatórias (x_1, x_2, \dots, x_n) . Para variáveis aleatórias reais com média zero, os cumulantes de 2ª, 3ª e 4ª ordens são dados por (MENDEL, 1991):

$$\begin{aligned} cum(x_1, x_2) &= E\{x_1 x_2\}, \\ cum(x_1, x_2, x_3) &= E\{x_1 x_2 x_3\}, \\ cum(x_1, x_2, x_3, x_4) &= E\{x_1 x_2 x_3 x_4\} - E\{x_1 x_2\}E\{x_3 x_4\} - E\{x_1 x_3\}E\{x_2 x_4\} \\ &\quad - E\{x_1 x_4\}E\{x_2 x_3\}, \end{aligned} \quad (1)$$

sendo E o operador de esperança matemática, que é definido como a soma das probabilidades do sinal multiplicada pelo valor da amostra.

Supondo $x(t)$, um processo aleatório estacionário com média zero, os cumulantes de ordem k , denotados por $C_{k,x}(\tau_1, \tau_2, \dots, \tau_k)$, onde τ_1, \dots, τ_k são deslocamentos no tempo, são definidos em termos dos sinais $x(t), x(t + \tau_1), \dots, x(t$

+ τ_k). Definindo $\tau_1 = \tau_2 = \tau_3 = \tau$, a partir da Equação (1), os cumulantes de 2ª, 3ª e 4ª ordens podem ser reescritos, de acordo com (Mendel, 1991), como,

$$\begin{aligned} C_{2,x}(\tau) &= E\{x(t)x(t+\tau)\}, \\ C_{3,x}(\tau) &= E\{x(t)x^2(t+\tau)\}, \\ C_{4,x}(\tau) &= E\{x(t)x^3(t+\tau)\} - 3C_{2,x}(\tau)C_{2,x}(0). \end{aligned} \quad (2)$$

Para um sinal discreto $x[n]$, a Equação (2) pode ser aproximada utilizando a forma circular de cálculo dos cumulantes, proposta em (RIBEIRO et al., 2007):

$$C_{2,x}(\tau) = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x[\text{mod}(n+\tau, N)], \quad (3)$$

$$C_{3,x}(\tau) = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^2[\text{mod}(n+\tau, N)]$$

$$C_{4,x}(\tau) = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^3[\text{mod}(n+\tau, N)] - 3 \frac{1}{N^2} \sum_{n=0}^{N-1} x[n]x[\text{mod}(n+\tau, N)] \cdot \sum_{n=0}^{N-1} x^2[n],$$

sendo $x \in \mathbb{R}^N$ e $\tau = 0, 1, \dots, N-1$, em que mod é o operador de módulo (resto da divisão de número inteiro).

2.3.3 Redução da Dimensionalidade

A redução da dimensionalidade é uma etapa utilizada para identificar atributos que são mais relevantes em uma base de dados. A técnica remove os dados (características) redundantes e irrelevantes de um conjunto de alta dimensão, permitindo, dessa forma, uma melhor compreensão dos resultados

gerados, identificando o grau de influência de cada um dos atributos selecionados em relação ao objetivo desejado (HAIR et al., 2009).

Uma quantidade excessiva de atributos aumenta o custo computacional e pode prejudicar a busca por padrões. Em decorrência desse problema, a técnica de redução de dimensionalidade objetiva manter as características de um conjunto de dimensão X em outro espaço de dimensão menor que X (HAIR et al., 2009).

A seguir, duas ferramentas que podem ser utilizadas nesta etapa são apresentadas: a Análise Discriminante de Fisher e os Algoritmos Genéticos.

a) Análise Discriminante de Fisher - LDA

A análise discriminante é uma técnica de estatística multivariada, utilizada para discriminar e classificar objetos e tem por objetivo estudar o modo de separação de objetos de uma população em duas ou mais classes (KHATTREE; NAIK, 2000).

Abordado inicialmente por Fisher, o problema da discriminação entre dois ou mais grupos tinha por finalidade uma classificação posterior. O método consiste em obter funções matemáticas com capacidade para classificar um indivíduo em uma de várias populações. Essa classificação é realizada com base em determinadas características, buscando minimizar as chances de classificar erroneamente um indivíduo em uma população a qual não pertence (FISHER, 1936).

Desse modo, pode-se dizer que a técnica de Fisher assemelha-se a uma técnica de obtenção de funções de decisão lineares, segundo um critério de otimalidade que é baseado em estatísticas de primeira e segunda ordem. Assim, a LDA provê extração de características, reduzindo a dimensionalidade do problema de classificação (WU; AHMAD, 2012).

A função discriminante linear de Fisher pode ser descrita como uma combinação linear de características originais que tem, por propósito, atingir uma separação máxima entre duas populações. A técnica consiste em determinar uma base vetorial que maximize a razão entre o determinante de uma matriz interclasse A_b com uma matriz intraclasse A_w , ou seja,

$$\text{Critério}_{Fisher} = \max \frac{|A_b|}{|A_w|} \quad (4)$$

Essa base vetorial pode ser resolvida como problema de autovalores e autovetores e é determinada por:

$$(A_w^{-1} * A_b)\Phi = \Lambda\Phi, \quad (5)$$

sendo Φ a matriz de autovetores e Λ é a matriz de autovalores de $A_w^{-1} * A_b$.

b) Algoritmos genéticos

Outra ferramenta utilizada para reduzir a dimensionalidade são os Algoritmos Genéticos descritos na subseção 2.2.1.1. Estes são utilizados, em razão do seu poder de explorar grandes espaços de busca e têm sido largamente utilizados em problemas que visam a reduzir a dimensionalidade e maximização do desempenho (NAVES; BARBOSA; FERREIRA, 2014a).

Na resolução de problemas, por meio da utilização de AG, pode-se adotar uma representação binária da solução em que o cromossomo é representado por uma cadeia de bits (0's ou 1's). Nessa representação, quando uma posição na cadeia de bits for igual a um, isso implica no uso dessa característica. Por outro lado, se uma posição na cadeia de bits contém o valor zero, isso indica que a característica não é utilizada.

2.3.4 Classificação

As técnicas de classificação de padrões podem ser supervisionadas e não supervisionadas. Na classificação supervisionada é fornecida a identificação (rótulos) de cada objeto da base de dados. Na classificação não supervisionada (agrupamento) as categorias envolvidas são conhecidas, mas a base não está identificada, ou seja, não possui rótulos.

A seguir, serão utilizados os seguintes métodos de classificação supervisionada: Árvores de Decisão (*Decision Trees*) (BREIMAN et al., 1984), Máquinas de Vetores Suporte (VAPNIK, 1995), *k*-vizinhos mais próximos (FIX; HODGES, 1951) e Classificador Bayesiano (MITCHELL, 1997). Esses métodos serão detalhados a seguir.

2.3.4.1 Árvores de Decisão

As Árvores de Decisão pertencem ao subcampo de aprendizagem de máquina. Isso se deve à sua habilidade de aprender, por meio de exemplos, decompondo um problema complexo em subproblemas simples, aplicando essa estratégia de forma recursiva (BREIMAN et al., 1984).

Baseando-se no conjunto de dados de treinamento, a árvore é montada e, a partir dessa estrutura, a amostra desconhecida é classificada. Em cada nível da árvore, tomam-se decisões em relação ao nível seguinte até atingir um nó folha, em que cada percurso na árvore corresponde a uma regra de classificação.

A técnica utiliza a estratégia de dividir para conquistar, em que a cada nível, um problema mais complexo é decomposto em subproblemas mais simples, para, então, realizar a classificação e predição das amostras desconhecidas, obtendo como resultado um subconjunto de atributos (BREIMAN et al., 1984).

De acordo com Cho e Kurup (2011), as árvores de decisão possuem: nós que representam suas características; arestas ou ramos, advindos dos nós e que recebem os valores possíveis para esses atributos; nós folha, que representam os tipos diferentes de classes de um conjunto de treinamento. Na Figura 12, ilustra-se uma estrutura do tipo árvore de decisão.

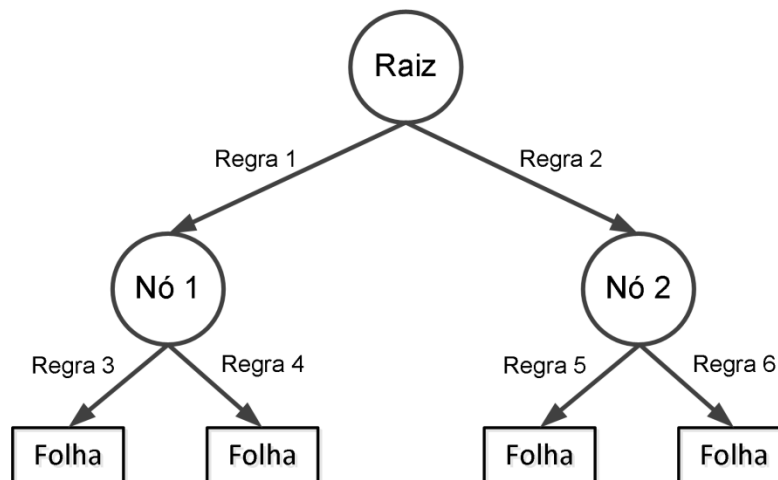


Figura 12 Estrutura de dados baseada em árvore de decisão

O modelo classifica as suas instâncias percorrendo a árvore a partir da raiz, que representa o início da árvore, até alcançar o nó folha, este que contém informações de classificação do algoritmo. Cada nó é responsável em testar o valor de um único atributo, oferecendo arestas diferentes a serem percorridas na árvore a partir desse nó (BREIMAN et al., 1984).

2.3.4.2 Máquinas de Vetores Suporte

As Máquinas de Vetores Suporte constituem uma técnica de aprendizado estatístico desenvolvida por Vapnik (1995). A ideia principal de

uma máquina de vetor de suporte consiste em obter um hiperplano para a separação de dados pertencentes a duas classes.

Um hiperplano ótimo é definido como aquele em que a margem de separação entre pontos positivos e negativos seja máxima. Esses pontos são denominados de vetores de suporte e são circulos na Figura 13.




Figura 13 Hiperplano de separação

Dado o conjunto de treinamento $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ em que y assume valores 1 ou -1, o que define a classe que x pertence. Sendo x um vetor de p dimensões normalizadas (valores entre 0,1 ou -1) as máquinas de vetores suporte dividem o hiperplano de acordo com a equação:

$$w^T + b = 0 \quad (6)$$

em que w é o vetor de entrada perpendicular ao hiperplano e b é uma variável que permite a maximização da margem do hiperplano.

2.3.4.3 k-vizinhos mais próximos – k-NN

O classificador k -NN foi introduzido em 1975, por Fix e Hodges (FIX; HODGES, 1951) e se trata de uma das técnicas mais simples de implementar e vem sendo utilizada para classificar padrões.

