

INSTITUTO FEDERAL DE SANTA CATARINA

Bruno Alexandre Oechsler

Análise de sons do ciclo cardíaco utilizando técnicas de Aprendizado de Máquina  
para detecção de sopro cardíaco

Gaspar – SC

Novembro de 2018

Bruno Alexandre Oechsler

Análise de sons do ciclo cardíaco utilizando técnicas de Aprendizado de Máquina  
para detecção de sopro cardíaco

Trabalho de Conclusão de Curso  
apresentado ao Curso Superior de  
Tecnologia em Análise e  
Desenvolvimento de Sistemas do  
Câmpus Gaspar do Instituto Federal  
de Santa Catarina como requisito  
parcial para aprovação na unidade  
curricular Trabalho de Conclusão de  
Curso II.

Orientadora: Daniela Sbizera Justo,  
Dra.

Gaspar – SC

Novembro de 2018

O28a Oechsler, Bruno Alexandre

Análise de sons do ciclo cardíaco utilizando técnicas de Aprendizado de Máquina para detecção de sopro cardíaco / Bruno Alexandre Oechsler; orientadora, Daniela Sbizera Justo, 2018.

70 p.

Trabalho de Conclusão de Curso (graduação) – Instituto Federal de Santa Catarina, Câmpus Gaspar, Curso Superior de Tecnologia em Análise e Desenvolvimento de Sistemas, Gaspar, 2018.

Inclui referências.

1. Diagnóstico Impreciso. 2. Sopro cardíaco. 3. Processamento de áudio. 4. Aprendizado de máquina. I. Justo, Daniela Sbizera. II. Instituto Federal de Santa Catarina. Curso Superior de Tecnologia em Análise e Desenvolvimento de Sistemas. III. Título.

CDD 006.3

## RESUMO

A imprecisão em realizar diagnósticos a partir do exame de auscultação cardíaca é um grande problema na área médica. Por meio deste exame, pode-se considerar, erroneamente, um paciente com doença das valvas cardíacas como saudável e, no pior cenário, este não receber o tratamento adequado e vir a óbito. Entretanto, durante o ciclo cardíaco é possível auscultar o sopro cardíaco, que pode indicar a presença de mau funcionamento em uma ou mais valvas do coração. Assim, com o intuito de auxiliar no diagnóstico, neste trabalho são abordados aspectos relevantes para a construção de uma solução para auxiliar os profissionais da área da saúde no diagnóstico de auscultação cardíaca. Para isso, foram realizadas pesquisas e testes em dois campos de estudo: Processamento de Áudio, para obter meios de ler arquivos de áudio e coletar características relevantes; e Aprendizado de Máquina, com o intuito de analisar e encontrar padrões entre os dados para indicar se o paciente possui sopro no coração ou não. Ao fim, o sistema desenvolvido extrai dados da frequência, tonalidade, escala e magnitude do áudio aplicando estes dados no algoritmo Vetor de Suporte Linear para realizar a classificação deste entre com sopro no coração ou normal.

Palavras-chave: Diagnóstico Impreciso. Sopro Cardíaco. Processamento de Áudio. Aprendizado de Máquina.

## **ABSTRACT**

The inaccuracy in performing diagnostics from cardiac auscultation exam is a major problem in the medical field. Through this exam, a patient with heart valve disease, can be considered, erroneously, as healthy and, in the worst scenario, come to die. Considering that in the cardiac cycle it is possible to auscultate a heart murmur, which can indicate the presence of a malfunction in one or more heart valves. This work will discuss aspects that are relevant for the construction of a solution to assist health professionals in the cardiac auscultation diagnostics. To achieve that, research and tests will be carried out in two fields of study: Audio Processing, to obtain means of reading audio files and collecting relevant characteristics; and Machine Learning, in order to analyse and find patterns in data, stating whether the patient has heart murmurs or not. Finally, the developed system extracts data from the frequency, tone, scale and magnitude of the audio by applying this data in the Linear Support Vector algorithm to perform the classification of this between heart murmur or normal.

Keywords: Inaccurate Diagnosis. Heart murmur. Audio Processing. Machine Learning.

## LISTA DE FIGURAS

Figura 1	- Fluxo sanguíneo e anatomia básica do coração .....	13
Figura 2	- Valva mitral (aberta) e as cordas tendíneas .....	15
Figura 3	- Valva aórtica .....	16
Figura 4	- Sinais do ciclo cardíaco .....	20
Figura 5	- Hierarquia de aprendizado .....	26
Figura 6	- Exemplo de fluxo de dados de tarefa de classificação .....	28
Figura 7	- Gráfico de relação peso x altura e linha de melhor ajuste .....	30
Figura 8	- Exemplo de fluxo de dados de tarefa de regressão .....	31
Figura 9	- Exemplo de fluxo de dados de tarefa de associação .....	33
Figura 10	- Exemplo de fluxo de dados de tarefa de agrupamento .....	34
Figura 11	- Exemplo de agrupamento hierárquico .....	35
Figura 12	- Exemplo de agrupamento por densidade e baseado em protótipo .....	35
Figura 13	- Arquitetura e processamento da solução proposta .....	40
Figura 14	- Exemplo de arquivo ARFF .....	50
Figura 15	- Tela inicial do sistema .....	59
Figura 16	- Explorador de arquivos para seleção de arquivo de áudio .....	59
Figura 17	- Exemplo de classificação de arquivo normal .....	60
Figura 18	- Exemplo de plotagem do arquivo informado .....	60

## LISTA DE QUADROS

Quadro 1 - Relação causa de morte x Quantidade de óbitos .....	12
Quadro 2 - Exemplos de tarefas de classificação .....	27
Quadro 3 - Relação entre características desta solução com trabalhos correlatos	38
Quadro 4 - Quantidade de arquivos de áudio em cada grupo .....	47
Quadro 5 - Relação entre algoritmos x corretude na classificação do arquivo ....	57

## LISTA DE ABREVIATURAS E SIGLAS

- AM – Aprendizado de Máquina
- ARFF – *Attribute-Relation File Format*
- CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
- CSV – *Comma-Separated Values*
- DCNT – Doenças Crônicas Não Transmissíveis
- DCV – Doenças Cardiovasculares
- EA – Estenose Aórtica
- EM – Estenose Mitral
- ET – Estenose Tricúspide
- FRS – *Fuzzy Rought Set*
- GPL – *General Public License*
- HMM – *Hidden Markov Model*
- IA – Inteligência Artificial
- IIR – Filtros de Resposta Impulsiva Infinita
- IM – Insuficiência Mitral
- IT – Insuficiência Tricúspide
- JMSL – *Java Music Specification Language*
- MAD – Módulo de Análise de Dados
- MFCC – *Mel Frequency Cepstral Coefficient*
- MPA – Módulo Processador de Áudio
- OMS – Organização Mundial da Saúde
- PVM – Prolapso da Valva Mitral
- SUS – Sistema Único de Saúde
- SQL – *Structure Query Language*
- STFT – Short-Time Fourier Transform
- SVC – *Support Vector Classification*
- TCC – Trabalho de Conclusão de Curso
- WEKA – *Waikato Environment Knowledge for Analysis*

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	7
<b>1.1 Objetivos</b> .....	8
1.1.1 Objetivo Geral.....	8
1.1.2 Objetivos Específicos.....	8
<b>1.2 Justificativa</b> .....	9
<b>2 FUNDAMENTAÇÃO TEÓRICA</b> .....	11
<b>2.1 Sistema Cardiovascular</b> .....	11
2.1.1 O Ciclo Cardíaco.....	13
2.1.2 Valvas Cardíacas.....	14
2.1.3 Doenças das Valvas Cardíacas.....	16
2.1.4 Sopros Cardíacos.....	19
2.1.5 Erro no diagnóstico do sopro Cardíaco.....	21
<b>2.2 Inteligência Artificial</b> .....	22
2.2.1 Aprendizado de Máquina ( <i>Machine Learning</i> ).....	24
2.2.2 Tipos de Aprendizado.....	26
<b>2.3 Processamento de Áudio</b> .....	36
<b>2.4 Trabalhos Correlatos</b> .....	36
<b>2.5 Considerações Finais</b> .....	38
<b>3 MATERIAIS E MÉTODOS</b> .....	39
<b>3.1 Descrição da Solução</b> .....	39
<b>3.2 Requisitos da Solução</b> .....	41
<b>3.3 Estudo de Viabilidade</b> .....	41
3.3.1 Bibliotecas para análise de áudio.....	42
3.3.2 Hidden Markov Model (HMM).....	44
3.3.3 Naive Bayes.....	45
3.3.4. Execução dos Testes.....	45
<b>3.4 Obtenção da Base de Dados</b> .....	45
<b>3.5 Construção dos Módulos e Base de Dados</b> .....	47
3.5.1 Linguagem de Programação Python.....	47
3.5.2 Bibliotecas Utilizadas.....	48
3.5.3 Ferramenta WEKA.....	49
3.5.4 Módulo Processador de Áudio (MPA).....	51
3.5.5 Construção da Base de Dados.....	52
3.5.6 Módulo Analisador de Dados (MAD).....	53
<b>3.6 Considerações Finais</b> .....	55
<b>4 RESULTADOS OBTIDOS</b> .....	56
<b>4.1 Resultados dos testes</b> .....	56
<b>4.2 Interface gráfica</b> .....	58
<b>5 CONCLUSÃO</b> .....	61
<b>REFERÊNCIAS</b> .....	63
<b>GLOSSÁRIO</b> .....	70

## 1 INTRODUÇÃO

Segundo a Organização Mundial da Saúde (OMS), as doenças cardiovasculares (DCV) são um grupo de doenças do coração e dos vasos sanguíneos, as quais são a principal causa de morte do mundo. Em 2015 foi estimado que cerca de 17,7 milhões de pessoas morreram por conta de doenças cardiovasculares, totalizando 31% das mortes no mundo (WORLD..., 2017a).

Dados nacionais indicam que o número de pessoas que sofre de problemas no coração chega a 300 mil por ano. Enfermidades relacionadas ao coração e à circulação sanguínea provocaram 3,5 milhões de mortes entre 2004 a 2014, equivalente a quase 1 mil mortes por dia (BRASIL, 2017).

O próprio sistema cardiovascular pode dar sinais de que o coração está ou não saudável. Um desses sinais é chamado de sopro no coração (MAYO..., 2018a). Sopro no coração é um ruído gerado pelo fluxo sanguíneo entre as válvulas e os vasos cardíacos (MARTINS *et al.*, 2008). “O coração possui quatro válvulas – a válvula aórtica, mitral, pulmonar e tricúspide – que se abrem e fecham para direcionar o fluxo de sangue através do seu coração” (MAYO..., 2018b, não paginado, tradução nossa).

Porém, nem todo caso de sopro no coração aponta problemas cardíacos estruturais ou fisiológicos (PELECH, 2004), ou seja, é um sopro inocente aquele que não está atrelado a anomalias anatômicas e/ou funcionais do sistema cardiovascular (MARTINS *et al.*, 2008).

A partir da análise desse ruído, pode-se ter conhecimento se o sopro é inocente ou se responde a uma doença (MARTINS *et al.*, 2008). A identificação do sopro é comumente realizada por meio do exame clínico da ausculta cardíaca utilizando o estetoscópio, assim, o resultado é mediado a habilidades e capacidades do ouvido humano. No entanto, auscultar este ruído por meio de um estetoscópio requer uma habilidade que profissionais da saúde obtém somente através da experiência (LATHA; SABANAYAGAM; ANEESH, 2017). Até mesmo profissionais experientes acabam não auscultando este ruído, pois a frequência sonora pode estar abaixo da capacidade de percepção do ouvido humano, podendo acarretar em um diagnóstico falho (ISMAIL, 2015).

Este cenário pressupõe a necessidade de instrumentos ou recursos que apoiem o diagnóstico de maneira mais precisa. Neste ínterim, propõe-se um sistema

baseado em algoritmos de classificação os quais, a partir de padrões encontrados nos dados apresentados previamente, infere o resultado para novos dados apresentados. Este sistema visa auxiliar os profissionais da área da cardiologia na obtenção de um diagnóstico mais preciso, informando, a partir da análise do áudio de exame de ausculta cardíaca, se o paciente possui ou não sopros no coração.

## **1.1 Objetivos**

Nesta seção são expostos o objetivo geral e os objetivos específicos a serem desenvolvidos neste trabalho.

### **1.1.1 Objetivo Geral**

A finalidade deste trabalho é projetar e desenvolver um sistema computacional que informará se um paciente possui ou não sopros no coração a partir da extração de dados de arquivos de áudio de exames de ausculta cardíaca e da aplicação de métodos de aprendizado de máquina sobre estes dados para realização de classificação.

### **1.1.2 Objetivos Específicos**

- a) Obter uma base de dados que contenha arquivos de áudio de ausculta cardíaca bem como a classificação de cada um desses arquivos quanto a presença ou não de sopros;
- b) realizar a leitura e extração de atributos do arquivo de áudio que permitam identificar padrões para posterior classificação de acordo com o atributo meta (sopros, saudável);
- c) aplicar métodos de aprendizado de máquina para realizar a análise de dados e que permitam realizar classificação; e
- d) apresentar o resultado obtido após a classificação do arquivo de áudio analisado.

## 1.2 Justificativa

As doenças crônicas não transmissíveis (DCNT) como doenças cardiovasculares, câncer e doenças respiratórias crônicas, afetam fatores sociais e econômicos. Essa vertente é ponderada como um problema da saúde pública a nível mundial (SIQUEIRA *et al.*, 2017).

Erros em diagnóstico ocorrem com menos frequência do que falhas ligadas a procedimentos cirúrgicos ou a medicamentos, porém, é de grande magnitude visto uma vez que 50% das falhas em diagnósticos levam a um dano grave, que pode resultar em lesão permanente ou morte do paciente. Das ocorrências de inexatidão em diagnósticos, 83,3% são consideradas evitáveis, na qual foi reconhecido que a falha humana é a principal causa. Dados apontam que esses erros são regularmente descobertos durante ou após a internação do paciente (ZAMBON, 2014). Na análise de Siqueira *et al.* (2017), no ano de 2015 houve cerca de 1.124.156 internações por DCV no Sistema Único de Saúde (SUS) gerando um valor gasto acima de 2.5 bilhões de reais.

Uma vez entendido que a maior causa de erros em diagnósticos é originário de falha humana, a aplicação de ferramentas que auxiliam na análise inicial do paciente e na diminuição no tempo gasto para definição do mesmo é visto como benéfico, pois poderá reduzir os casos de diagnósticos errados e, conseqüentemente, diminuir gastos com internações e exames desnecessários. Também, essas ferramentas irão contribuir na descoberta de doenças que não seriam possíveis de se detectar somente através da avaliação humana, principalmente na cardiologia em exames de auscultação cardíaca onde pode-se passar despercebido um ruído entre os batimentos cardíacos que pode estar associado a um problema em uma, ou mais, válvulas do coração (KOBINGER, 2003).

O uso de conceitos de Inteligência Artificial (IA) tem crescido em várias áreas, como no setor automobilístico, mídia e comércio eletrônico, reconhecimento facial em redes sociais, sistemas bancários e em indústrias. Com essa gama de áreas abrangidas, surgem, no campo da saúde, mecanismos para apoio em diagnóstico médico (GUARIZI *et al.*, 2014).

No âmbito da saúde está sendo adotado o uso de técnicas provenientes da IA

para obter melhores resultados em diagnósticos. Uma dessas técnicas é a *Machine Learning* (Aprendizado de Máquina, na tradução) que consiste em trazer um novo conhecimento a partir da análise de dados. A aplicação de Aprendizado de Máquina na área médica pode ser feita, por exemplo, para detectar diversos tipos de câncer ou até mesmo doenças oculares, extraíndo-se dados de imagens de exames do paciente e analisando-as de forma a procurar por padrões similares aos que já possui em uma base de conhecimento construída previamente. Outra aplicação na área da saúde se dá na detecção de diabetes, via análise e detecção de padrão em dados numéricos de exame de sangue (FERRARA, 2005). Desta forma, com a utilização da IA aliada a outras técnicas pode ser fornecido, em alguns casos, um diagnóstico mais preciso (OBERMEYER; EMANUEL, 2016).

Com base nos conteúdos que são abordados neste texto, foi possível projetar, analisar e construir uma ferramenta que poderá contribuir tecnológica e cientificamente no campo da saúde. Esta ferramenta fará análise e classificação de exames de auscultação cardíaca, onde esta ferramenta utiliza técnicas de Aprendizado de Máquina e de Processamento de Áudio.

Este trabalho está organizado da seguinte maneira:

- O Capítulo 2 aborda a Fundamentação Teórica que explica sobre o sistema cardiovascular e sobre um sinal que o coração apresenta quando há um mau funcionamento em uma ou mais valvas do coração. Ademais, explana os conceitos de Inteligência Artificial e Aprendizado de Máquina, seus principais tipos de aprendizado e as respectivas tarefas. Apresenta, ainda, apresenta um breve conceito sobre de Processamento de Áudio. O capítulo 2 é finalizado demonstrando trabalhos correlatos, bem como as semelhanças e diferenças entre os trabalhos e este projeto;
- O Capítulo 3 tem por objetivo apresentar a solução desenvolvida, tal como os métodos, base de dados, ferramentas utilizadas e a construção de cada módulo;
- No Capítulo 4 são apresentados os resultados obtidos nos testes da solução e a interface desenvolvida;
- No Capítulo 5 apresenta-se a conclusão deste trabalho além de ser mencionado a cerca de trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo aborda os tópicos referentes à revisão bibliográfica realizada para maior entendimento dos conceitos relacionados ao desenvolvimento deste trabalho. Estes conceitos desdobram-se em dois contextos.

O primeiro contexto refere-se à descrição do sistema cardiovascular, às doenças associadas ao mau funcionamento das valvas cardíacas e ao diagnóstico das mesmas. Neste contexto é dado enfoque à problemática do diagnóstico a partir do resultado do exame para identificação do sopro cardíaco. Todos estes conceitos são apresentados na seção 2.1.

O segundo contexto aborda as tecnologias que estão associadas à proposta de desenvolvimento de um sistema computacional inteligente que seja capaz de processar arquivos de áudio de exames para identificação de sopro. Com o processamento destes arquivos de áudio, pretende-se derivar atributos que sejam úteis para a realização da análise de dados e, por conseguinte, fazer a classificação. Esta classificação indicará se o arquivo de áudio processado resulta ou não na presença de mau funcionamento das valvas cardíacas. Para a realização da classificação, serão aplicadas técnicas de Inteligência Artificial, mais especificamente de Aprendizado de Máquina (*Machine Learning*). Neste sentido, a seção 2.2 apresenta as definições e os conceitos relacionados à Inteligência Artificial, as formas de aprendizado (supervisionado e não supervisionado) e os tipos de tarefa de Aprendizado de Máquina.

Adicionalmente, na seção 2.3 são abordados conceitos e técnicas de processamento de áudio também necessários de compreensão para concepção e elaboração do projeto aqui proposto.

Por fim, são mencionados alguns trabalhos correlatos identificados como estado da arte na seção 2.4.

Para finalizar a seção, apresenta-se na seção 2.5 as considerações finais.

### 2.1 Sistema Cardiovascular

No ano de 2015, foi estimado que, a nível global, houve cerca de 56.4 milhões de mortes, na qual mais da metade está vinculada às dez principais causas. Analisando-se os dados do Quadro 1 vê-se uma relação entre as 10 principais

causas de morte em 2015 e a quantidade de óbitos, percebe-se que doenças relacionadas ao sistema cardiovascular são as que mais matam. Essas doenças estiveram como líder de causas de mortes nos últimos 15 anos (WORLD..., 2017b):

Quadro 1 – Relação causa de morte x Quantidade de óbitos

Causa de morte	Quantidade de óbitos (em milhões)
Doença Cardíaca Isquêmica	8,76
Acidente Vascular Cerebral	6,24
Infecção das Vias Aéreas Superiores	3,19
Doença Pulmonar Obstrutiva Crônica	3,17
Câncer do Pulmão, Traqueia e Brônquios	1,69
Diabetes Mellitus	1,59
Doença de Alzheimer e outras demências	1,54
Doenças Diarreicas	1,39
Tuberculose	1,37
Acidentes de trânsito	1,34

Fonte: adaptado de World... (2017b).

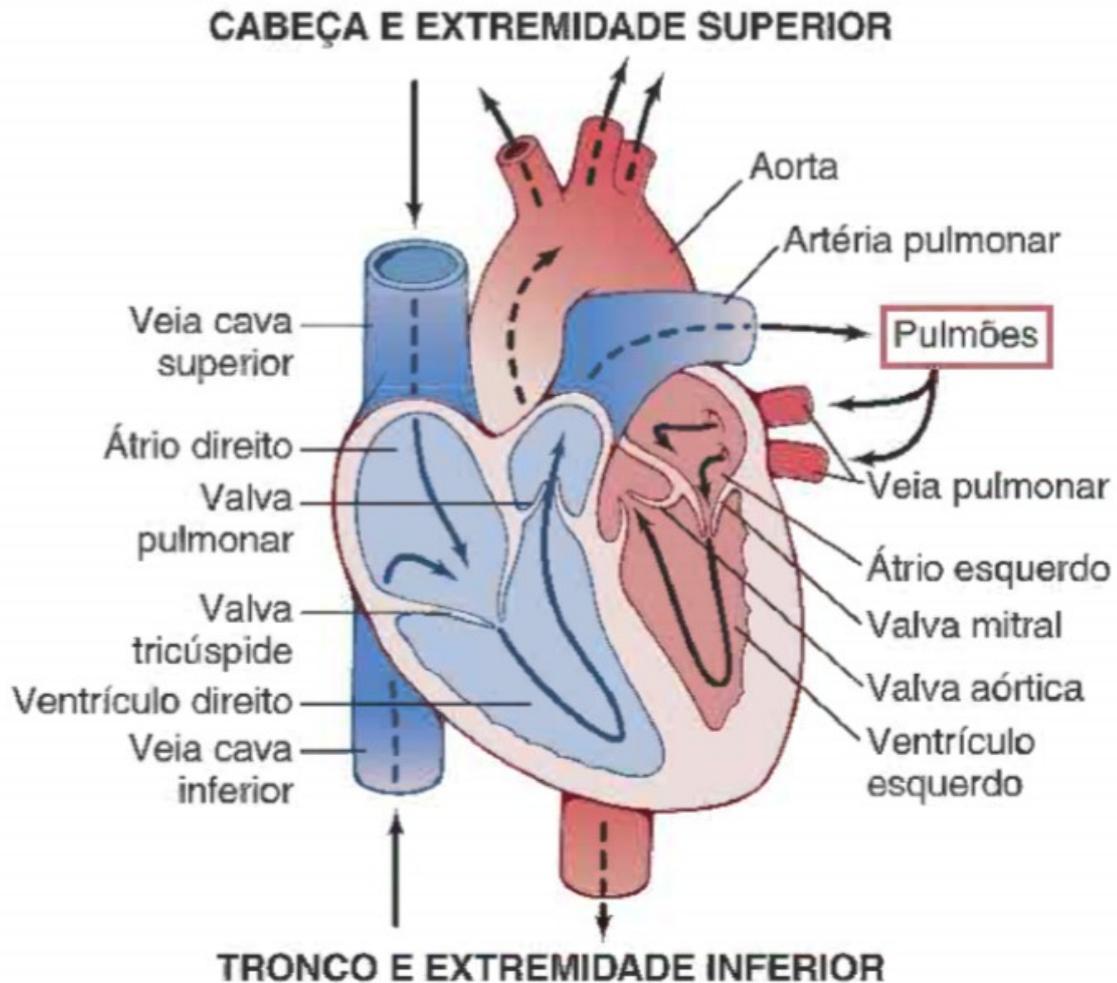
O sistema cardiovascular é responsável pela circulação sanguínea, que transporta oxigênio e nutrientes para todo o corpo, e utiliza os vasos sanguíneos (artérias, arteríolas, capilares, vênulas e veias) para se deslocar. Para que o sangue percorra todo o corpo humano, o coração impulsiona o sangue recebido das veias para as artérias. Assim, o sistema cardiovascular é composto pelos vasos sanguíneos e o coração (MOHRMAN; HELLER, 2007).

O coração é constituído por duas bombas que trabalham de forma independente. Essas bombas são denominadas de coração direito e coração esquerdo. O coração direito é responsável por bombear o sangue para os pulmões e o coração esquerdo tem por sua função bombear o sangue, rico em oxigênio, para os órgãos e demais partes do corpo (HALL, 2011).