O princípio básico de seu funcionamento consiste em classificar um padrão por meio do cálculo da distância, por exemplo, a distância Euclidiana, entre os k padrões mais próximos a ele, a partir da lista de vizinhos mais próximos (DUDA; HART; STORK, 2000). A distância Euclidiana $\mathbf{d}(\mathbf{x}, \mathbf{y})$ entre duas instâncias x e y pode ser definida como:

$$\mathbf{d}(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}. \quad (7)$$

O algoritmo então calcula a distância do padrão dado para cada um dos padrões que formam a base de treinamento e, então, ordena os padrões dessa base. Desses padrões ordenados, são selecionados os k primeiros (mais próximos) e, por meio do voto majoritário, determina-se o rótulo da classe desconhecida do padrão.

Assim, de acordo com Garcia et al. (2010), os passos básicos do Algoritmo k -NN são:

- a) calcular as distâncias entre o padrão desconhecido e todos os padrões rotulados anteriormente;
- b) selecionar os k padrões mais próximos do padrão desconhecido;
- c) usar o voto majoritário para prever a classe do padrão.

Na Figura 14, ilustra-se o funcionamento do processo de classificação do k -NN.

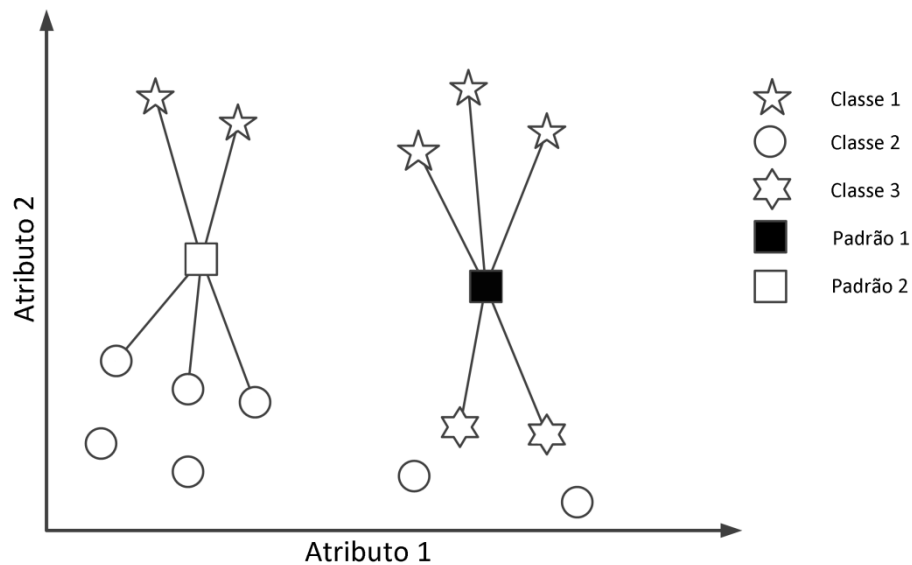


Figura 14 Esquema de classificação pelo k-NN

No exemplo ilustrado na Figura 14, existem amostras que estão distribuídas em 3 classes diferentes e deseja determinar a classe de 2 padrões. Para esse exemplo, os 5 vizinhos mais próximos de cada padrão são questionados sobre suas classificações. Assim, utilizando o voto majoritário, o padrão 1 é classificado como pertencente à classe 1 e o padrão 2 é classificado como pertencente à classe 2.

2.3.4.4 Classificador Bayesiano

O classificador bayesiano é um classificador probabilístico que aprende as distribuições de probabilidades a partir de dados e classifica uma instância de teste escolhendo a classe que apresenta a maior probabilidade a posteriori. A classe escolhida é a que satisfaz:

$$\mathcal{H}_{MAP} = \arg_{\mathcal{H}_i \in \mathcal{H}} \max p(\mathbf{x}|\mathcal{H}_i) p(\mathcal{H}_i), \quad (8)$$

Em que $P(\mathcal{H}_i)$ representa a probabilidade a priori e $p(\mathbf{x}|\mathcal{H}_i)$ representa a função de densidade de probabilidade da classe \mathcal{H}_i , em que \mathbf{x} é o valor do atributo e i corresponde ao número da classe. Uma função de densidade de probabilidade condicional bastante utilizada é a distribuição gaussiana, expressa por:

$$p(\mathbf{x}|\mathcal{H}_i) = \frac{1}{(2\pi\sigma_i^2)^{1/2}} \exp\left\{-\frac{1}{2\sigma_i^2}(\mathbf{x} - \mu_i)^2\right\}, \quad (9)$$

sendo μ_i o valor médio da classe \mathcal{H}_i e σ_i sua variância. Assumindo probabilidades a priori uniformes, a Eq. (8) simplifica para:

$$\mathcal{H}_{ML} = \arg_{\mathcal{H}_i \in \mathcal{H}} \max p(\mathbf{x}|\mathcal{H}_i), \quad (10)$$

em que \mathcal{H}_{ML} é chamada de hipótese de Máxima Verossimilhança.

2.3.4.5 Dividir para conquistar

A abordagem dividir para conquistar consiste em dividir um problema complexo em subproblemas mais simples, aplicando a estratégia de forma recursiva a cada subproblema. O resultado dessa divisão pode ser visto como uma árvore de decisão que divide o conjunto de dados a ser classificado. Nessa abordagem de classificação, cada aresta da árvore pode ser vista como uma regra que deve ser avaliada com objetivo de chegar a um resultado.

Ao aplicar a estratégia de dividir para conquistar em um problema, o espaço de dados é, então, dividido em partes menores e mais fáceis de aprender por diferentes classificadores. Essa estratégia permite desenvolver sistemas de classificação mais robustos, por meio de uma combinação apropriada dos

diferentes classificadores, que irão realizar a divisão de cada subconjunto até conter apenas uma classe.

A ideia principal dessa abordagem é de combinar as saídas de vários classificadores de modo que o desempenho alcançado no final do processo de classificação seja superior ao desempenho de um único classificador.

O classificador árvore de decisão (BREIMAN et al., 1984), tem como base o uso da estratégia de dividir para conquistar, em que um conjunto de dados de um problema são divididos em vários subconjuntos, de forma que cada subconjunto seja formado, baseando-se nas características semelhantes desses dados. Dessa maneira, esse classificador busca uma forma de dividir o conjunto dos dados em nodos. O processo de classificação opera à medida em que são percorridos os caminhos por meio de um conjunto de regras, até que seja encontrado o nodo que possui a característica decisiva.

A abordagem Mistura de Especialistas (ou sistemas modulares) que faz parte da grande área Máquinas de Comitê é, também, uma aplicação direta dessa abordagem.

Os sistemas modulares partem da estratégia “dividir para conquistar” para resolução de problemas complexos. Pelo fato de não necessitarem de estimadores complexos e a inteligibilidade inerente a tais sistemas fizeram com que essa abordagem se destacasse em problemas de aprendizagem de máquinas.

A utilização desses sistemas é, também, muitas vezes justificada por fazer com que o sistema como um todo seja fácil de entender e modificar (SHARKEY, 1999). O tempo de treinamento pode ser reduzido (GALLINARI, 1995) e conhecimento, a priori, pode ser incorporado como auxílio na escolha da forma mais apropriada de decomposição de um problema (PRATT; MOSTOW; KAMM, 1991).

A decomposição do problema original em subproblemas é uma das principais questões dessa abordagem. Hampshire e Waibel (1989) apresentaram

uma arquitetura modular em que a divisão do problema em subtarefas é realizada mediante conhecimento prévio do problema, sendo necessário um conhecimento profundo do problema pelo projetista. A decomposição automática de um problema foi apresentada por Jacobs, Jordan e Barto (1991) e, posteriormente, por Jacobs et al. (1991) em que a arquitetura mistura de especialistas foi apresentada à comunidade científica.

2.3.5 Trabalhos relacionados

Existem várias aplicações envolvendo o problema de separação e classificação de sons pulmonares. Os principais trabalhos que compõem o referencial bibliográfico serão relatados a seguir.

Os autores Amaral et al. (2015) desenvolveram um sistema de reconhecimento de padrões com objetivo de aumentar a precisão da técnica de oscilações forçadas (*Forced Oscillation Technique* - FOT) na classificação do nível de obstrução das vias aéreas em pacientes com doença pulmonar obstrutiva crônica (*Chronic Obstructive Pulmonary Disease* - COPD). Para a tarefa de classificação, foram utilizados os classificadores *k*-NN, SVM e *Random Forest* e para avaliar o desempenho do sistema proposto, foi utilizada a curva ROC (*Receiver Operating Characteristic*), alcançando resultados de classificação superiores a 0.9.

O classificador SVM também foi utilizado em (JIN; SATTAR; GOH, 2014; SEN; SARACLAR; KAHYA, 2015), para classificar sons pulmonares. Sem, Saraclar e Kahya (2015) classificaram vários tipos de condições pulmonares, incluindo condições saudáveis e condições patológicas e também utilizaram o classificador GMM (*Gaussian Mixture Models*). Após vários testes realizados, uma versão hierárquica do classificador GMM obteve melhor desempenho de classificação, com uma taxa de classificação de 85%. Os autores

(JIN; SATTAR; GOH, 2014) classificaram os sons pulmonares entre normais e adventícios contínuos. Foram utilizadas curtose instantânea, função discriminante e entropia para extração de características dos sinais e foram alcançados 97,7% a 98,8% em acerto médio de classificação.

Para classificar os sinais pulmonares em sinais normais, estertores e roncos, (IÇER; GENGEÇ, 2014) aplicaram três técnicas de processamento de sinais para extrair características dos sons pulmonares: PSD (*Power Spectral Density*), HHT (*Hilbert Huang Transform*) e SSA (*Singular Spectrum Analysis*). No processo de classificação, SVM também foi utilizada. Como resultado de acerto de classificação foram obtidos valores acima de 90%, com possibilidade de implementação do sistema em tempo real. A técnica PSD também foi utilizada para extração de características em (VILLALOBOS et al., 2011). Os autores propuseram um conjunto de técnicas de parametrização de sons pulmonares com o objetivo de classificar esses sons entre sons normais e sons anormais. Uma RNA supervisionada foi utilizada para a tarefa de classificação dos sinais, obtendo resultados de classificação de 75% para indivíduos saudáveis e 93% para indivíduos com alguma patologia respiratória.

Uma técnica para se obter a representação tempo-frequência (*Time-Frequency Representation* - TFR) dos sons torácicos foi proposta por (REYES et al., 2014). Ao utilizar os padrões obtidos pela representação tempo-frequência, os autores avaliaram o desempenho de dez TFRs do coração, dos sons adventícios e dos sons pulmonares normais. Depois de algumas simulações, eles concluíram que o melhor desempenho encontrado pela TFR foi obtido ao utilizar o Espectro-Hilbert-Huang (*Hilbert-Huang Spectrum* - HHS).

Os métodos análise tempo-frequência e análise tempo-escala foram propostos em (SERBES et al., 2013) para classificar sinais pulmonares em estertores e não estertores. Os autores utilizaram o classificador Perceptron Multi-Camadas (*Multilayer Perceptron* - MLP), *k*-NN e SVM. Após realizar

alguns testes, os autores concluíram que o classificador SVM foi superior na detecção de sinais estertores, alcançando 97,5% em acerto de classificação. O classificador SVM também foi utilizado por (LEE et al., 2012). Os autores propuseram uma abordagem hierárquica do SVM para classificar doenças intersticiais pulmonares difusas. O método proposto seleciona cada classe por meio de um classificador binário implementado em uma árvore de classificação em que cada nó distingue dois subconjuntos de classes. O desempenho geral em classificação pelo método proposto foi superior a 91%.