Cada uma dessas bombas é constituída por duas câmaras denominadas átrio e ventrículo. O átrio tem por função receber o sangue das veias e o ventrículo tem o serviço de bombear o sangue para fora do coração, para suas respectivas artérias. A Figura 1 apresenta, de forma didática, os átrios direito e esquerdo, ventrículos direito e esquerdo, o fluxo sanguíneo, bem como suas respectivas veias, artérias e valvas

(HALL, 2011).

Figura 1 – Fluxo sanguíneo e anatomia básica do coração



Fonte: Hall (2011, p. 107).

### 2.1.1 O Ciclo Cardíaco

O ciclo cardíaco é composto por uma série de eventos entre o início de um batimento e o início do próximo batimento (HALL, 2011), no qual a força necessária para realizar o bombeamento do sangue procede de movimentos sincronizados e contínuos de contração (**sístole**) e de relaxamento (**diástole**) (MOHRMAN; HELLER, 2007).

Geralmente, o sangue flui de forma contínua do átrio para o ventrículo. Por conta da localização do nodo sinusal – que é responsável por gerar o estímulo elétrico cardíaco – os átrios contraem-se primeiramente em relação aos ventrículos,

bombeando, assim, o restante do sangue para dentro da câmara ventricular antes de ocorrer a sístole ventricular. Logo no início da contração ventricular, o sangue é impedido de passar dos átrios para os ventrículos, para que todo fluxo sanguíneo se concentre em seguir para a respectiva grande artéria do ventrículo. Após a sístole, há o momento de diástole em que os músculos se relaxam, o sangue é impedido de voltar das grandes artérias para a câmara ventricular e o sangue que estava contido nos átrios volta a fluir continuamente para os ventrículos até o início da próxima contração (HALL, 2011). A Figura 1 mostra o fluxo sanguíneo que vem pelas veias encontrando o átrio, que preenche o ventrículo que bombeia para a artéria. O sangue passa e é impedido de passar de uma câmara a outra e de uma câmara para a artéria através das valvas cardíacas.

### 2.1.2 Valvas Cardíacas

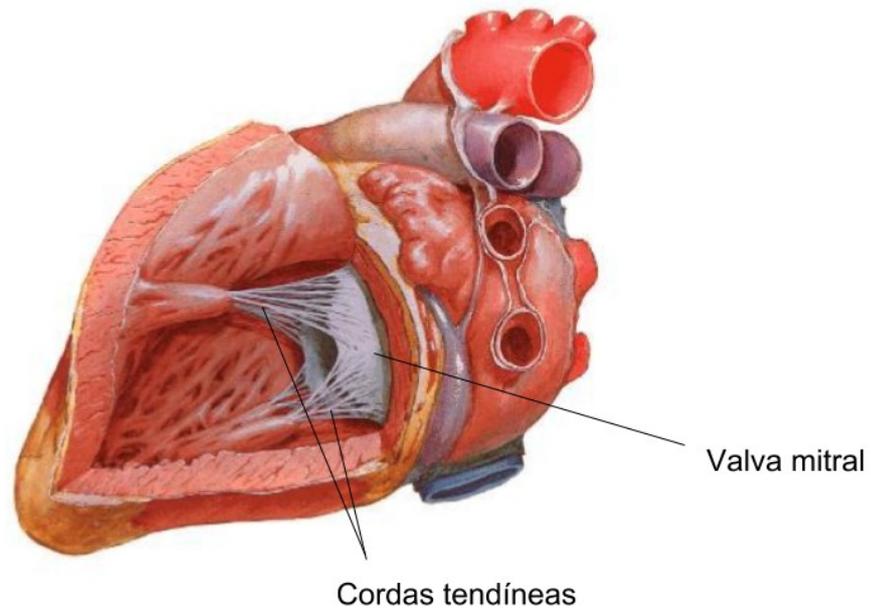
As válvulas cardíacas são compostas de duas ou três “folhas” formadas pelo tecido conjuntivo. Estas folhas são chamadas de folhetos valvares ou cúspides. Esta estrutura das válvulas constituem as valvas cardíacas que são responsáveis pelo bloqueio e pela liberação do sangue entre o átrio e ventrículo e entre o ventrículo e sua respectiva artéria (HALL, 2011). Ou seja, elas efetuam o controle do fluxo sanguíneo durante o ciclo cardíaco.

Como descrito anteriormente, no momento da sístole o sangue não passa dos átrios para os ventrículos, pois um bloqueio é feito pelas valvas A-V. Essas são denominadas de **valva tricúspide** no coração direito e **valva mitral** no coração esquerdo conforme mostra a Figura 1. No período da contração ventricular o sangue segue em direção à artéria através da abertura das valvas semilunares, que são nomeadas de **valva pulmonar** no coração direito e **valva aórtica** no coração esquerdo. Na etapa da diástole as valvas semilunares se fecham e as valvas A-V se abrem (HALL, 2011).

As valvas A-V possuem cordas cuja função é fazer com que não ocorra prolapso das valvas, isto é, impedem que se abram na direção inversa, no sentido dos átrios, como acontece com um guarda-chuva em dia de fortes ventos. Essas cordas são chamadas de cordoalha tendínea ou corda tendínea que estão ligadas aos músculos papilares dos ventrículos, como mostra a Figura 2, evitando assim a volta do sangue para os átrios no momento da sístole (HALL, 2011). Já as valvas

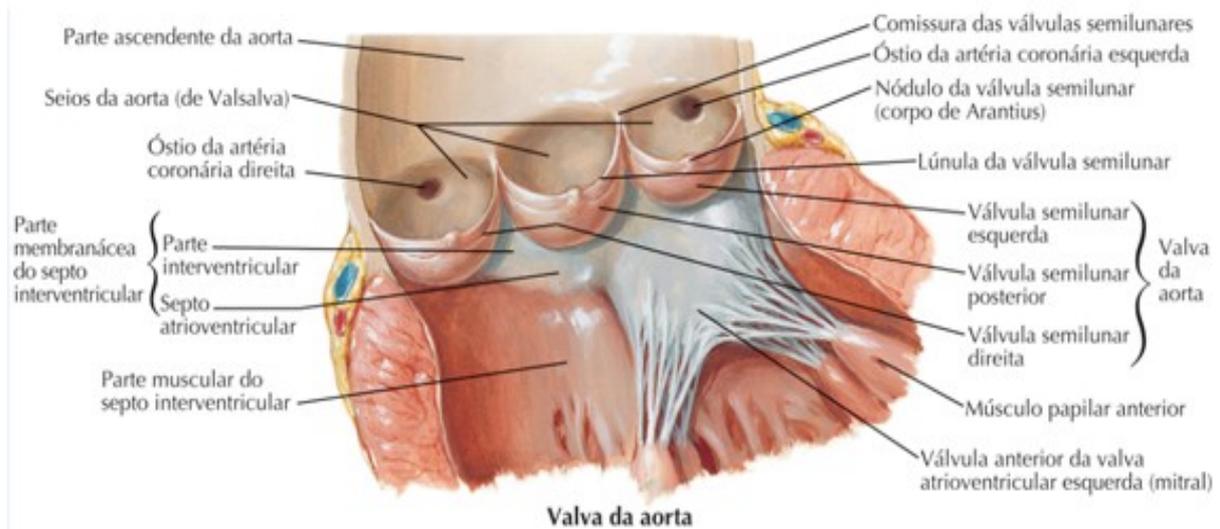
semilunares se fecham quando, após a sístole ventricular, uma parcela do sangue tenta voltar ao coração, pois as válvulas possuem uma espécie de “bolsa” chamada de seio da artéria (vide Figura 3) que quando enche tende as válvulas a se juntarem (CONTI, 2015).

Figura 2 – Valva mitral (aberta) e as cordas tendíneas



Fonte: adaptado de Conti (2015, p. 11).

Figura 3 – Valva aórtica



Fonte: Conti (2015, p. 12).

Percebe-se, então, que esse controle é uma parte essencial para que o fluxo sanguíneo siga com excelência; a abertura correta das valvas A-V (tricúspide e mitral) permite o enchimento adequado dos ventrículos, a abertura correta das valvas semilunares (pulmonar e aórtica) libera o sangue para as artérias e o fechamento completo das valvas evita a regurgitação/retrocesso do sangue de volta para as câmaras (átrios e ventrículos) (MOHRMAN; HELLER, 2007).

### 2.1.3 Doenças das Valvas Cardíacas

Todavia, o funcionamento inadequado das valvas cardíacas prejudica o fluxo de sangue no interior do coração, podendo causar fadiga, falta de ar, dores no peito e palpitações. Além do mais, pode estar relacionado a alguma cardiopatia valvar, as quais são demonstradas a seguir (O'GARA; LOSCALZO, 2013a):

- **Estenose Mitral (EM):** é quando ocorre o estreitamento da abertura da valva mitral, ou seja, a saída do fluxo de sangue do átrio esquerdo é obstruída pela abertura parcial da valva. Nesse caso é necessária elevação na pressão do átrio, para que o sangue continue a fluir de forma normal. Essa elevação na pressão pode resultar em dispneia (falta de ar), tosse, entre outras causas e sintomas, o que eventualmente é fatal. Pode haver intervenção cirúrgica para correção da valva.
- **Insuficiência Mitral (IM):** está relacionado à oclusão incompleta da valva

mitral, isto é, não é fechada completamente no momento da sístole ventricular, gerando retorno do sangue para o átrio. Casos de IM crônico pode resultar em fadiga intensa, dispneia quando realizados esforços, ortopneia e também há palpitações. Edema agudo de pulmão é frequente ocorrência de IM aguda grave. Também pode haver intervenção cirúrgica.

- **Prolapso da Valva Mitral (PVM):** esta doença é referente a regurgitação/retrocesso do sangue para o átrio esquerdo. Conforme descrito anteriormente, este retrocesso ocorre por conta do abrimento da valva mitral no sentido do átrio durante a sístole ventricular. Cordas tendíneas alongadas, redundantes ou rompidas causam este tipo de doença. Distúrbios hereditários do tecido conectivo e deformidades esqueléticas torácicas também podem causar ou contribuir para este tipo de doença. Na PVM é comum o paciente sentir arritmias, como extrassístoles ventriculares, taquicardias supraventricular paroxística e ventricular, palpitações, tontura e síncope (desmaio). Por conta dessa doença pode ocorrer a morte súbita. Pode-se realizar intervenção cirúrgica para correção.
- **Estenose Aórtica (EA):** na Figura 3 é possível identificar as válvulas semilunares esquerda, posterior e direita. Estas também são denominadas de cúspides. A EA é causada pela classificação de uma ou mais cúspides, gerando assim a obstrução, ou impedimento, da passagem do sangue do ventrículo para a artéria aorta. Esta doença pode ser originária de malformação congênita ou de lesões (EA valvar, miocardiopatia hipertrófica obstrutiva, estenose subaórtica fibromuscular/membranosa isolada e EA supravalvar). Os sintomas decorrentes deste tipo de doença são dispneia de esforço, angina de peito (dor no peito), síncope, fadiga, fraqueza intensa, cianose periférica (descoloração azulada nos pés e mãos), caquexia e também pode gerar um edema pulmonar. Neste caso há tratamento clínico e intervenção cirúrgica.
- **Insuficiência Aórtica:** ocorre quando a valva aórtica não se oclui e causa o retrocesso do sangue, ou seja, durante a diástole a valva não se fecha e o sangue retorna da artéria aórtica ao ventrículo. Esta doença pode ser originada do mau estado das cúspides (deformação ou encurtamento) e também da dilatação da aorta, sem envolvimento das cúspides. Pacientes com Insuficiência Aórtica podem sentir desconforto dos batimentos cardíacos,

taquicardia sinusal durante esforços ou emoção, palpitações causadas de extrassístoles, latejamento na cabeça, dispneia ao realizar esforços podendo ser seguida de ortopneia e pode haver dor torácica. É necessária intervenção cirúrgica.

- **Estenose Tricúspide (ET):** similar a EM, a ET ocorre quando a valva tricúspide não abre totalmente, assim o fluxo sanguíneo do átrio para o ventrículo direito não ocorre perfeitamente. Congestão pulmonar, fadiga, dispneia e desconforto causado por edema refratário, pela ascite e hepatomegalia são sintomas de pacientes com ET. Também necessita de intervenção cirúrgica.
- **Insuficiência Tricúspide (IT):** assim como a IM, quando há regurgitação do sangue do ventrículo direito para o átrio direito durante a sístole entende-se que o paciente possui IT. Esta pode ser originada por conta de infarto dos músculos papilares do ventrículo direito, prolapso da valva tricúspide, doença carcinóide, fibrose endomiocárdica, irradiação, endocardite infecciosa e raramente está associada a deformação da valva. O paciente com IT pode conter insuficiência cardíaca direita, hepatomegalia intensa, ascite, derrame pleural, entre outros sintomas. Dependendo da hipertensão arterial, não há necessidade de cirurgia.
- **Doença da Valva Pulmonar:** como o próprio nome sugere, esta doença está relacionada a valva pulmonar. Um dos problemas que afetam esta válvula é o retrocesso de sangue da artéria pulmonar para o ventrículo durante a diástole.  
A remoção cirúrgica desta válvula pode não acarretar em insuficiência cardíaca, a menos que sejam seguidas de hipertensão arterial pulmonar grave.
- **Doença Valvar Cardíaca Múltipla e Mista:** um paciente é diagnosticado com esta doença quando possui doença em mais de uma valva do coração, geralmente associado a muitas lesões adquiridas ou congênitas. Por exemplo: se um paciente possui o chamado síndrome de Marfan, podem apresentar Insuficiência Aórtica e IM causada por PVM, ou seja, neste caso o paciente possui três doenças das valvas cardíacas.

#### 2.1.4 Sopros Cardíaco

Há diversos métodos para análise do funcionamento do coração, como a realização de exames de ecocardiograma, o eletrocardiograma, o ultrassom, etc. A técnica mais comum não invasiva é o exame de auscultação cardíaca, que pode fornecer informações preciosas sobre o estado do coração e achados que outra técnica não poderia apresentar como, por exemplo, o sopro cardíaco. Um método utilizado é por meio da utilização do estetoscópio, porém a interpretação é restrita à percepção humana (CHAUHAN *et al.*, 2008).

Sopro cardíaco é um achado auscultatório, ou seja, o sopro é ouvido e não visto. Este achado é gerado por conta de vibrações causadas pelo aumento da turbulência do fluxo sanguíneo à medida que atravessa o coração, devido ao mau funcionamento das valvas cardíacas. A causa de um sopro pode ser identificada por meio da análise das suas principais características, como o momento do ciclo cardíaco em que ocorre o achado, isto é, no momento em que ocorre a sístole (**sopros sistólicos**) e/ou a diástole (**sopros diastólicos**). O sopro também pode ser graduado em uma escala de 1 a 6, os quais estão relacionados a intensidade do sopro; a escala 1 é de intensidade leve, quase imperceptível e da escala 4 à 6 ocorre o sopro com frêmito (pode ser sentido no tórax), onde é fácil de auscultar, entretanto a intensidade do sopro não está relacionada com a sua gravidade (O'GARA; LOSCALZO, 2013b).

Os **sopros sistólicos** podem ser auscultados no início, meio, final ou até mesmo durante toda essa fase do ciclo cardíaco (sístole). Pode estar relacionado com as seguintes cardiopatias valvares: IM crônica (resulta em sopro holossistólico), IM aguda (resulta em sopro protossistólico decrescente), IT (resulta em sopro holossistólico), IT aguda (resulta em sopro protossistólico crescente), EA (resulta em sopro mesodiastólico), IM (resulta em sopro da miocardiopatia hipertrófica obstrutiva) e PVM (resulta em sopro telessistólico) (O'GARA; LOSCALZO, 2013b).

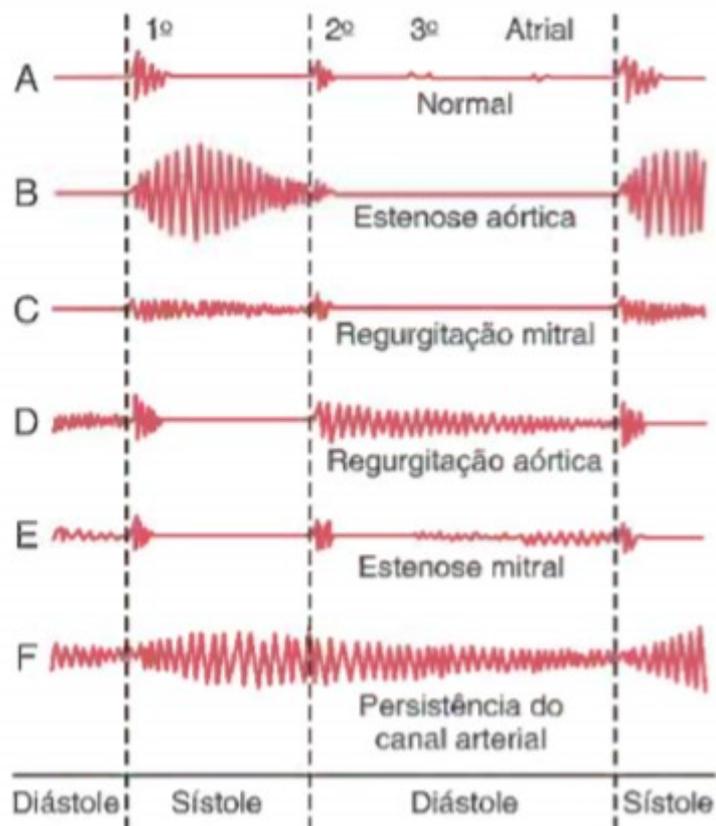
Ao contrário do sopro sistólico, os **sopros diastólicos**, sempre indicam alguma doença estrutural cardíaca e são auscultados durante a fase da diástole. Sopros diastólicos podem estar relacionados com as seguintes cardiopatias valvares: Insuficiência Aórtica aguda grave e crônica grave, Insuficiência Pulmonar, EM e ET (O'GARA; LOSCALZO, 2013b).

Quando um sopro contempla todo o ciclo cardíaco, entende-se que o paciente

possui **sopro contínuo**. Ou seja, o ruído é achado no início da sístole, permanece durante a sístole ventricular e persiste durante a diástole. Desta forma, o paciente possui uma cardiopatia valvar mista ou múltipla (O’GARA; LOSCALZO, 2013b).

A Figura 4 apresenta sinais de áudio referente ao ciclo cardíaco, onde o registro A corresponde a um coração normal e os registros restantes a coração com mau funcionamento das valvas cardíacas.

Figura 4 – Sinais do ciclo cardíaco



Fonte: Hall (2011, p. 281).

É importante frisar que o sopro cardíaco não é uma doença, mas sim um sinal que pode haver um defeito em uma ou mais valvas do coração. E por se tratar de um sinal, há casos em que a ausculta deste ruído não está atrelada a nenhuma patologia. Este é o chamado **sopro inocente**, que pode se caracterizar nos seguintes tipos (MARTINS *et al.*, 2008):

- A) Sistólico
  - a) *Sopro de Still* ou *sopro vibratório* precordial: ruído gerado pela mudança de fluxo do ventrículo para a artéria aorta;
  - b) *Sopro expulsivo pulmonar*: gerado na saída do ventrículo para a artéria pulmonar;
  - c) *Sopro carotídeo* ou *supraclavicular*: gerado na ramificação de vasos da artéria aorta;
  - d) *Sopro da estenose pulmonar periférica fisiológica transitória*: ruído gerado pela turbulência durante o fluxo de sangue na principal artéria pulmonar (principalmente em recém-nascidos).
- B) Contínuos
  - a) *Zumbido venoso*: gerado no local de junção das veias jugulares, veias subclávias e veias braquiocefálicas;
  - b) *Sopro mamário*: auscultado em mulheres grávidas / em lactação.

#### 2.1.5 Erro no diagnóstico do sopro Cardíaco

Conforme apresentado anteriormente, as doenças do coração são as que mais causam mortes no mundo e no Brasil e, tendo em vista que irregularidades no funcionamento das valvas cardíacas são sérias, um bom exame auscultatório é de extrema importância para se obter um diagnóstico inicial correto a fim de avaliar de forma precisa o estado do coração.

A eficiência de reconhecimento de sopro é apenas regular na prática auscultatória (O'GARA; LOSCALZO, 2013b). Segundo Delgado-Trejos *et al.* (2009), esta diminuição na eficiência se dá por conta de limitações do ouvido humano na percepção de ruídos com intensidade baixa e por esta ser uma aptidão que requer anos de experiência.

Deste modo, a identificação precisa de sopro cardíaco evita o envio de um paciente saudável a exames desnecessários e até mesmo de internação. De forma semelhante, evita-se a liberação de um paciente com possível cardiopatia valvar que pode até ser considerada cirúrgica.

## 2.2 Inteligência Artificial

A computação, aliada a outras áreas da tecnologia, é utilizada na resolução de diversos problemas, na execução e na automação de serviços. Entretanto, algumas habilidades humanas são complexas de serem aplicadas na computação. Um exemplo de habilidade é o reconhecimento étnico, de voz e de gestos levando-se em consideração as características da fisionomia, a tonalidade de voz e a velocidade do gesto efetuado. Os seres humanos possuem essa capacidade de fazer reconhecimento por conta de padrões chaves que são analisados, geralmente associados às particularidades de cada exemplo anteriormente aprendido (FACELI *et al.*, 2011).

Por outro lado, uma tarefa complexa de ser desempenhada por humanos e de ser aplicada com maior êxito computacionalmente é a análise de grandes quantidades de dados. Determinar padrões, sequências e agrupar dados com o intuito de obter informações são tarefas que podem ser executadas por um programa de computador (FACELI *et al.*, 2011). Quando a computação é utilizada com o intuito de analisar dados de empresas, por exemplo, podem ser encontrados padrões que não seriam tão facilmente descobertos por humanos.

Estudos estão sendo realizados para, de alguma forma, trazer soluções no sentido de reduzir a complexidade que se apresenta na análise de dados, sendo um deles o da Inteligência Artificial (FACELI *et al.*, 2011).

A IA abrange o estudo de elementos que tem por entradas dados da área na qual estão envolvidos e a partir dessas entradas, desempenhar determinadas funções (RUSSEL *et al.*, 2003).

Russel *et al.* (2003) apresentam algumas abordagens para IA que até então são seguidas, na qual referem-se no leal comportamento humano e no comportamento ideal de inteligência. São elas:

- a) Sistemas que pensam como humanos;
- b) Sistemas que agem como humanos;
- c) Sistemas que pensam racionalmente; e
- d) Sistemas que agem racionalmente.

Disciplinas as quais contribuíram e continuam contribuindo com ideias, pontos

de vista e técnicas para o desenvolvimento e o crescimento constante da IA abrangem desde Matemática, Economia, Engenharia da Computação, Teoria de Controle e Cibernética até Filosofia, Psicologia, Linguística e Neurociência (RUSSEL *et al.*, 2003).

Como mencionado na Introdução deste trabalho, técnicas de IA têm sido desenvolvidas e aplicadas nas mais diversas áreas do conhecimento.

Desde 1939, quando iniciaram-se as pesquisas nesta área, o setor automobilístico tem apresentado um grande avanço de tecnologia embarcada com o desenvolvimento e a fabricação de carros autônomos, unindo sensores (que coletam os dados), IA para aprender hábitos de motoristas e analisar os dados coletados e atuadores para que o automóvel de desloque de forma autônoma e segura (PISSARDINI; MIN WEI; FONSECA JUNIOR, 2013).

A IA também tem aplicação na robótica por meio do desenvolvimento de braços robóticos que podem ser utilizados em fábricas ou em ambientes nos quais oferecem perigo aos seres humanos. Também na produção de robôs exploratórios como, por exemplo, o robô Curiosity, o qual tem por finalidade explorar o planeta Marte (NATIONAL..., 2017) e robôs humanóides, os quais têm a finalidade de se comportar semelhantemente a um humano para auxiliar em tarefas cotidianas e interagir com as pessoas ao seu redor por meio de gestos e pela fala, como o ASIMO, da empresa HONDA (HONDA, 2000).

No comércio e na mídia eletrônica, são armazenados históricos dos clientes como as compras feitas ou pesquisas realizadas sobre um determinado produto. Estes históricos são úteis para, futuramente, recomendar outros itens relacionados aos que foram comprados ou pesquisados (AMARAL, 2016b).

Na indústria de jogos eletrônicos, a IA é fortemente utilizada. Uma das aplicações é fazer com que personagem tome ações coerentes com o ambiente do jogo (KISHIMOTO, 2004). Em um jogo de futebol, por exemplo, o personagem deve se comportar como um jogador real ou em um jogo de guerra, o personagem deve tomar ações semelhantes a um soldado.