O método Coeficiente Mel-Cepstral (*Mel-Frequency Cepstral Coefficient* - MFCC) foi utilizado para extração de características de sons pulmonares em (BAHOURA, 2009; HASHEMI; ARABALIBEIK; AGIN, 2012). No trabalho de (HASHEMI; ARABALIBEIK; AGIN, 2012), os sons pulmonares foram classificados em sibilos monofônicos e polifônicos, por meio de uma MLP, obtendo 93,5% em acerto de classificação. No trabalho de (BAHOURA, 2009), os sons pulmonares foram classificados em normais e sibilos, por meio do classificador GMM, obtendo 94,2% em acerto de classificação.

A Transformada Wavelet foi utilizada para decompor o sinal pulmonar em (KANDASWAMY et al., 2004; QUANDT et al., 2012; SEZGIN et al. 2001; XIAO GUANG; BAHOURA, 2008). Quandt et al. (2012) utilizaram LDA para a redução da dimensionalidade dos dados e classificaram pelo método *k*-NN entre sinais pulmonares normais, estertores finos e grossos. Os resultados de acerto de classificação obtidos foram de 70% para estertores grossos, 60% para estertores finos e 100% para sons normais. O sistema proposto por (Xiaoguang et al. 2008) separa o sinal normal do sinal anormal (estertor), utilizando o filtro *Wavelet Packet*. Em seguida, os estertores são detectados pelo uso da Dimensão Fractal (*Fractal Dimension* - FD) e, por último, são classificados pelo GMM em estertores finos e estertores grossos. O resultado de acerto de classificação

obtido foi de 91,5%. Kandaswamy et al. (2004) classificaram 6 tipos de sons pulmonares (normais, sibilos, estertores, grasnido, estridor e ronco), utilizando Redes Neurais Artificiais. Após realizar diversas simulações, o melhor resultado de acerto de classificação obtido foi de 94,56%. Os autores (SEZGIN et al., 2001) propuseram um classificador de sons respiratórios em indivíduos saudáveis e indivíduos com asma e, assim como (KANDASWAMY et al., 2004), também utilizaram Redes Neurais Artificiais para classificá-los. Foi utilizada uma Rede Neural de Aprendizado Construtivo (*Grow and Learn - GAL*). Os resultados obtidos mostraram que a Rede Neural proposta classificou de forma satisfatória os sinais analisados, alcançando 98% de acerto de classificação.

As redes wavelets também foram utilizadas para parametrizar e quantificar a forma de onda dos sinais estertores com apenas um pequeno conjunto de parâmetros significativos em (YEGINER; KAHYA, 2009). Os autores utilizaram wavelet de Morlet como os nós de uma rede para modelar o sinal estertor com o objetivo de obter os parâmetros relevantes para a pesquisa de sons pulmonares. Para representar a morfologia da forma de onda dos estertores, o modelo utilizou cinco parâmetros por nó. Os autores compararam as características extraídas dos parâmetros do modelo com as características convencionais no domínio do tempo em um experimento de duas classes, sendo obtido um acerto de classificação de 90% entre esses modelos.

A Análise de Componentes Principais (*Principal Component Analysis - PCA*) foi utilizada para a redução da dimensionalidade dos dados em (KAHYA et al., 2003; MARTINEZ-HERNANDEZ et al., 2005). Martinez-Hernandez et al. (2005) propuseram um sistema para classificar sons pulmonares entre normais e adventícios. Os autores utilizaram Modelos Autorregressivos Multivariados (*Multivariate Autoregressive Models - MAR*) para extração de características e também utilizaram a Decomposição em Valores Singulares

(*Singular Value Decomposition - SVD*) para redução da dimensionalidade. Uma RNA foi utilizada para classificação, sendo obtido acertos de classificação superiores a 80%. Kahya et al. (2003) classificaram os sons pulmonares entre normais ou adventícios e utilizaram o k -NN como classificador dos sinais pulmonares, obtendo resultados de classificação entre 65% e 86%.

A implementação de um sistema de diagnóstico em tempo real capaz de adquirir, parametrizar e classificar sons pulmonares em duas classes: sons normais e sons anormais foi proposta por (ALSMADI; KAHYA, 2008). O instrumento utiliza dois classificadores para avaliar o processo de classificação: k -NN e classificador de distância mínima. Os autores verificaram a operação em tempo real do instrumento em um ambiente clínico, que obteve 96% de acerto em classificação.

Para extrair e revelar informações sobre os sons pulmonares, (HADJILEONTIADIS; PANAS, 1997) utilizaram estatísticas de ordem superior para obter uma melhor caracterização e diagnóstico. Eles utilizaram a abordagem paramétrica de estimação do biespectro que revela informações sobre sons pulmonares, tais como desvios de normalidade. Depois de realizar alguns experimentos, os autores concluíram que os métodos baseados em biespectro são mais adequados e robustos que os métodos baseados em estatísticas de segunda ordem para análise e caracterização dos sons pulmonares, por suas propriedades gerais em ambientes ruidosos.

Esforços têm sido feitos para aperfeiçoar os sistemas de classificação de sons respiratórios. Pesquisadores têm utilizado diversas técnicas para alcançar esse objetivo. Assim, esse é um campo de pesquisa em aberto, com vários estudos sendo realizados com o intuito de obter um diagnóstico mais preciso das enfermidades pulmonares.

3 METODOLOGIA DE DESENVOLVIMENTO

Neste capítulo, apresentam-se os materiais e métodos para desenvolvimento do sistema de reconhecimento de padrões para sons pulmonares. São detalhadas as seguintes etapas: escolha do banco de dados de sinais pulmonares, processo de extração de características, redução da dimensionalidade e por fim, técnicas de classificação.

3.1 Materiais

A implementação do trabalho se deu em um computador Dell com processador Intel® Core™ i7 (3.1GHz), 6 GB de RAM e sistema operacional Windows 7 Professional 64 bits. Foram utilizados o software Matlab® para implementação do sistema de reconhecimento de padrões e o software livre Audacity 2.0.5 para a análise dos sons pulmonares.

O banco de dados utilizado neste trabalho foi obtido pelo livro (LEHRER, 2004) acompanhado de um CD. A escolha desse banco de dados foi decorrente da facilidade de aquisição e pelo fato de alguns trabalhos já terem o utilizado (JIN; SATTAR; GOH, 2014; NAVES; BARBOSA; FERREIRA, 2014a, 2014b; QUANDT et al., 2012; XIAOGUANG; BAHOURA, 2008). Dessa forma, é possível realizar estudos comparativos em relação às técnicas utilizadas nos diferentes trabalhos, para reconhecimento de padrões em sons pulmonares.

Há outros bancos de dados com sinais pulmonares disponíveis, alguns são gratuitos, mas possuem poucos dados e outros bancos de dados possuem um alto custo para a sua aquisição, o que, de certa forma, inviabilizaria o trabalho.

Assim, foi utilizado o conjunto de dados obtidos em (LEHRER, 2004), em que sons normais e adventícios estão disponíveis. As classes de sons

pulmonares utilizadas são: normais, estertores finos, estertores grossos, sibilos monofônicos e sibilos polifônicos. Em decorrência do fato de os sons pulmonares serem ruídos auscultados mais frequentemente durante a inspiração, foram extraídos somente os componentes inspiratórios de cada sinal pulmonar. Todos os sinais utilizados foram amostrados em 8 kHz (QUANDT et al., 2012). Na Figura 15, ilustra-se um sinal pulmonar estertor grosso com 3 fases inspiratórias e 3 fases expiratórias.

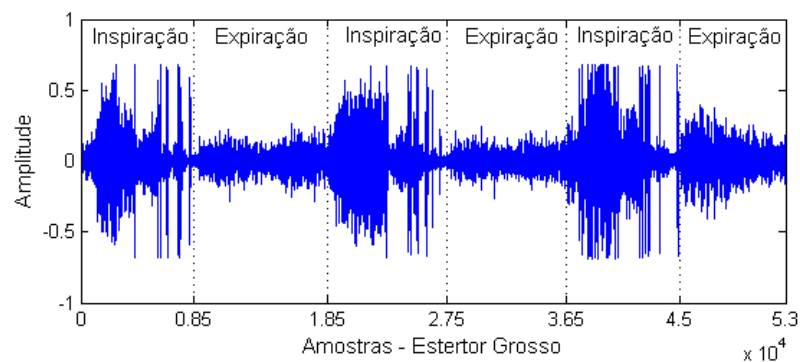


Figura 15 Som pulmonar estertor grosso. Fases inspiratórias e expiratórias

Ao analisar a Figura 15, é possível observar que esses sons são mais intensos na fase inspiratória que na fase expiratória.

Após a etapa de separação das fases inspiratórias das expiratórias de cada sinal pulmonar, foram concatenados cada um dos seus respectivos segmentos inspiratórios. Na Figura 16, ilustra-se o sinal estertor grosso, em que suas fases inspiratórias foram concatenadas.

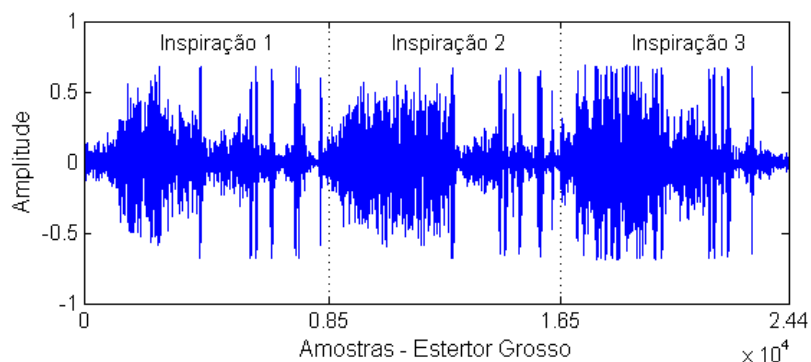


Figura 16 Som pulmonar estertor grosso. Fases inspiratórias concatenadas

De acordo com Serbes et al. (2013) e Sovijärvi et al. (2000), a duração dos sinais estertores é inferior a 20ms. Desse modo, todos os sinais pulmonares utilizados (sons normais, estertores e sibilos) foram recortados em segmentos de tamanho 320 amostras, representando, aproximadamente, 40 ms. Esse procedimento foi realizado para garantir que ao menos um sinal estertor esteja presente no segmento.

Porém, em alguns dos segmentos dos sinais estertores (finos e grossos) que foram obtidos por meio desse processo, não foram observadas as características de seu comportamento explosivo e, em outros casos, foram observadas apenas a metade dessas características.

Assim, a partir do estudo e análise do comportamento desses sons pulmonares, foi realizada uma seleção manual de cada segmento que continha, pelo menos, metade de um sinal característico de um estertor. Esses sinais, como mencionado na Seção 2, são produzidos durante a inspiração, pela abertura explosiva de pequenas vias aéreas até então fechadas. Na Figura 17, ilustra-se um segmento de sinal estertor grosso com 1600 amostras (total de cinco segmentos) obtido a partir da inspiração 1 da Figura 16.