Instituições financeiras fazem uso de IA com o intuito de realizar a detecção de fraude ou identificar comportamento anômalo no uso de cartão de crédito em caso de furto do cartão (HAUERT, 2017).

Na área da saúde, IA disponibiliza auxílio na apresentação de diagnóstico. Com base na análise de exames e diagnósticos de pacientes anteriores é possível

aplicar técnicas de IA para prever o diagnóstico de um novo paciente (HAUERT, 2017).

Essas aplicações são realizadas com sucesso depois de serem usados exemplos reais de como a área funciona. Esses exemplos usados nada mais são do que informações sobre um determinado aspecto ou área de aplicação, que servem de treinamento para os sistemas.

### 2.2.1 Aprendizado de Máquina (*Machine Learning*)

A quantidade de informação gerada diariamente é enorme (GRUS, 2016), bancos geram dados financeiros, da mesma forma que estações meteorológicas e portuárias geram grande massa de dados por dia. *Smartphones* e aviões também produzem ampla diversidade de dados através de seus sensores. Os hospitais e clínicas possuem dados de seus pacientes, bem como empresas do setor automotivo portam dados do estado de montagem do automóvel. Dados de pesquisas e *websites* visitados por usuário são armazenados. Esses são apenas alguns exemplos de campos que geram e guardam vários tipos de dados. Todas as informações produzidas e armazenadas são formadas por um conjunto organizado de dados (AMARAL, 2016b), ou seja, um dado único não transmite uma informação, mas o conjunto desses gera um conhecimento.

A partir deste cenário de “produção em massa de dados”, torna-se complexa a análise completa e acurada dos dados tanto por humanos como para simples programas de computador, quando, o ideal seria não desperdiçar nenhum conhecimento a respeito de um determinado setor (AMARAL, 2016b).

Diante deste panorama de complexidade em analisar uma massa muito grande de dados sobre um determinado tema objetivando constatar alguma informação, encontra-se na literatura uma técnica proveniente da IA que fornece apoio para este tipo de tarefa possibilitando o reconhecimento de padrões. Esta técnica é chamada de Aprendizado de Máquina (AM) ou *Machine Learning* no inglês e recebeu esta denominação, pois os algoritmos utilizam-se da “experiência” aprendida em casos anteriores para poder solucionar um novo problema (FACELI *et al.*, 2011).

Cada dado utilizado em uma técnica de aprendizado de máquina é chamado de atributo. Um conjunto de atributos é denominado de exemplo ou registro. Os

algoritmos de aprendizado de máquina normalmente utilizam em sua entrada atributos cujos valores são discretos, ou seja, assumem valores dentro de um conjunto finito com os números especificados. Um atributo de valor discreto também pode ser denominado de atributo categórico ou atributo nominal. Quando há a presença de atributos contínuos a serem avaliados, deve-se discretizar estes atributos antes de fornecê-los como entrada nos algoritmos de AM. Por exemplo: a altura de um determinado objeto é considerado como um atributo contínuo e deve-se transformar este atributo contínuo em um atributo discreto o qual poderia ser categorizado em três possíveis valores: pequeno, médio e grande (AMARAL, 2016a).

Em algumas tarefas um desses atributos irá descrever o fato de interesse ou a classificação, também chamado de classe ou atributo meta (MONARD *et al.*, 2003). O atributo meta também pode ser denominado como rótulo.

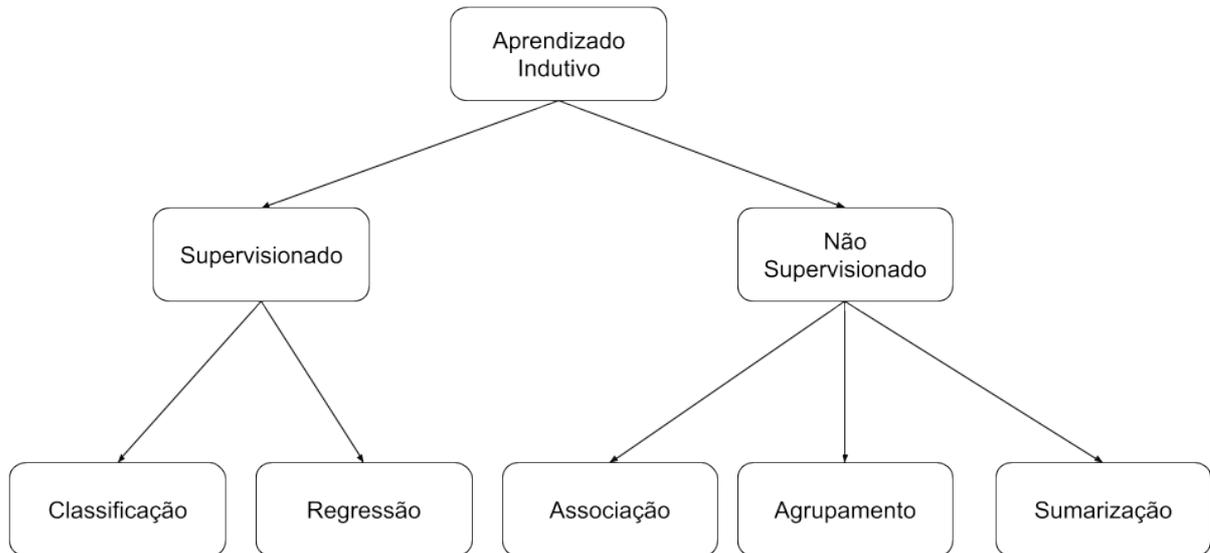
Quando o objetivo é obter conhecimento sobre o estado de um paciente entre “saudável” ou “doente”, os dados relevantes coletados de exames e diagnóstico serão os atributos de entrada (por exemplo frequência cardíaca, taxa de glicose no sangue, a cor de manchas na pele, etc) e o conjunto desses atributos é o registro que será aplicado no aprendizado de máquina, onde que, fundamentado neste registro, irá associar com a base de conhecimento existente. Logo, caso o registro se assemelhe com dados de pacientes rotulados como “saudável”, o atributo meta retornará como saída a classificação “saudável”, do contrário retornará “doente” como saída para o novo dado (FACELI *et al.*, 2011).

O AM dispõe de dois princípios que implicam na conclusão após a análise de dados. Um deles é a Indução que, de acordo com Monard *et al.* (2003, p. 40) “é a forma de inferência lógica que permite obter conclusões genéricas sobre um conjunto particular de exemplos.”. Ou seja, são estudados os exemplos para assim aplicar as regras. Outro princípio é o de Dedução, o qual são estudadas as regras e então aplicados exemplos específicos.

Neste trabalho será utilizado o princípio da indução, onde o mesmo oferece formas de aprendizado para determinado tipo de problema ou área de aplicação. As mais utilizadas são Aprendizado Supervisionado e Aprendizado Não Supervisionado (GRUS, 2016).

A Figura 5 mostra uma hierarquia de aprendizado indutivo.

Figura 5 – Hierarquia de aprendizado



Fonte: adaptado de FACELI *et al.* (2011, p. 6).

## 2.2.2 Tipos de Aprendizado

Como já mencionado, há dois tipos principais de aprendizado. O que difere um do outro é a presença ou ausência de um agente externo. Ou seja, pode-se entender que existe o aprendizado com e sem um “supervisor”, no qual, este agente externo influencia no aprendizado da máquina, de acordo com o ambiente no qual está inserido (HAYKIN, 2009).

### 2.2.2.1 Aprendizado Supervisionado

No Aprendizado Supervisionado há a ação de um agente externo, onde o “supervisor” já tem uma ideia da saída; “doente” ou “saudável”, por exemplo. O “supervisor” sabe da saída, pois é fornecido um conjunto de registros  $R = \{R_1, R_2, R_3, \dots, R_n\}$ , onde para cada  $R_i \in R$ , encontra-se um rótulo que diz respeito à classificação deste registro  $R_i$  (MONARD *et al.*, 2003).

Este conjunto de registros acompanhado de seu respectivo rótulo é a base de conhecimento que é fornecida para o algoritmo de aprendizado, que devolve o chamado modelo. Este modelo é uma função  $f$ , na qual, a partir de  $f$  é possível prever valores ou rótulos, para os novos registros (MONARD *et al.*, 2003).

Este tipo de aprendizado pode ser representado por duas importantes tarefas:

a Classificação, que utiliza rótulos de valores discretos os quais podem ou não ser numéricos (“doente” ou “saudável”, por exemplo); e a Regressão, na qual os rótulos são valores numéricos infinitos e ordenados, ou seja, de valores contínuos (medidas de altura ou temperatura, por exemplo) (FACELI *et al.*, 2011).

#### 2.2.2.1.1 Classificação

Conforme anteriormente descrito, os atributos de um registro consistem nos dados relevantes de um determinado problema a ser analisado. Um desses atributos contém a informação do fato a ser resolvido ou descoberto. Este atributo é chamado de classe, atributo meta ou rótulo.

Quando uma área requer obter conhecimentos sobre a categoria ou espécie de um novo caso e, tanto a resposta como os valores de entrada, são constituídos por valores discretos, diz-se que há um problema de classificação (FACELI *et al.*, 2011). No Quadro 2, são demonstrados dois breves exemplos de classificação (AMARAL, 2016b).

#### Quadro 2 – Exemplos de tarefas de classificação

##### Exemplo 1)

Uma instituição financeira deseja saber se um determinado cliente é um “bom pagador” ou “mau pagador”, com a finalidade de se obter conhecimento em qual taxa de juros liberar crédito solicitado pelo cliente. Para isso, coletou-se dados que podem ser úteis como: idade, se possui emprego fixo, número de dependentes, como foi o comportamento do mesmo em outras situações que obteve crédito, etc. Esses conjuntos de dados é submetido ao modelo do aprendizado de máquina, que irá classificar este cliente como “bom pagador” ou “mau pagador”. As expressões “bom pagador” e “mau pagador” são os rótulos do atributo meta definido para o conjunto de registros.

##### Exemplo 2)

Uma nova flor foi descoberta e pretende-se determinar a espécie da mesma dentre três possíveis: “setosa”, “versicolor” e “virginica”. Assim, os dados referentes à largura e ao comprimento das sépalas e pétalas da nova flor são submetidas ao modelo do aprendizado de máquina e o modelo, por conseguinte, classifica a

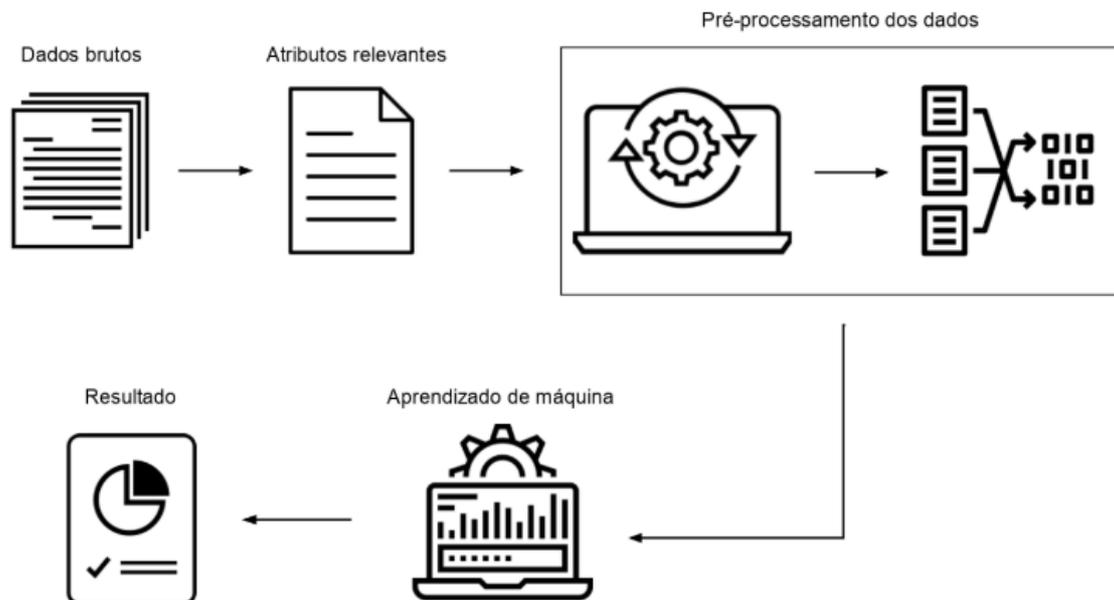
espécie da nova flor apresentada. Neste exemplo, o atributo meta pode assumir um dos três rótulos possíveis.

Fonte: adaptado de Amaral (2016b).

Pode-se observar que o atributo meta contém a informação requerida; classificação do cliente ou a espécie de uma nova flor, conforme pode ser visto nos exemplos apresentados acima. Portanto, entende-se que, na tarefa de classificação, o objetivo é prever a qual classe deve pertencer um novo registro apresentado (AMARAL, 2016b).

A Figura 6 abaixo, demonstra um exemplo de fluxo dos dados na tarefa de classificação, começando com a obtenção de dados brutos e extração de atributos relevantes. O pré-processamento desses dados é realizado com o intuito de tratar dados inconsistentes, vagos ou duplicados (FACELI *et al.*, 2011). Após o pré-processamento, o registro é submetido a um algoritmo de aprendizado de máquina que devolve o resultado de sua análise.

Figura 6 – Exemplo de fluxo de dados de tarefa de classificação



Fonte: O autor (2018).

Com propósitos de aprendizado, o conjunto de registros são divididos em dois subconjuntos: conjunto de treinamento, que é usado no aprendizado do conceito; e o conjunto de teste, que compreende no teste do modelo gerado no treinamento e é

usado para medir o grau de efetividade do conceito aprendido (AMARAL, 2016b).

Existem técnicas de separação dos conjuntos de treinamento. Duas delas são citadas a seguir (AMARAL, 2016b):

- *Hold Out*: consiste em separar, aleatoriamente, 70% dos registros para treinamento e 30% para testes. Os registros selecionados não podem se repetir em grupos distintos, por tanto, dados do grupo de treino não podem ser usados no grupo de teste, e vice-versa.
- Validação Cruzada: possui a mesma ideia da técnica *hold out*, entretanto o mesmo dado pode ser usado, no mesmo número de vezes, tanto no grupo de teste como de treinamento.

Para realizar classificações, há na literatura um grande leque de algoritmos que podem ser utilizados. Alguns podem ser citados, como: Algoritmo do 1-Vizinho Mais Próximo, Algoritmo K-NN, algoritmos relacionados ao teorema de Bayes como o Naive Bayes e Redes Bayesiana de Classificação. Na tarefa de classificação também são usados algoritmos associados a Árvores de Decisão e Redes Neurais Artificiais (FACELI *et al.*, 2011).

#### 2.2.2.1.2 Regressão

Na tarefa de classificação descrita na seção anterior, os valores dos dados de entrada e a resposta são caracterizados por valores nominais e podem ser numéricos ou não. Já na atividade de regressão, estes valores obrigatoriamente são numéricos contínuos e ordenados.

Nesta atividade, submetendo-se um registro de valores numéricos (também chamados de valores independentes) ao modelo, ao invés deste modelo fornecer como resultado uma determinada classe, ele irá fornecer uma “resposta” cujo valor também é numérico (AMARAL, 2016b).

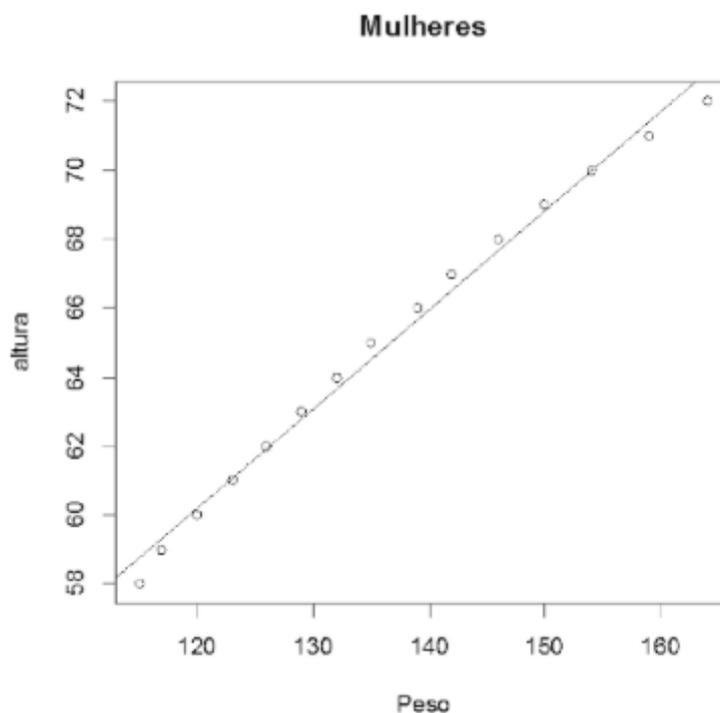
Quando há somente um valor independente, entende-se que é um caso de regressão linear simples. Do contrário, uma vez que há mais de um valor independente, é chamado de regressão linear múltipla (AMARAL, 2016b).

O modelo de regressão gera uma função que permite analisar os valores independentes e os demais valores na base de conhecimento (HAYKIN, 2009), a fim

de prever o valor de uma resposta.

Um exemplo didático é apresentado a seguir (AMARAL, 2016b): possui-se uma base de dados com a altura e peso de mulheres. Ao aplicar esta base em algoritmo de regressão cria-se modelo que relaciona o peso com a altura gerando a linha de melhor ajuste, como pode ser visualizado na Figura 7, na qual é utilizada para prever novos valores. Assim, ao informar o peso de uma mulher, a função utiliza a linha de melhor ajuste para prever a altura a sua altura.

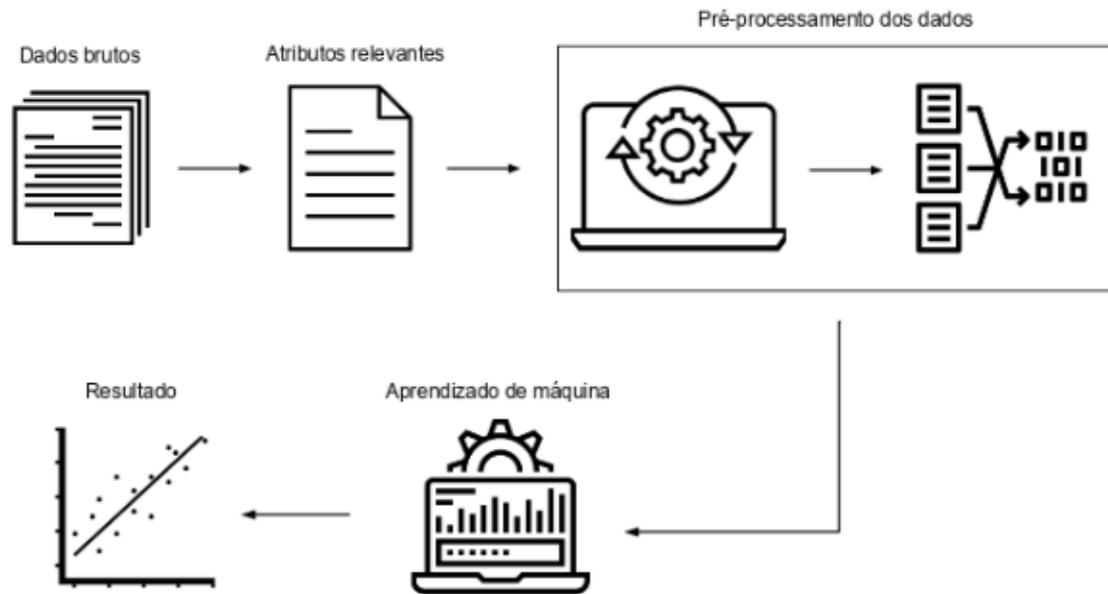
Figura 7 – Gráfico de relação peso x altura e linha de melhor ajuste



Fonte: Amaral (2016b, p. 107).

A Figura 8 demonstra um exemplo de fluxo de dados em uma tarefa de regressão, onde é semelhante ao de uma tarefa de classificação. O que as diferencia é a saída a qual consiste em um valor numérico previsto com base na linha de melhor ajuste.

Figura 8 – Exemplo de fluxo de dados de tarefa de regressão



Fonte: O autor (2018).

Os algoritmos utilizados na regressão perante valores totalmente numéricos são apresentados a seguir: Algoritmos de Árvore de Regressão, Redes Neurais Artificiais, e Máquinas de Vetores de Suporte são utilizados neste caso. Para Métodos Baseados em Distância e Métodos Probabilísticos é utilizado, respectivamente, o Algoritmo K-NN e NaiveBayes, mesmos algoritmos da tarefa de classificação, porém com adaptações (FACELI *et al.*, 2011).

#### 2.2.2.2 Aprendizado Não Supervisionado

Neste tipo de aprendizado, não há ação de um agente externo, em outras palavras, não há um “supervisor” para influenciar no processo de aprendizagem (HAYKIN, 2009). A máquina aprende por meio de uma “investigação” nos dados com o intuito de obter novos conhecimentos, assim, “tem a característica de observar e descobrir, de realizar uma análise exploratória nos dados.” (JUSTO, 2016, p. 31). Como não há ação de agente externo, não existe rótulo. Assim, o atributo meta no aprendizado não supervisionado é ausente.

Empregando o Aprendizado Não Supervisionado pode-se adquirir novos conhecimentos valiosos como padrões, grupos e associações entre dados dentro de uma determinada área, como Marketing, Biologia, Medicina, Engenharia e Visão

Computacional, por exemplo (FACELI *et al.*, 2011).

Existem tarefas que auxiliam na obtenção de conhecimento para determinados propósitos (FACELI *et al.*, 2011). Neste trabalho serão descritas as tarefas mais comumente empregadas quando há a necessidade de aplicar-se o aprendizado não supervisionado: a Associação e o Agrupamento (do inglês, *Clustering*).

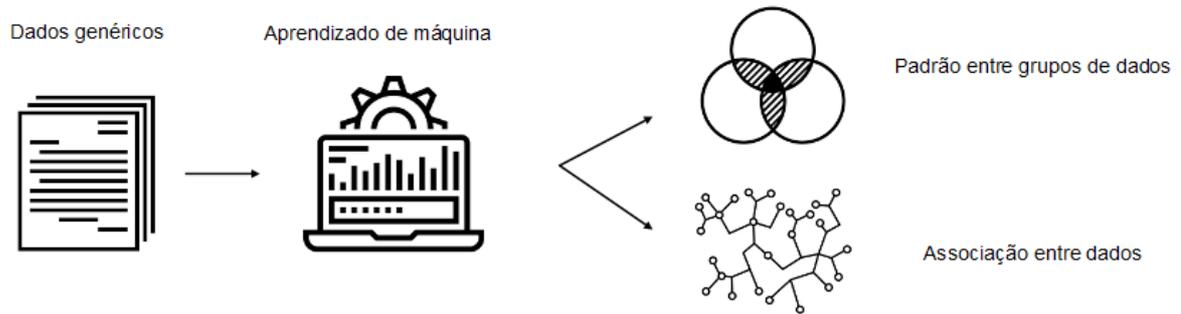
#### 2.2.2.2.1 Associação

Uma aplicação de destaque do emprego da tarefa de associação foi realizada na análise de cestas de compras em um supermercado (FACELI *et al.*, 2011). Esta aplicação consistia em examinar cada compra e detectar quais produtos eram comprados em grupo. Percebeu-se que, quando o produto X era comprado, o produto Y também era adquirido. Ou ainda, quando o produto A era comprado, os produtos B e C também eram. Assim, grandes varejistas como a *Amazon* usam este conceito para quando um cliente comprar A, oferecer B e também C, pois estes produtos estavam associados em compras passadas (AMARAL, 2016b).

Os algoritmos desenvolvidos para realizar a tarefa de associação têm como objetivo explorar bases de dados e encontrar uma relação ou padrões entre dados, e também a frequência que um determinado dado aparece em um grupo de dados. Além disso, esta tarefa tem o intuito de determinar o que acarreta neste relacionamento e na frequência da ocorrência de um dado (VASCONCELOS; CARVALHO, 2004)

O esquema representado na Figura 9 representa uma tarefa de associação, na qual uma base de dados genéricos são aplicados ao aprendizado de máquina, onde algoritmos analisam esta base e apresentam o resultado, que pode ser relações ou padrões entre os dados.

Figura 9 – Exemplo de fluxo de dados de tarefa de associação



Fonte: O autor (2018).