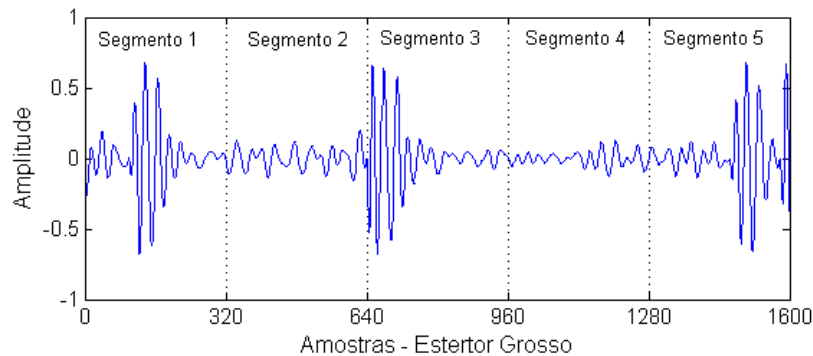


Figura 17 Som pulmonar estertor grosso. Segmentos de tamanho igual a 320 amostras

Na Figura 17, o segmento de 1600 amostras foi dividido em cinco segmentos com tamanho igual a 320 amostras e esses segmentos estão numerados de 1 a 5. O comportamento explosivo dos estertores é visto nos segmentos 1, 3 e 5. O segmento 1 apresenta um sinal característico de um estertor grosso. Os segmentos 3 e 5 apresentam apenas metade de um sinal característico de um estertor grosso. Nos segmentos 2 e 4 não existe sinal característico de um estertor grosso. Esse fato ocorre, por serem os sinais estertores (grossos e finos) sinais descontínuos, assim, em alguns segmentos, não estão presentes as suas características explosivas.

Os demais sinais pulmonares (sons normais e sibilos), por não possuírem um comportamento explosivo como os estertores, não foram submetidos à seleção manual de características, pois são contínuos. Na Figura 18, ilustram-se dois segmentos de sinais pulmonares (a - sibilo polifônico, b - normal) com 1600 amostras (total de cinco segmentos cada).

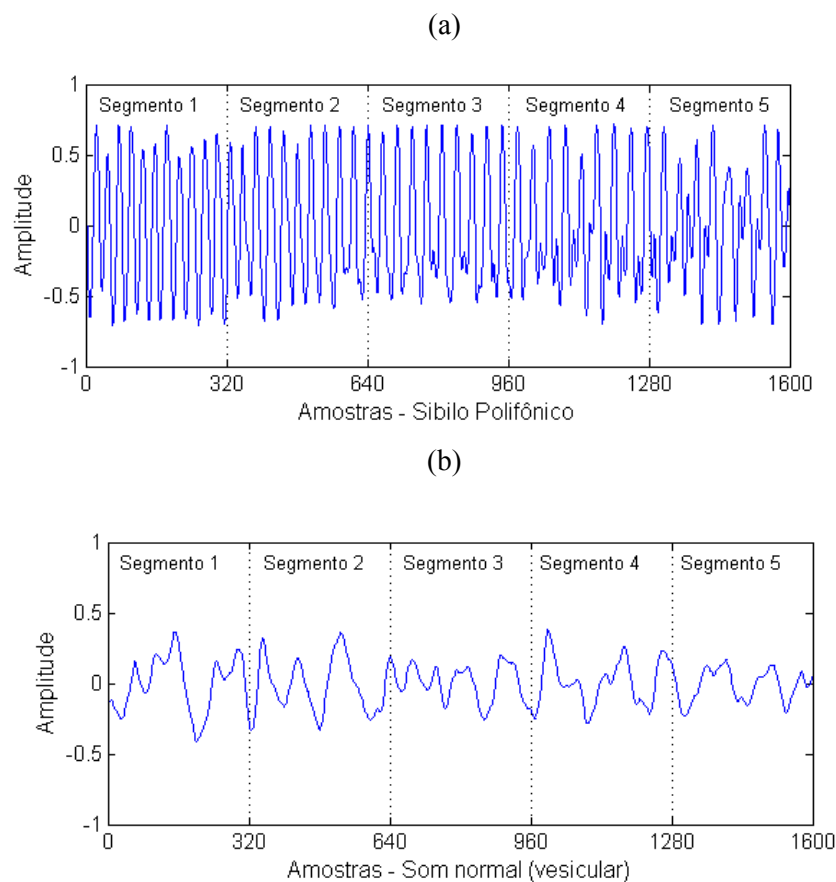


Figura 18 Segmentos de sinais pulmonares com 1600 amostras. (a) Sibilo Polifônico e (b) Som Normal

Ao analisar a Figura 18, é possível observar em ambos os sinais, (a) sibilo polifônico e (b) normal que cada um de seus cinco segmentos não apresentam um comportamento explosivo como o comportamento dos sinais estertores. Após a seleção dos sinais, todas as amostras foram normalizadas com média zero e variância unitária.

Dessa forma, após o processo de normalização de cada um dos sons pulmonares, foram obtidos 318 eventos de sons respiratórios, 102 eventos de sons normais, 57 eventos de estertores finos, 57 eventos de estertores grossos, 51

eventos de sibilos monofônicos e 51 eventos de sibilos polifônicos. Na Figura 19, ilustram-se eventos de cada tipo de som pulmonar utilizado. Cada evento foi selecionado aleatoriamente, a partir do banco de dados utilizado.




Figura 19 Eventos de Sons Pulmonares. (a) Normal, (b) Estertor Fino, (c) Estertor Grosso, (d) Sibilo Monofônico e (e) Sibilo Polifônico

3.2 Métodos

Nesse trabalho, foi utilizado o método de aprendizagem supervisionado em que todos os padrões de treinamento são rotulados. Assim eles possuem tanto as entradas que consistem o conjunto de atributos, quanto às saídas que apresentam as respectivas classes. Desse modo, com a obtenção dos 318 eventos de sons respiratórios, foi realizado o processamento desses dados.

As características foram extraídas com o uso de EOS. Ao aplicar as equações (3) no conjunto de dados, 160 cumulantes de 2ª ordem, 320 cumulantes de 3ª ordem e 320 cumulantes de 4ª ordem foram obtidos para cada evento. Na Figura 20, ilustra-se a média das características extraídas, cumulantes de 2ª, 3ª e 4ª ordem dos eventos dos sons pulmonares de cada uma das cinco classes.




Figura 20 Cumulantes de 2^a, 3^a e 4^a ordem. (a) Normal, (b) Estertor Fino, (c) Estertor Grosso, (d) Sibilo Monofônico e (e) Sibilo Polifônico

Após finalizada a etapa de extração de características, deu-se início à etapa de redução da dimensionalidade. Em razão do grande número de

cumulantes (800 características), alguns devem ser selecionados. Assim, duas técnicas são utilizadas e comparadas: o AG e a LDA.

O objetivo do uso do AG é selecionar os melhores cumulantes dentre os 800 disponíveis para serem utilizados no sistema de classificação.

Para isso, o AG minimiza uma função custo que engloba o erro de classificação e o número de cumulantes utilizado pelo classificador. A avaliação de cada indivíduo, proposta neste trabalho, é dada por:

$$Avaliação = Erro_{classificação} + 0,001 * Número_{cumulantes} \quad (11)$$

Onde a variável $Erro_{classificação}$ é o erro de classificação (em porcentagem) do indivíduo avaliado e a variável $Número_{cumulantes}$ é o número de características (cumulantes) utilizadas pelo indivíduo. Essa segunda variável, $Número_{cumulantes}$, foi inserida para reduzir o número de cumulantes selecionados pelo método de classificação. Quando indivíduos distintos possuírem o mesmo erro de classificação, aquele indivíduo que selecionar um menor número de cumulantes obterá a melhor avaliação. Os indivíduos são sequências binárias com até 800 posições, sendo que cada posição indica o uso ou não do cumulante respectivo. Na Figura 21, ilustra-se o processo de avaliação do indivíduo.

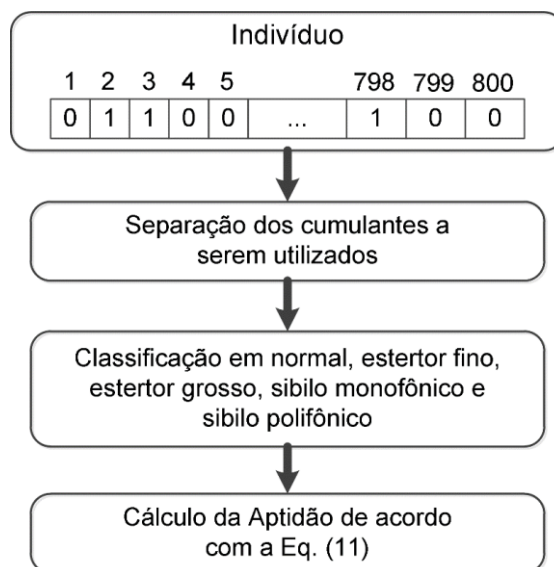


Figura 21 Avaliação do indivíduo

Após a etapa de redução da dimensionalidade, os dados foram separados em dois subconjuntos, dados de treinamento e validação. Para treinamento, foram utilizados 70% dos dados e para validação foram utilizados os 30% restantes. Para os sinais normais, estertores finos, estertores grossos, sibilos monofônicos e sibilos polifônicos, os dados de treinamento representam, respectivamente, 71, 39, 39, 35 e 35 eventos, enquanto que, para validação, os dados representam, respectivamente, 31, 18, 18, 16 e 16 eventos.

A etapa de classificação dos sinais foi feita pelos métodos k -NN, classificador bayesiano e árvores de decisão. Para o classificador k -NN, foi utilizada a distância euclidiana e o valor de k foi escolhido como 5. Para o classificador bayesiano, foi adotada a distribuição gaussiana e probabilidades, a priori, uniforme. Para o classificador árvore de decisão, foi utilizado o algoritmo de classificação *Classification and Regression Trees* - CART e o vetor de pesos das observações com valor 1. Por último, foi feito o cálculo da aptidão pela equação que determina a avaliação de cada indivíduo, Eq. (11).

Para fins de comparação com o AG, a LDA, apresentada na subseção 2.3.3 é também utilizada para a tarefa de redução da dimensionalidade. O objetivo foi selecionar o mesmo número de cumulantes selecionados pelo AG, por meio da LDA, para, então, verificar e comparar o desempenho de cada um dos métodos.

Por fim, foram propostas duas abordagens dividir para conquistar para a tarefa de classificação. Na primeira abordagem, os classificadores acima mencionados foram organizados em uma estrutura em árvore e, na segunda abordagem, foi proposta uma classificação hierárquica (em árvore) utilizando SVM.

Para esse classificador, foi utilizada a função kernel linear e o algoritmo usado para encontrar o hiperplano de separação foi o SMO *Sequential Minimal Optimisation*.

Para a comparação dos métodos propostos, utilizando o conjunto de dados obtido (total de 318 eventos), 20 conjuntos com diferentes dados de treinamento e validação foram gerados aleatoriamente. Esses conjuntos foram gerados para avaliar e comparar o desempenho dos classificadores.