Desta forma, esta tarefa pode proporcionar descobertas valiosas quando aplicada em grande base de dados. Para tornar mais ágil a análise em bases de larga escala, são usados algoritmos como *FP-growth* e *Apriori* (FACELI *et al.*, 2011).

#### 2.2.2.2.2 Agrupamento ou *Clustering*

A tarefa de agrupamento tem por objetivo a organização dos dados (AMARAL, 2016), na qual estes grupos são chamados de *clusters* (JUSTO, 2016) e podem ser entendidos como um conjunto de dados correlatos, na qual esta correlação são propriedades significativas dentro no campo de estudo (FACELI *et al.*, 2011).

A tarefa de agrupamento pode ser aplicada, por exemplo, em marketing, quando se deseja saber para quais grupos de clientes focar uma promoção. Desta forma, os clientes são agrupados conforme idade ou o setor que mais compram (AMARAL, 2016b). Outras aplicações se dão no agrupamento de documentos, reconhecimento de padrões (JUSTO, 2016), entre outras.

O esquema representado na Figura 10 ilustra a tarefa de agrupamento onde a base de dados genéricos é aplicado ao aprendizado de máquina e os algoritmos buscam por padrões entre os dados, formando grupos. Exemplos de resultados de tarefas de agrupamento podem ser visualizadas nas Figuras 11 e 12.

Figura 10 – Exemplo de fluxo de dados de tarefa de agrupamento

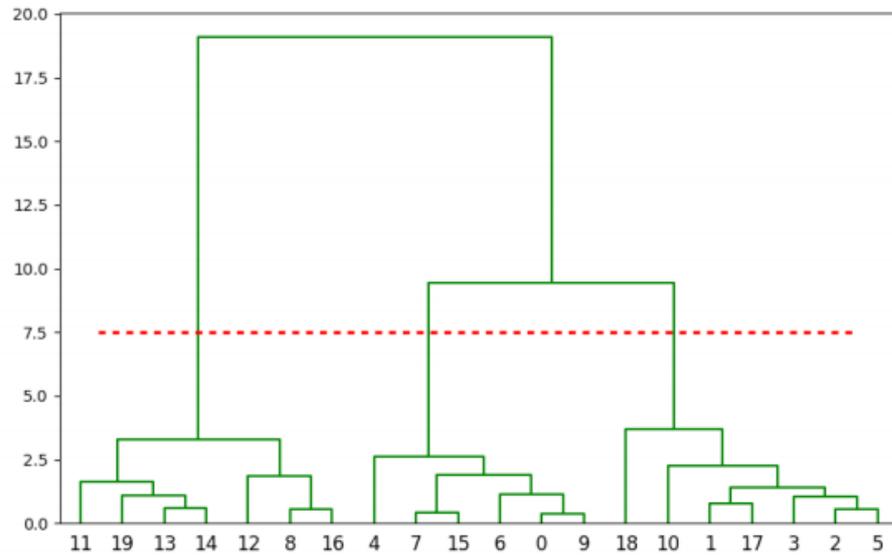


Fonte: O autor (2018).

Amaral (2016b) aponta três principais tipos de agrupamento, os quais estão listados e explicados a seguir:

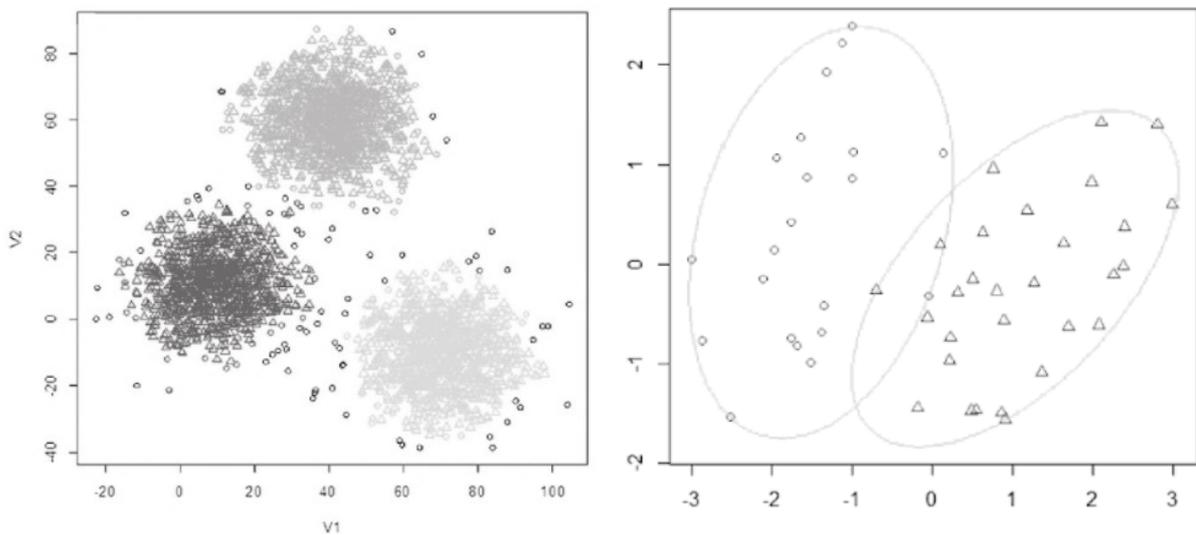
1. Agrupamento Hierárquico: os dados são agrupados de forma hierárquica, ou seja, um elemento pode possuir grupos pais e/ou subgrupos filhos. A Figura 11 apresenta um exemplo de agrupamento hierárquico, realizado a partir de uma base de dados organizada em três grupos multivalorados, onde que, abaixo da linha horizontal pontilhada pode se visualizar os três grupos formados.
2. Agrupamento por densidade: nesta forma de agrupamento são organizados grupos conforme a alta densidade de dados, entretanto, dados com ruídos ou em extremidades podem não ser agrupados. A Figura 12 (esquerda) mostra três grupos organizados conforme a densidade dos dados.
3. Agrupamento baseado em protótipo: os dados são agrupados conforme sua similaridade, ou seja, dados que possuem características semelhantes entre si. Ao contrário do agrupamento por densidade, todos os dados são agrupados. A Figura 12 (direita) demonstra um exemplo de agrupamento por protótipo.

Figura 11 – Exemplo de agrupamento hierárquico



Fonte: Padilha e Carvalho (2017, p. 38).

Figura 12 – Exemplo de agrupamento por densidade e baseado em protótipo



Fonte: Compilação do autor (2018)<sup>1</sup>.

<sup>1</sup> Montagem a partir do livro de Amaral (2016), páginas 111 e 110 respectivamente

### 2.3 Processamento de Áudio

Dentre as ciências, encontra-se uma responsável pela pesquisa e desenvolvimento técnico e metodológico no âmbito da reprodução sonora. Esta é a ciência do áudio, que visa contribuir para a reprodução de som artificial de forma mais natural e com fidelidade ao que originou o som, podendo ser a fala ou música (HERRERA, 2004).

Para que o áudio seja reproduzido com qualidade e fidelidade ao que foi gerado, é necessário uma série de componentes físicos e eletrônicos (*hardware*) e também de processamento deste áudio (*software*) (HERRERA, 2004).

O processamento de áudio geralmente está associado a manipulação ou análise dos sinais e pode ser utilizado, por exemplo, no reconhecimento de voz aplicado na verificação de identidade e controle de acesso (ITTICHAICHAREON, 2012) ou na classificação automática de ritmos musicais (ALMEIDA, 2009) ou em conjunto com IA para desenvolver um sistema que realiza tarefas, como agendar um corte de cabelo ou reservar uma mesa em um restaurante por meio de ligação telefônica (LEVIATHAN; MATIAS, 2018). Pode, portanto, também ser utilizado para a análise do som do ciclo cardíaco, foco do presente trabalho.

A partir do processamento de sinais de áudio, pode-se obter recursos, como por exemplo, valores fixos e, analisando esses dados podem ser obtidas informações interessantes a respeito de um áudio (CHAUHAN *et al.*, 2008).

### 2.4 Trabalhos Correlatos

Nesta seção são apresentados trabalhos similares à solução que está sendo proposta, os quais foram encontrados durante o estudo de viabilidade (seção 3.3). Os trabalhos de Zhong *et al.* (2013), Jimenez *et al.* (2014) e Chauhan *et al.* (2008) foram encontrados em periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

O trabalho de Zhong *et al.* (2013) propõe o reconhecimento de sopro cardíaco baseado no *Hidden Markov Model* (HMM). Neste trabalho foi utilizado uma base de dados com 600 áudios do ciclo cardíaco, separados em normal e entre 5 tipos de sopro. Foram testados 4 modelos de HMM com a finalidade de obter a classificação do sinal MFCC (*Mel Frequency Cepstral Coefficient*), extraído como atributo do

áudio.

Jimenez *et al.* (2014) pretendem realizar a detecção de sopro cardíaco utilizando 4 características derivadas do sinal MFCC. É utilizado métodos de pré-processamento para coleta de segmentação para então ser empregado técnicas de decomposição do sinal em questão. O algoritmo FRS (*Fuzzy Rought Set*) é utilizado com a finalidade de realizar ajustes em dados imprecisos para, então, ser aplicado ao HMM.

No estudo de Chauhan *et al.* (2008), utiliza-se o sinal MFCC e HMM para classificação de sons do ciclo cardíaco em 3 tipos mais o tipo normal. Também foram testados Domínio de Tempo e STFT (Transformada de Fourier de curta duração, na tradução) para captação de dados em ciclos de som.

O trabalho de Zhong *et al.* (2013) pode classificar não somente entre um coração saudável ou com sopro, como também classifica o tipo de sopro presente. Entretanto, é extraído de apenas uma característica do áudio (MFCC), ou seja, somente um atributo, e não se faz uso de técnicas de AM para realizar análise de dados ou classificação dos áudios.

De mesma maneira, Jimenez *et al.* (2014) obtiveram bons resultados utilizando características derivadas do MFCC, porém não é efetuada a leitura de arquivos de áudio, o autor já possuía uma base pronta com sinais de MFCC coletados a partir de exames de Fonocardiografia, outros tipos de características do áudio (p.e. escalas, sinais e medidas) não são testados e os atributos também não são analisados por um *software* específico ou aplicados a um algoritmo de AM.

Chauhan *et al.* (2008) utilizaram uma base com 1381 registros contendo dados de sons do ciclo cardíaco, coletados a partir de um estetoscópio eletrônico desenvolvidos pelos autores. Entretanto também utilizou uma propriedade do som (MFCC) e um classificador (HMM), sem constar testes com outros recursos, bem como a utilização de diferentes algoritmos para avaliar a acurácia na classificação.

Em contrapartida, esta solução possui como uma de suas metas, ler os arquivos de áudio informados e testar a extração de diferentes características do áudio que contém grandes chances de se tornar um atributo. A partir dos atributos obtidos testar classificação do áudio (entre um coração normal ou com sopro) em diferentes algoritmos classificadores de AM. Além do mais, nos trabalhos acima apresentados, não consta citação sobre uma interface gráfica, todavia, há o interesse de construir uma interface nesta solução, com o objetivo de tornar mais

prático a submissão do arquivo de áudio e exibição do resultado da classificação. Estas características entre os trabalhos correlatos e esta solução, podem ser visualizadas no Quadro 3 abaixo.

Quadro 3 – Relação entre características desta solução com trabalhos correlatos

Trabalho	Qtd. atributos testados	Tamanho da base de dados	Qtd. Algoritmos de AM testados	Acurácia	Possui Interface Gráfica?
Zhong <i>et al.</i>	1	600 registros	1	94,2%	Não
Jimenez <i>et al.</i>	4	400 registros	1	98,9%	Não
Chauhan <i>et al.</i>	3	1381 registros	1	99,21%	Não
Esta solução	10	257 registros	10	75%	Sim

Fonte: O autor, 2018.

## 2.5 Considerações Finais

Após a leitura desta seção, é possível ter noção que o mau funcionamento das valvas cardíacas geram sérias consequências. Entendeu-se ainda, que a identificação de cardiopatia valvar pode ser alcançada através da ausculta cardíaca, na qual é descoberto, durante o ciclo cardíaco, o chamado sopro cardíaco. Entretanto, a acurácia no reconhecimento deste ruído é, por muitas vezes, impreciso por parte do profissional da saúde por ser uma técnica que requer experiência e também por questões de percepção do ouvido humano.