4 RESULTADOS E DISCUSSÃO

Após a obtenção do banco de dados (sons pulmonares) e seu posterior processamento, conforme discutido no Capítulo 3, foi realizada a redução da dimensionalidade por meio do AG ou LDA. No entanto, para executar essa tarefa com AG, alguns parâmetros do mesmo devem ser ajustados como: tipos de seleção, cruzamento e mutação e suas respectivas probabilidades. Esses parâmetros influenciam o desempenho do algoritmo e, após vários experimentos utilizando uma população de 100 indivíduos e realizando 50 execuções para cada conjunto de parâmetros, a seguinte configuração foi obtida:

- a) Tipo de seleção = Estocástico Uniforme;
- b) Tipo de mutação = Uniforme;
- c) Tipo de cruzamento = Dois pontos de corte;
- d) Probabilidade de Cruzamento = 0,8;
- e) Probabilidade de Mutação = 0,25;
- f) Número de Gerações = 100;
- g) Tipo de codificação = binária.

Após a execução dos testes para determinar a melhor configuração do AG, a primeira tentativa de construção do classificador consistiu em classificar as 5 classes utilizando apenas um classificador. Para esse fim, foram utilizados os classificadores, árvores de decisão, classificador bayesiano e k -NN.

Para verificar o desempenho dos classificadores e comparar técnicas de redução de dimensionalidade (AG e LDA) três testes foram realizados:

- a) Teste 1: verificação do desempenho do AG. O algoritmo seleciona os cumulantes mais significativos de forma automática, ao minimizar a função custo definida na Eq. (11);
- b) Teste 2: verificação do desempenho da LDA. Com o mesmo número médio de cumulantes obtido pelo AG, para uma comparação justa, os cumulantes são selecionados segundo a LDA. Para aplicação do critério, cada classe foi comparada com todas as outras (abordagem uma contra todas) de forma a obter os cumulantes que melhor representam cada classe. As classes foram divididas conforme apresentado na Tabela 5, sendo que cinco vetores de cumulantes (um para cada classe) foram obtidos e concatenados para a utilização nos classificadores. Quando algum cumulante se repetia entre os cinco vetores, ele foi substituído de forma a manter o número total de cumulantes utilizados pela LDA igual ao obtido pelo AG;
- c) Teste 3: sem redução de dimensionalidade. Nesse caso, os 800 cumulantes foram fornecidos para os classificadores.

Tabela 5 Classes utilizadas pela LDA

CLASSE 1	CLASSE 2 (concatenação de classes)
1° - Classe 1 – som normal	Classe 2 – sibilos (monofônicos e polifônicos) e estertores (grossos e finos)
2° - Classe 1 – sibilo monofônico	Classe 2 – som normal, sibilo polifônico e estertores (grossos e finos)
3° - Classe 1 – sibilo polifônico	Classe 2 – som normal, sibilo monofônico e estertores (grossos e finos)
4° - Classe 1 – estertor fino	Classe 2 – som normal, sibilos (monofônicos e polifônicos) e estertor grosso
5° - Classe 1 – estertor grosso	Classe 2 – som normal, sibilos (monofônicos e polifônicos) e estertor fino

Desse modo, foram realizados os testes com os 3 classificadores, árvore de decisão, classificador bayesiano e k -NN. Os resultados médios de treinamento e validação (sobre os 20 subconjuntos) são ilustrados na Tabela 6.

Tabela 6 Testes realizado com os classificadores: árvore de decisão, classificador bayesiano e k -NN. Resultados mostram acerto de classificação em porcentagem e seus respectivos desvios padrões

Classificador	Teste	AG	LDA	Treinamento (%)	Validação (%)	Cumulantes
Árvore de Decisão	1	Sim	Não	92 ± 1,1	79,4 ± 1,4	168,4 ± 4,6
	2	Não	Sim	90,1 ± 1,1	69,1 ± 1,5	168
	3	Não	Não	95,2 ± 1,8	74,5 ± 3,5	800
Classificador Bayesiano	1	Sim	Não	93,6 ± 0,7	88,4 ± 1,1	219,3 ± 7,9
	2	Não	Sim	75,2 ± 4,2	65,4 ± 3,9	220
	3	Não	Não	89,2 ± 1,5	79,9 ± 3,2	800
k -NN	1	Sim	Não	91,1 ± 0,7	86,6 ± 1,3	310,6 ± 8,7
	2	Não	Sim	81,2 ± 1,9	62,6 ± 1,8	310
	3	Não	Não	81,6 ± 1,4	67,2 ± 1,4	800

Ao analisar os resultados obtidos, fica evidente que o Teste 1 (uso do AG), que faz o uso do AG como ferramenta para a redução do vetor de características, superou os outros testes.

Ao comparar os Testes 1 (uso do AG) e 2 (uso da LDA), observa-se que o AG se sobressai sobre a LDA na tarefa de redução da dimensionalidade por não necessitar estipular *a priori* um valor do número de características (cumulantes) a serem utilizadas pelos classificadores, pois sua escolha é automática. Além disso, o AG seleciona as melhores características dentre as 800 possíveis, sem depender muito da estrutura dos diferentes classificadores, pois a escolha é baseada no desempenho deles ao classificar os dados. Os resultados mostraram que os classificadores treinados com cumulantes selecionados por AG obtiveram melhores resultados em dados de treinamento e validação.

No Teste 2 (uso da LDA), o número de cumulantes foi selecionado de acordo com o número médio de cumulantes selecionado pelo AG. Para o classificador árvore de decisão, foram utilizados 168 cumulantes e, em cada um dos 5 vetores obtidos por LDA, foram utilizados aproximadamente 34 cumulantes não repetidos. Para o classificador bayesiano, foram utilizados 220 cumulantes e, para cada um dos 5 vetores, 44 cumulantes foram utilizados. Para o classificador k -NN, foram utilizados 310 cumulantes e, para cada um dos 5 vetores, 62 cumulantes foram utilizados. Na Figura 22, ilustra-se o processo de seleção dos cumulantes para o classificador bayesiano, aplicando o LDA utilizando a abordagem uma classe contra todas as outras classes.

1 ^a	Classe 1 – som normal	Classe 2 – sibilos (monofônicos e polifônicos) e estertores (grossos e finos)	1	2	44	799	800	Ranking LDA
			12	455	...	56	...	Índice Cumulante
						247	58	
2 ^a	Classe 1 – sibilo monofônico	Classe 2 – som normal, sibilo polifônico e estertores (grossos e finos)	1	2	44	799	800	Ranking LDA
			98	319	...	79	...	Índice Cumulante
						42	58	
3 ^a	Classe 1 – sibilo polifônico	Classe 2 – som normal, sibilo monofônico e estertores (grossos e finos)	1	2	44	799	800	Ranking LDA
			35	715	...	11	...	Índice Cumulante
						781	58	
4 ^a	Classe 1 – estertor fino	Classe 2 – som normal, sibilos (monofônicos e polifônicos) e estertor grosso	1	2	44	799	800	Ranking LDA
			2	618	...	49	...	Índice Cumulante
						420	43	
5 ^a	Classe 1 – estertor grosso	Classe 2 – som normal, sibilos (monofônicos e polifônicos) e estertor fino	1	2	44	799	800	Ranking LDA
			10	18	...	7	...	Índice Cumulante
						68	44	

Figura 22 Seleção dos cumulantes pela LDA (abordagem uma classe contra todas)

Ao comparar os Testes 2 (uso da LDA) e 3 (sem redução da dimensão), nota-se que o terceiro teste alcançou resultados melhores que com o uso da LDA, mas, por outro lado, utiliza um número bem maior de cumulantes, o que aumenta o custo computacional.

Ao finalizar esta etapa de testes, conclui-se que a melhor opção na tarefa de classificação de sons pulmonares consiste no uso do AG. Em posse desses resultados, foi realizado o teste de Tukey (Figura 23), que comprovou que as amostras são estatisticamente diferentes (nível de confiança de 95%) e que o resultado obtido pelo classificador bayesiano foi estatisticamente melhor que os resultados obtidos pelos classificadores k -NN e árvores de decisão.

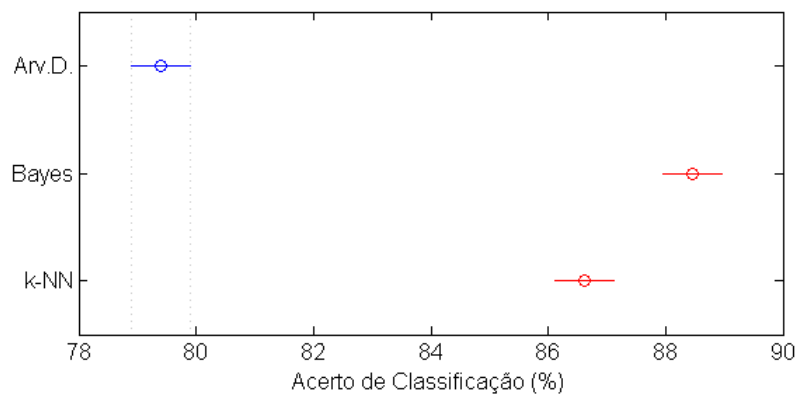


Figura 23 Teste de Tukey (95% de confiança) dos resultados obtidos pelos classificadores: árvore de decisão, classificador bayesiano e k -NN. Os cumulantes foram selecionados por meio do AG

Assim, com o intuito de melhorar o desempenho de classificação, foi proposta uma abordagem dividir para conquistar, em que os melhores classificadores foram utilizados para tentar dividir um problema maior em problemas menores e menos complexos. A metodologia proposta será descrita na seção 4.1.

4.1 Abordagem dividir para conquistar

Com o objetivo de definir os melhores classificadores para determinadas classes de sons pulmonares, foram criadas várias combinações de classes e cada combinação foi testada utilizando os três classificadores implementados. Em todos os testes realizados, os cumulantes mais significativos foram selecionados pelo AG.

Esses testes foram importantes para demonstrar como cada tipo de classe se comporta com outra na tarefa de classificação. Por exemplo, no primeiro teste realizado, observou-se o desempenho de classificação das classes: som pulmonar normal e som pulmonar adventício; este que englobou sinais contínuos (sibilos monofônicos e sibilos polifônicos) e sinais descontínuos (estertores finos e estertores grossos). Nesse teste, os três classificadores obtiveram bons resultados de treinamento e validação, conforme pode ser observado na Tabela 7.

A partir desse teste, foi investigado o comportamento dos sinais adventícios. O objetivo foi verificar como as classes dos sinais contínuos (sibilos) e descontínuos (estertores) se comportariam em relação ao sinal normal. Desse modo, foi realizado o segundo teste com a classe adventício contínuo (sibilos monofônicos e sibilos polifônicos) e classe som pulmonar normal. Do mesmo modo foi realizado o terceiro teste com a classe adventício descontínuo (estertores finos e estertores grossos) e classe som pulmonar normal. Nesses testes, todos os classificadores obtiveram bons resultados de treinamento e validação (Tabela 7). Com esses resultados, foi possível concluir que os sinais adventícios são bem separáveis dos sinais normais usando cumulantes.

Tabela 7 Testes realizados com os classificadores: árvore de decisão, classificador bayesiano e k-NN

CLASSES		Árv. Decisão	Bayes	k-NN	
1	Normal	Treinamento	100	100	100
	x	Validação	93,4±1,1	93,6±1,2	93,8±1,1
	Adventícios	Nº Cumulantes	123,4±2,5	134,8±2,8	153,6±3,2
2	Sibilos	Treinamento	100	100	100
	(Monofônico e Polifônico)	Validação	98,6±1,3	98,6±1,3	97,8±1,2
	x	Nº Cumulantes	131±2,7	133,6±2,2	150,6±3,4
3	Normal	Treinamento	100	100	100
	(Grossos e Finos)	Validação	98,6±1,2	98,8±1,1	98,9±1,1
	x	Nº Cumulantes	127,6±2,4	125±2,6	131,4±3,5

Os testes seguintes tiveram por objetivo verificar como os sinais adventícios se comportam entre si.

Nessa modalidade, o primeiro teste consistiu em analisar o comportamento dos sinais adventícios contínuos, sibilo monofônico contra sibilo polifônico. Os testes revelaram que o classificador bayesiano obteve melhor desempenho em relação aos classificadores árvore de decisão e *k*-NN (Tabela 8).

No segundo teste, foi analisado o comportamento dos sinais adventícios descontínuos, estertor grosso contra estertor fino. Assim como no primeiro teste, foi revelado que o classificador bayesiano obteve melhor desempenho em relação aos classificadores, árvore de decisão e *k*-NN (Tabela 8).

Assim, foi realizado um último teste nessa modalidade, para verificar o comportamento de classificação de 3 classes: normal, adventícios contínuos (sibilos monofônicos e sibilos polifônicos) e adventícios descontínuos (estertores finos e estertores grossos). Nesse teste, o classificador *k*-NN obteve melhor desempenho em relação aos outros classificadores (Tabela 8).

Por meio desses resultados, foi possível concluir que, para a tarefa de classificação de sinais normais, sinais adventícios contínuos e sinais adventícios descontínuos, os classificadores bayesiano e k -NN mostraram um desempenho superior em relação ao classificador árvore de decisão.

Tabela 8 Testes realizados entre as classes de sinais adventícios

CLASSES			Árv. Decisão	Bayes	k -NN
1	Sibilo Monofônico x	Treinamento	92,3±1,2	93,1±1,2	91,1±1,3
		Validação	80,1±1,1	89,9±2,6	84,8±1,2
	Sibilo Polifônico	Nº Cumulantes	124,1±2,3	166,4±3,3	182,4±3,4
2	Estertor Fino x	Treinamento	94,2±1,2	94,1±0,7	86,1±1,2
		Validação	77,4±1,2	90,1±2,3	71,5±2,6
	Estertor Grosso	Nº Cumulantes	132,5±2,1	167,3±3,8	253,2±5,8
3	Normal x	Treinamento	94,7±1,1	94,9±1,2	95,2±1,6
		Sibilos	Validação	85,4±1,1	90,1±1,5
	Estertores	Nº Cumulantes	132,3±2,2	203,2±3,4	225,5±10,4

Em posse dos resultados, foi proposta uma abordagem dividir para conquistar que utiliza os melhores resultados alcançados pelos classificadores bayesiano e k -NN. O classificador árvore de decisão, por ter alcançado desempenho inferior aos outros dois classificadores, não foi utilizado nessa implementação.

Assim, uma árvore de classificação (Figura 24) foi definida a partir dos resultados das Tabelas 7 e 8. Nessa árvore, cada nodo implementa um método de classificação.

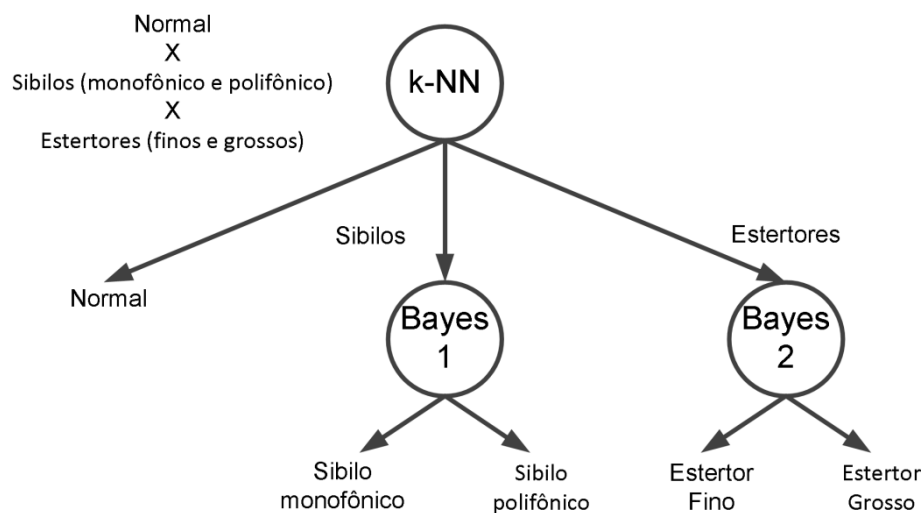


Figura 24 Árvore de classificação

No primeiro passo (nó 1), o som pulmonar é classificado como uma das três classes: som normal, sibilos (monofônico e polifônico) ou estertores (grossos e finos) pelo classificador k -NN. Para esse nó, os resultados médios de treinamento e validação obtidos foram $95,2\% \pm 1,6$ e $90,9\% \pm 1,6$, respectivamente, com $225,5 \pm 10,4$ cumulantes selecionados.

Embora o número de cumulantes utilizados pelo classificador seja ainda elevado, é importante notar que o espaço de características foi consideravelmente reduzido (800 características para cerca de 220). O desempenho em validação sugere que o classificador alcançou uma boa capacidade de generalização.

Após o primeiro passo, se o som pulmonar for classificado como sibilo, o classificador (nó 2) é responsável pela determinação da classificação do som em sibilo monofônico ou sibilo polifônico. O classificador bayesiano (Bayes 1) é empregado nessa tarefa de classificação. Os resultados médios de treinamento e validação obtidos foram $93,1 \pm 1,2$ e $89,9 \pm 2,6$, respectivamente, com $166,4 \pm 3,3$ cumulantes selecionados.

Se o som pulmonar for classificado como estertor, no próximo passo, outro classificador (nó 3) é responsável pela classificação do som em estertor fino ou estertor grosso. Essa tarefa de classificação também é realizada pelo classificador bayesiano (Bayes 2). Os resultados médios de treinamento e validação obtidos foram $94,1 \pm 0,7$ e $90,1 \pm 2,3$, respectivamente, com $167,3 \pm 3,8$ cumulantes selecionados.

O desempenho geral de treinamento e validação da árvore de classificação foi $94,1\% \pm 1,1$ e $91,1\% \pm 2,3$, respectivamente. Para implementar os três classificadores, a árvore de classificação requer, em média, o uso de 395 cumulantes, em que alguns são usados em mais de um classificador. A matriz de confusão obtida utilizando os conjuntos de validação é apresentada na Tabela 9.

Tabela 9 Matriz de confusão de desempenho em dados de validação

SONS	S. N.	E. F.	E. G.	S. M.	S. P.	Validação
S. N.	$28,8 \pm 0,8$	0	0	$2,2 \pm 0,8$	0	$92,9\% \pm 2,1$
E. F.	0	$16,3 \pm 0,7$	$1,7 \pm 0,7$	0	0	$90,5\% \pm 2,3$
E. G.	0	$1,8 \pm 0,6$	$16,2 \pm 0,6$	0	0	$89,7\% \pm 2,3$
S. M.	0	0	0	$14,5 \pm 0,6$	$1,5 \pm 0,6$	$90,3\% \pm 2,5$
S. P.	0	0	0	$1,7 \pm 0,9$	$14,3 \pm 0,9$	$89,6\% \pm 2,6$
D. G.						$91,1\% \pm 2,3$

Nota: Os resultados mostram o número de eventos e o respectivo desvio padrão classificado em cada classe. S. N. – som normal, E. F. – estertor fino, E. G. – estertor grosso, S. M. – sibilo monofônico, S.P. – sibilo polifônico, D.G. – desempenho geral.

Pode-se inferir, a partir dessa tabela, que a abordagem proposta de classificação de sons pulmonares alcançou bom desempenho superando os classificadores que não utilizaram a estratégia de dividir para conquistar e, além disso, é possível verificar que quando se trata de sinais adventícios, ou seja, sinais pulmonares relacionados a alguma doença o sistema de classificação não o classificou como sendo um sinal normal.

Ao finalizar os 20 testes que determinaram a árvore de classificação, foi realizada uma análise de quais cumulantes foram mais selecionados para cada um dos classificadores k -NN, Bayes 1 e Bayes 2, utilizados na abordagem dividir para conquistar. Esse resultado é ilustrado na Tabela 10, que apresenta o número médio de cumulantes de 2^a, 3^a e 4^a ordem selecionados para cada um desses classificadores.

Tabela 10 Cumulantes selecionados

Classificador	Cumulante 2^a ordem	Cumulante 3^a ordem	Cumulante 4^a ordem
k -NN	46,1 ± 4,8	79,1 ± 9,4	83,8 ± 9,1
Bayes 1	35,7 ± 5,1	69,8 ± 8,7	59,1 ± 6,1
Bayes 2	34,7 ± 7,1	66,7 ± 7,8	69,5 ± 8,7

Ao analisar os resultados, é possível concluir que os cumulantes de 3^a e 4^a ordem são mais selecionados que os cumulantes de 2^a ordem. Os cumulantes de 3^a ordem são responsáveis por capturar as diferenças entre as distribuições dos dados no que tange à simetria. Os cumulantes de 4^a ordem medem a distância da distribuição dos dados de uma gaussiana. Por meio desses resultados, conclui-se que os cumulantes de 2^a, 3^a e 4^a ordem se completam no processo de classificação.

Ademais, como o cálculo dos cumulantes é uma tarefa computacionalmente simples (Ribeiro et al. 2007), torna-se viável a aplicação do classificador proposto em um sistema embarcado. Ademais, por ser um problema dividido em partes, cada uma destas pode ser modificada ou atualizada sem que o desempenho das outras partes seja prejudicado.

A comparação dos resultados obtidos neste trabalho com os trabalhos de outros pesquisadores é uma tarefa difícil. Isso se deve ao fato de os sons

respiratórios utilizados serem classificados de formas diferentes ou quando é utilizado um banco de dados diferente.

Nos trabalhos de Jin, Sattar e Goh (2014); Quandt et al. (2012); Xiaoguang e Bahoura (2008), os sinais são classificados em um número menor de classes. No trabalho de Jin, Sattar e Goh (2014) foi alcançado 97,7% a 98,8% em acerto médio de classificação dos sinais. No trabalho de Quandt et al. (2012) os resultados de acerto de classificação obtidos foram de 70% para estertores grossos, 60% para estertores finos e 100% para sons normais. No trabalho de Xiaoguang e Bahoura (2008) foram obtidos 91,5% em resultado de acerto de classificação.

No entanto, vale ressaltar que a abordagem proposta alcançou resultados competitivos, mesmo usando apenas uma ferramenta de extração de características (EOS) e, além disso, a abordagem proposta lida com mais classes de sons pulmonares do que são normalmente encontrados em trabalhos desenvolvidos nessa área.

Para fins de comparação da técnica apresentada com outra abordagem dividir para conquistar um classificador SVM hierárquico é também proposto. Os detalhes serão descritos na seção 4.2.

4.2 Uma abordagem SVM hierárquica

Ao utilizar o SVM para a classificação de todas as classes, foi utilizada uma abordagem hierárquica que permite classificar um conjunto de múltiplas classes em vários conjuntos de duas classes. Desse modo, foi possível utilizar a abordagem básica de classificação binária do SVM.

Após alguns testes, uma árvore de classificação (Figura 25) foi definida, em que cada nodo utiliza um classificador SVM binário. Foram realizadas várias

combinações de agrupamento de classes com o SVM para chegar à árvore de classificação que apresentou o melhor desempenho.

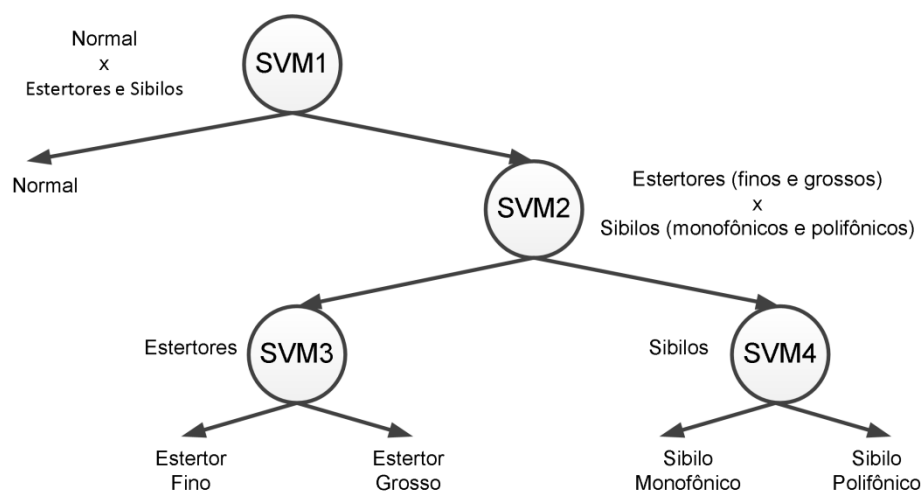


Figura 25 Árvore de classificação SVM hierárquica

No primeiro passo (nó 1), o som pulmonar é classificado como uma das duas classes: som normal ou adventícios pelo classificador SVM 1. Para esse nó, os resultados médios de treinamento e validação obtidos foram $95,92\% \pm 0,25$ e $92,13\% \pm 2,04$, respectivamente, com $120,9 \pm 6,47$ cumalantes selecionados.

Após o primeiro passo, se o som pulmonar for classificado como adventício, o classificador SVM 2 (nó 2) é responsável pela determinação da classificação do som em estertores ou sibilos. Os resultados médios de treinamento e validação obtidos foram $94,53\% \pm 0,69$ e $90,66\% \pm 2,01$, respectivamente, com $124,7 \pm 5,75$ cumalantes selecionados.

Se o som pulmonar for classificado como estertor, o classificador SVM 3 (nó 3) é responsável pela determinação da classificação do som em estertor fino ou estertor grosso. Para o nó 3, os resultados médios de treinamento e

validação obtidos foram $95,1\% \pm 0,73$ e $90,35\% \pm 3,37$, respectivamente, com $122,9 \pm 5,17$ cumulantes selecionados.

Por fim, se o som pulmonar for classificado como sibilos, o classificador SVM 4 (nó 4) é responsável pela determinação da classificação do som em sibilo monofônico ou sibilo polifônico. Nesse nó, os resultados médios de treinamento e validação obtidos foram $91,8\% \pm 0,32$ e $85,69\% \pm 3,23$, respectivamente, com $127,3 \pm 5,07$ cumulantes selecionados.

A acurácia geral de validação da árvore de classificação com SVM foi $92,15 \pm 1,28$. Para implementar os quatro classificadores, a árvore de classificação requer em média o uso de 385 cumulantes, em que alguns são usados em mais de um classificador. A matriz de confusão obtida utilizando os conjuntos de validação do SVM hierárquico é apresentada na Tabela 11.

Tabela 11 Matriz de confusão de desempenho em dados de validação. Os resultados mostram o número de eventos e o respectivo desvio padrão classificado em cada classe. S. N. – som normal, E. F. – estertor fino, E. G. – estertor grosso, S. M. – sibilo monofônico, S.P. – sibilo polifônico, D.G. – desempenho geral

SONS	S. N.	E. F.	E. G.	S. M.	S. P.	Validação
S. N.	$29,1 \pm 0,3$	0	0	$1,9 \pm 0,3$	0	$93,9 \pm 1,4$
E. F.	0	$16,7 \pm 0,4$	$1,3 \pm 0,4$	0	0	$92,7 \pm 1,4$
E. G.	0	$1,3 \pm 0,5$	$16,7 \pm 0,5$	0	0	$92,8 \pm 1,3$
S. M.	0	0	0	$14,5 \pm 0,4$	$1,5 \pm 0,4$	$90,6 \pm 0,6$
S. P.	0	0	0	$1,8 \pm 0,4$	$14,2 \pm 0,4$	$88,7 \pm 1,3$
D. G.						$92,15 \pm 1,28$

Pode-se inferir, a partir da Tabela 11, que essa abordagem proposta de classificação de sons pulmonares também alcançou bom desempenho e assim como na abordagem dividir para conquistar é possível verificar que quando se trata de sinais adventícios, ou seja, sinais pulmonares relacionados a alguma

doença o sistema de classificação SVM hierárquica não o classificou como sendo um sinal normal.

Comparando-se os resultados das abordagens dividir para conquistar com a abordagem hierárquica do SVM, observa-se que, em geral, os resultados de acerto de validação estão próximos, o que mostra a eficiência de ambas as abordagens na tarefa de classificação de sons pulmonares.

5 CONCLUSÃO

Neste trabalho, uma abordagem de classificação dividir para conquistar para sons pulmonares foi desenvolvida. A técnica proposta emprega Estatísticas de Ordem Superior (cumulantes de segunda, terceira e quarta ordens) combinadas com métodos de classificação. Os cumulantes selecionados se mostraram eficazes em representar os sons pulmonares.

Dois métodos de classificação foram implementados para construir uma árvore de classificação para sons pulmonares. O classificador bayesiano e o k -NN foram usados para este propósito. O k -NN é um classificador simples, eficaz e também robusto ao ruído. O classificador bayesiano também é simples, eficaz e rápido tanto no treinamento quanto na avaliação de novos padrões de entrada.

O Algoritmo Genético foi utilizado com sucesso para selecionar os melhores cumulantes que constituem o vetor de características a ser utilizado nos classificadores. A configuração dos parâmetros do AG foi importante para os bons resultados alcançados, pois uma má configuração desses parâmetros poderia influenciar de forma negativa no resultado obtido e no tempo de execução.

Neste trabalho, também foi proposta uma abordagem de classificação hierárquica para sons pulmonares, utilizando o classificador SVM. Esse classificador apresenta as vantagens de possuir alto poder de generalização, robustez e capacidade de lidar com dados ruidosos. Com o uso do SVM, foram alcançados bons resultados de classificação dos sinais pulmonares, ao utilizar uma abordagem hierárquica.

A função *fitness* utilizada cumpriu seu objetivo de maximizar o desempenho da classificação e reduzir o espaço de características. Assim, as abordagens propostas alcançaram bons resultados, mesmo utilizando apenas uma ferramenta de extração de características (EOS). Além disso, as abordagens

propostas classificam mais sons pulmonares que boa parte dos trabalhos desenvolvidos na área.

Como trabalhos futuros, espera-se implementar essa técnica de reconhecimento de padrões de sons pulmonares em um dispositivo portátil e classificar mais tipos de sons pulmonares adventícios. Uma outra possível continuidade deste trabalho é acrescentar outras técnicas de extração de características para serem selecionadas pelo AG.

REFERÊNCIAS

ALSMADI, S.; KAHYA, Y. P. Design of a DSP-based instrument for real-time classification of pulmonary sounds. **Computers in Biology and Medicine**, Elmsford, v. 38, n. 1, p. 53-61, Jan. 2008.

AMARAL, J. L. M. et al. Machine learning algorithms and forced oscillation measurements to categorise the airway obstruction severity in chronic obstructive pulmonary disease. **Computer Methods and Programs in Biomedicine**, Amsterdam, v. 118, n. 2, p. 186-197, Feb. 2015.

AMERICAN THORACIC SOCIETY. Updated nomenclature for membership relation. **ATS News**, United States, v. 3, p. 5-6, 1977.

BAHOURA, M. Pattern recognition methods applied to respiratory sounds classification into normal and wheeze classes. **Computers in Biology and Medicine**, Elmsford, v. 39, n. 9, p. 824-843, Sept. 2009.

BISHOP, C. M. **Neural networks for pattern recognition**. Oxford: Oxford University Press, 1995. 482 p.

BREIMAN, L. et al. **Classification and regression trees**. Belmont: Wadsworth, 1984. 368 p.

CARVALHO, V. O.; SOUZA, G. E. C. O estetoscópio e os sons pulmonares: uma revisão da literatura. **Medicina & Cultura**, São Paulo, v. 86, n. 4, p. 224-31, out./dez. 2007.

CHO, J. H.; KURUP, P. U. Decision tree approach for classification and dimensionality reduction of electronic nose data. **Sensors and Actuators. B, Chemical**, Lausanne, v. 160, n. 1, 542-548, Dec. 2011.

COX, E. **The fuzzy systems handbook: a practitioner's guide to building, using, and maintaining fuzzy systems**. New York: AP Professional, 1994. 626 p.

DALMAY, F. et al. Acoustic properties of normal chest. **European Respiratory Journal**, Copenhagen, v. 8, p. 1761-1769, Mar. 1995.

DEVIJVER, P. A.; KITTLER, J. **Pattern recognition: a statistical approach**. Londres: Prentice-Hall, 1982. 480 p.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2. ed. New York: John Wiley & Sons, 2000. 680 p.

EARIS, J. E.; CHEETHAM, B. M. G. Current methods used for computerized respiratory sound analysis. **European Respiratory Journal**, Copenhagen, v. 10, n. 77, p. 586–590, 2000.

EIBEN, A. E. Evolutionary computing: the most powerful problem solver in the universe? **Dutch Mathematical Archive**, Netherlands, v. 5, v. 2, p. 126-131, May 2002.

ENGELBRECHT, A. P. **Computational intelligence: an introduction**. 2. ed. New York: John Wiley & Sons, 2007. 628 p.

FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of Eugenics**, London, v. 7, n. 2, p. 179-188, Sept. 1936.

FIX, E.; HODGES, J. L. Discriminatory analysis, nonparametric discrimination: consistency properties. **Technical Report**, Texas, v. 4, n. 3, p. 261-279, Jan. 1951.

FIZ, J. et al. Detection of wheezing during maximal forced exhalation in patients with obstructed airways. **Chest**, Chicago, v. 122, p. 186-191, July 2002.

FOGEL, D. B. An introduction to simulated evolutionary computation. **IEEE Transactions on Neural Networks**, New York, p. 3–14, 1994.

FORGACS, P. Crackles and wheezes. **Lancet**, Minneapolis, v. 2, n. 7508, p. 203–205, July 1967.

GABRIEL, P. H. R.; DELBEM, A. C. B. **Fundamentos de algoritmos evolutivos**. São Paulo: Editora da USP, 2008. 33 p.

GALLINARI, P. Training of modular neural net system. In: ARBIB, M. A. (Ed.). **The handbook of brain theory and neural networks**. Cambridge: Bradford Books, 1995. p. 582–585.

GARCIA, E. A. C. **Biofísica**. São Paulo: Sarvier, 2002. 388 p.

GARCIA, V. et al. K-nearest neighbor search: Fast GPU-based implementations and application to high-dimensional feature matching. In: IEEE

INTERNATIONAL CONFERENCE ON, 17., 2010, Hong Kong. **Processing...**
Hong Kong: IEEE, 2010. p. 3757-3760.

GLOBAL ALLIANCE AGAINST CHRONIC RESPIRATORY DISEASES.
Disponível em: <http://www.who.int/gard/GARDGMreport2014_web.pdf>.
Acesso em: 5 maio 2015.

GOLDBERG, D. **Genetic algorithms in search, optimization, and machine learning**. Addison-Wesley Publishing Company, 1989. 432 p.

GUYTON, A. C.; HALL, J. E. **Textbook of medical physiology**. 11. ed.
Philadelphia: Elsevier Saunders, 2006. 1152 p.

HADJILEONTIADIS, L. J.; PANAS, S. M. Higher-order statistics: a robust vehicle for diagnostic assessment and characterisation of lung sounds. **Technology and Health Care Journal**, New York, v. 5, n. 5, p. 359-374, Nov. 1997.

HAIR, J. F. et al. **Multivariate data analysis**. 7. ed. Prentice Hall, 2009. 816 p.

HAMPSHIRE, J. B.; WAIBEL, A. The meta-pi network: building distributed knowledge representations for robust multisource pattern recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, New York, v. 14, n. 7, p. 751-769, July 1989.

HASHEMI, A.; ARABALIBEIK, H.; AGIN, K. Classification of wheeze sounds using cepstral analysis and neural networks. **Studies in Health Technology & Informatics. Medicine Meets Virtual Reality**, Oxford, v. 19, n. 173, p. 161-165, Feb. 2012.

HOLLAND, J. H. **Adaptation in natural and artificial systems**. The University of Michigan Press, 1975. 183 p.

IÇER, S.; GENGEÇ, S. Classification and analysis of non-stationary characteristics of crackle and rhonchus lung adventitious sounds. **Digital Signal Processing**, New York, v. 28, p. 18-27, May 2014.

JACOBS, R. A. et al. Adaptive mixtures of local experts. **Neural Computation**, Cambridge, v. 3, n. 1, p. 79-87, Mar. 1991.

JACOBS, R. A.; JORDAN, M. I.; BARTO, A. G. Task decomposition through competition in a modular connectionist architecture: the what and where vision tasks. **Cognitive Science**, Norwood, v. 15, n. 2, p. 219–250, Apr. 1991.

JIN, F.; SATTAR, F.; GOH, D. Y. T. New approaches for spectro-temporal feature extraction with applications to respiratory sound classification. **Neurocomputing**, Amsterdam, v. 123, p. 362-371, Jan. 2014.

KAHYA, Y. P. et al. Comparison of different feature sets for respiratory sound classifiers. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE EMBS, 25., 2003, Cancun. **Proceedings...** Cancun: IEEE, 2003. p. 2853–2856.

KANDASWAMY, A. et al. Neural classification of lung sounds using wavelet coefficients. **Computer in Biology and Medicine**, Amsterdam, v. 34, n. 6, p. 523-537, July 2004.

KASABOV, N. K. **Foundations of neural networks, fuzzy systems, and knowledge engineering**. Cambridge: Massachusetts Institute of Technology, 1996. 568 p.

KHATTREE, R.; NAIK, D. N. **Multivariate data reduction and discrimination with SAS software**. Cary: SAS Institute, 2000. 558 p.

LAËNNEC, R. T. H. **De l'auscultation médiate ou traité du diagnostic des maladies des poumons et du coeur, fondé principalement sur un nouveau moyen d'exploration**. Paris: Brossonet Chaudé, 1819.

LEE, Y. et al. Fast and efficient lung disease classification using hierarchical one-against-all support vector machine and cost-sensitive feature selection, **Computers in Biology and Medicine**, Elmsford, v. 42, n. 12, p. 1157-1164, Dec. 2012.

LEHRER, S. **Entendendo os sons pulmonares**. 3. ed. São Paulo: Roca, 2004. 174 p.

LINDEN, R. **Algoritmos genéticos: uma importante ferramenta da inteligência computacional**. 2. ed. Rio de Janeiro: Brasport, 2006. 348 p.

MARTINEZ-HERNANDEZ, H. et al. Computerized classification of normal and abnormal lung sounds by multivariate linear autoregressive model. In: IEEE ENGINEERING IN MEDICINE AND BIOLOGY ANNUAL CONFERENCE, 27., 2005, Shanghai. **Proceedings...** Shanghai: IEEE, 2005.

MENDEL, J. M. Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications. **Proceedings of the IEEE**, New York, v. 79, n. 3, p. 278-305, 1991.

MICHALEWICZ, Z.; SCHOENAUER, M. Evolutionary algorithms for constrained parameter optimization problems. **Evolutionary Computation**, Cambridge, v. 4, n. 1, p. 1–32, Mar. 1996.

MIKAMI, R. et al. International symposium on lung sounds. Synopsis of proceedings. **Chest**, Chicago, v. 92, n. 2, p. 342-345, Aug. 1987.

MITCHELL, T. **Machine learning**. New York: McGraw-Hill Education, 1997. 414 p.

NAVES, R.; BARBOSA, B. H. G.; FERREIRA D. D. Implementação de um sistema de reconhecimento de padrões baseado em redes neurais artificiais para classificação de sons pulmonares. In: CONGRESSO DE PÓS-GRADUAÇÃO DA UFPA, 23., 2014, Lavras. **Anais...** Lavras: 2014b.

NAVES, R.; BARBOSA, B. H. G.; FERREIRA, D. D. Classificação de sons pulmonares utilizando estatísticas de ordem superior e árvores de decisão. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 20., 2014, Belo Horizonte. **Anais...** Belo Horizonte: CBA, 2014a.

NOGUEIRA, M. L.; SAAVEDRA, O. R. Estratégias evolutivas aplicadas à resolução de otimização multimodal. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 1999, São Paulo. **Anais...** São Paulo: SBAI, 1999.

PRATT, L. Y.; MOSTOW, J.; KAMM, C. A. Direct transfer of learned information among neural networks. In: NINTH NATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE, 1991, Anaheim. **Proceedings...** Anaheim: AAAI, 1991. p. 584–589.

QUANDT, V. I. et al. Reconhecimento de padrões em sons pulmonares utilizando Wavelets, LDA E k-NN. In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA, 23., 2012, Porto de Galinhas. **Anais...** Porto de Galinhas: CBEB, 2012. p. 1894-1898.

RECHENBERG, I. **Evolutions strategie**: optimierung technis chersys temenach prinzipien der biologischen evolution. Berlin: Frommann-Holzboog, 1973. 170 p.

REYES, B. A. et al. Assessment of time–frequency representation techniques for thoracic sounds analysis. **Computer Methods and Programs in Biomedicine**, Amsterdam, v. 114, n. 3, p. 276-290, May 2014.

RIBEIRO, M. V. et al. Detection of disturbances in voltage signals for power quality analysis using HOS. **EURASIP Journal on Advances in Signal Processing**, New York, v. 2007, n. 1, p. 1-13, Apr. 2007.

ROGUIN, A. Rene Theophile hyacinthe laënnec (1781-1826): the man behind the stethoscope. **Clinical Medicine & Research**, New York, v. 4, n. 3, p. 230-235, Sept. 2006.

SAKULA, A. RTH laënnec (1781-1826) his life and work: a bicentenary appreciation. **Thorax**, London, v. 36, n. 2, p. 81-90, Feb. 1981.

SCHWEFEL, H. **Evolution and optimum seeking**. John Wiley, 1995. 456 p.

SEN, I.; SARACLAR, M.; KAHYA, Y. P. A comparison of SVM and GMM based classifier configurations for diagnostic classification of pulmonary sounds. **IEEE Transactions on Biomedical Engineering**, Elmsford, v. 62, n. 7, p. 1768-1776, July 2015.

SERBES, G. et al. Pulmonary crackle detection using time–frequency and time–scale analysis. **Digital Signal Processing**, New York, v. 23, n. 3, p. 1012-1021, May 2013.

SEZGIN, M. et al. Classification of respiratory sounds by using an artificial neural network. In: INTERNATIONAL CONFERENCE, 23., 2001, Turkey. **Proceedings...** Istanbul: IEEE, 2001. p. 697-699.

SHARKEY, A. **Combining artificial neural nets: ensemble and modular multinet systems**. New York: Springer-Verlag, 1999. 298 p.

SOVIJÄRVI, A. R. A. et al. Definition of terms for applications of respiratory sounds. **European Respiratory Review**, Copenhagen, v. 10, n. 77, p. 597–610, 2000.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. 4. ed. New York: Academic Press, 2009. 984 p.

VAPNIK, V. N. **The nature of statistical learning theory**. New York: Springer-Verlag, 1995. 314 p.

VILLALOBOS, S. C. et al. Assessment of multichannel lung sounds parameterization for two-class classification in interstitial lung disease patients, **Computers in Biology and Medicine**, Elmsford, v. 41, n. 7, p. 473-482, July 2011.

VISICH, M. A. Knowing what you hear: a guide to assessing breath and heart sounds. **Nursing**, Jenkintown, v. 11, n. 11, p. 64-76, Nov. 1981.

WELSBY, P. D.; PARRY, G.; SMITH, D. The stethoscope: some preliminary investigations. **Postgraduate Medical Journal**, Basingstoke, v. 79, n. 938, p. 695-698, June 2003.

WU, W.; AHMAD, M. O. A Discriminant model for the pattern recognition of linearly independent samples. **Circuits, Systems, and Signal Processing**, Cambridge, v. 31, n. 2, p. 669-687, Apr. 2012.

XIAOGUANG, L.; BAHOURA, M. An integrated automated system for crackles extraction and classification. **Biomedical Signal Processing and Control**, Amsterdam, v. 3, n. 3, p. 244-254, July 2008.

YEGINER, M.; KAHYA, Y. P. Feature extraction for pulmonary crackle representation via wavelet networks, **Computers in Biology and Medicine**, Elmsford, v. 39, n. 8, p. 713-721, Aug. 2009.

YERNAULT, J. C.; BOHADANA, A. B. Chest percussion. **European Respiratory Journal**, Copenhagen, v. 8, n. 10, p. 1756-1760, Oct. 1995.