Posteriormente, referiu-se sobre os conceitos de Inteligência Artificial dando enfoque a sua subárea Aprendizado de Máquina, mencionando sobre os aspectos dos tipos de aprendizagem que esta área proporciona, bem como demonstrando exemplos de aplicação em análise de dados.

Ademais, foi mencionado brevemente sobre processamento de áudio, onde é possível derivar dados para análise a partir de sinais, escalas e medidas do áudio.

E, finalmente, trabalhos similares a este foram apresentados, explicando suas características e apontando os pontos positivos e negativos, assim como uma comparação com a solução que será proposta neste trabalho, explicada detalhadamente na seção subsequente.

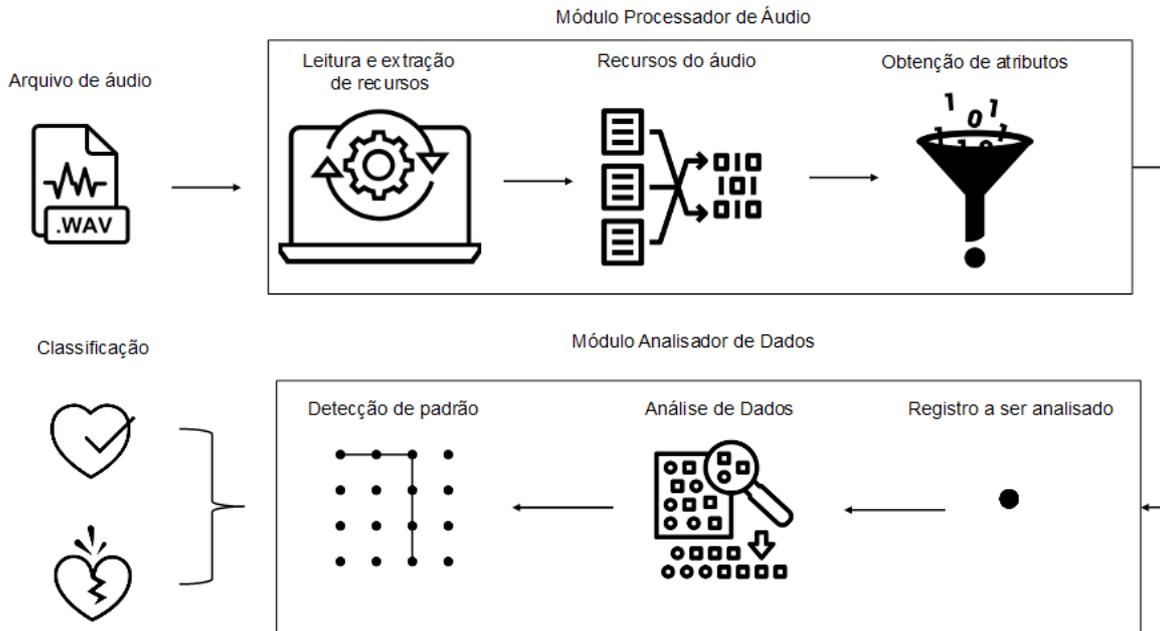
### 3 MATERIAIS E MÉTODOS

No presente Capítulo são apresentados a descrição da solução desenvolvida para o problema abordado bem como um estudo preliminar da viabilidade de execução em tempo hábil deste projeto considerando este ser um trabalho de graduação. Também, descreve-se sobre a base de dados utilizada no estudo preliminar e que foi adotada para o projeto em questão e as ferramentas de *software* que foram utilizadas na implementação da solução. Ainda nesta seção, apresenta-se as considerações finais fazendo uma relação entre todos os conceitos mencionados.

#### 3.1 Descrição da Solução

O objetivo principal do presente trabalho é o desenvolvimento de um sistema computacional que seja capaz de auxiliar os profissionais da área da saúde fornecendo informação que pode ser utilizada para complementar a análise clínica do paciente e melhorar o diagnóstico de presença de sopro cardíaco que pode ser identificado por meio de auscultação cardíaca. Esta informação consiste em indicar se há presença ou ausência de sopro cardíaco. Para atingir este propósito, o sistema está definido por uma arquitetura organizada em dois módulos, como pode ser visto na Figura 13.

Figura 13 – Arquitetura e processamento da solução proposta



Fonte: O autor (2018).

Abaixo são mencionados cada módulo, bem como descrita suas etapas:

- **Módulo de Processamento de Áudio (MPA):** o usuário do sistema deverá fornecer, como entrada de dados, um arquivo de áudio proveniente da ausculta cardíaca. O MPA fará a leitura deste arquivo e, a partir de um algoritmo apropriado, fará a extração dos atributos relevantes para a análise. Os atributos extraídos serão, por conseguinte, utilizados no Módulo de Análise de Dados descrito a seguir.
- **Módulo de Análise de Dados (MAD):** após a execução do MPA, obtém-se um registro formado pelos atributos extraídos, na qual deve ser classificado. Para realizar a sua classificação, será executada a segunda parte do processamento do *software*, que diz respeito à aplicação do registro em questão em técnicas de Aprendizado de Máquina. Estas técnicas visam a detecção de padrões entre os dados do novo registro apresentado ao sistema e os dados dos registros rotulados (classificados) já existentes na base de conhecimento. Desta forma, ao reconhecer uma similaridade entre o novo registro e os já existentes, poderá ser realizada a classificação deste novo registro.

Os atributos que são extraídos dos arquivos de áudio e as técnicas de Aprendizado de Máquina utilizadas nesta solução serão apresentadas no decorrer desta seção.

### 3.2 Requisitos da Solução

Para este sistema são apresentados os seguintes Requisitos Funcionais:

- O sistema deve ler e obter recursos dos arquivos de áudio;
- O sistema deve processar os recursos obtidos com a finalidade de obter atributos para ser aplicado em métodos de AM;
- O sistema deve analisar os dados a partir de métodos de AM para apresentar a classificação do arquivo de áudio; e
- O sistema deve permitir a visualização de um gráfico da onda do arquivo de áudio informado.

Requisitos Não Funcionais:

- Sistema Operacional *Windows*; e
- Linguagem de programação Python.

### 3.3 Estudo de Viabilidade

Para iniciar a concepção deste projeto, foi necessário realizar um estudo de viabilidade de execução do mesmo considerando este ser um Trabalho de Conclusão de Curso (TCC) de nível de graduação. O motivo deste estudo preliminar justifica-se pelo dimensionamento de tempo disponível para a realização de um TCC associado à necessidade da aquisição de conhecimento em conceitos específicos da área de Informática e, também, da área Médica, mais especificamente relacionados à Cardiologia.

Na área de Informática, os conceitos estudados estão relacionados às técnicas de Aprendizado de Máquina, uma subárea da Inteligência Artificial. Estas técnicas têm o objetivo de realizar tarefas preditivas ou indutivas baseadas em conhecimento de exemplos anteriores. Os algoritmos normalmente atuam com base em exemplos apresentados e na identificação de padrões nestes exemplos. Com o uso destas técnicas é possível criar, por exemplo, sistemas capazes de adquirir

conhecimento de forma automática.

Ainda na área técnica de Informática, foi necessário pesquisar e testar algoritmos que fossem capazes de extrair características ou atributos de arquivos de áudio e utilizar aqueles que fossem convenientes para a identificação de padrões capazes de auxiliar no processo de análise para obtenção de uma classificação. Estes algoritmos referem-se ao processamento de áudio. Os conceitos supracitados não foram abordados no decorrer da graduação por não fazerem parte da matriz curricular do curso.

O autor deste trabalho dedicou-se, ainda, ao estudo de patologias das valvas cardíacas, o estudo do chamado sopro cardíaco, que podem ser identificadas por meio do exame de ausculta cardíaca, bem como conhecer o ciclo cardíaco e a anatomia básica do coração. Realizou-se também um levantamento da acurácia apontada pelos resultados dos exames e o diagnóstico médico identificando que, na atualidade, muitos diagnósticos na ausculta cardíaca são imprecisos.

Após a etapa de estudos para formulação do tema deste trabalho e proposição de uma solução, iniciaram-se testes para verificar se haveria recursos de *software* disponíveis publicamente para implementação da solução proposta como, por exemplo, algoritmos já implementados para realizar o processamento dos arquivos de áudio e a posterior análise dos dados. Não somente verificar a existência destes algoritmos, mas também a compatibilidade dos dados extraídos de um para serem utilizados em outro deveria ser verificada.

Assim, para verificar a viabilidade de execução deste projeto, os testes realizados ocorreram sobre uma base de dados de arquivos de áudio provenientes de exames de ausculta cardíaca, o qual sua obtenção e organização está explicado na seção 3.4. Além da base de dados, utilizou-se a linguagem de programação Python para realizar o processamento dos arquivos de áudio conforme descrito na seção 3.3.1 deste documento. Os testes de classificação foram realizados a partir de um código implementado na linguagem JAVA, conforme apresentado na seção 3.3.4. Os demais recursos utilizados nestes testes estão descritos a seguir.

### 3.3.1 Bibliotecas para análise de áudio

Para que seja possível analisar arquivos de áudio objetivando encontrar padrões que permitam estabelecer uma classificação destes arquivos, é necessário

utilizar algoritmos de processamento de áudio para extração de seus atributos.

Há na literatura uma série de algoritmos para processamento de áudio com a finalidade de realizar a extração de atributos e, posteriormente, identificar padrões para uma possível classificação.

Em seu trabalho, Filho (2006) utiliza o *software* MARSYAS para a análise, síntese e extração de recursos em arquivos de áudio. Miletto (2004) apresenta *softwares* que possibilitam o trabalho com áudio, como o *Arranger's tool* (acompanhamento de áudio), *Sibelius* (edição de partitura), *Logic Audio Platinum* (gravação de áudio), *Musique* (instrução), *Cakewalk* (sequenciamento) e *Virtual Sound Canvas* (síntese). Costalonga (2005) faz uma listagem de bibliotecas para computação musical na linguagem JAVA, entre elas a Java Sound, JMSL (*Java Music Specification Language*) e JMusic, sendo que algumas não são destinadas para programadores, mas para músicos e, da listagem apresentada, não há uma biblioteca exclusiva para fornecimento de recursos para análise de dados de arquivos de áudio.

Diante dos algoritmos e bibliotecas publicamente disponíveis, adotou-se para a realização de testes as bibliotecas *PyAudioAnalysis* (GIANNAKOPOULOS, 2015) e *libROSA* (LIBROSA, 2018a). Após o estudo de ambas, identificou-se que a biblioteca *libROSA* oferece um leque maior de funções de extração de atributos a serem utilizados na classificação.

A biblioteca *libROSA* foi desenvolvida em linguagem Python e é de código aberto (*open source*). Tem o objetivo de auxiliar na análise de áudio e de músicas (LIBROSA, 2018a). É estruturada em uma série de submódulos onde cada um é destinado para uma funcionalidade específica na análise de arquivos de áudio como, por exemplo, *librosa.beat* para a estimação de tempo e detecção de ocorrências de batidas, *librosa.segment* contém funções para obter a segmentação estrutural do áudio (p.e, matriz de recorrência), *librosa.filters* disponibiliza funções para filtro de áudio, entre outras (LIBROSA, 2018b).

Para a realização dos testes neste projeto, o submódulo *librosa.feature* foi utilizado, pois dispõe de funções para extração e manipulação de recursos de baixo nível, como escalas e medidas.

A seguir, são descritas as funções disponíveis na biblioteca *libROSA* que foram utilizadas nos testes:

- *librosa.load*: realiza a leitura do arquivo de áudio como uma onda (ou

*waveform*) e retorna também a taxa de amostragem do áudio lido, ambos retornados como matrizes;

- *librosa.feature.mfcc*: retorna uma matriz a partir da medida do MFCC do áudio. É passado para esta função as duas matrizes retornadas pela função *librosa.load*;
- *librosa.feature.melspectrogram*: retorna uma matriz com valores da escala de medida *Mel*, a qual está relacionada com a frequência do áudio.

Patel *et al.* (2010) descrevem que a escala *Mel* mede a frequência, na unidade de medida Hertz, de um tom de uma faixa de áudio, uma vez que esta escala tenta alcançar aspectos que assemelham-se ao da sensibilidade do ouvido humano. A partir desta escala é possível calcular coeficientes de *cepstrum* de frequência de mel, ou *mel-frequency cepstrum coefficients* (MFCC), sendo que o conjunto de *cepstrum* são denominados de vetores acústicos.

### 3.3.2 Hidden Markov Model (HMM)

Para trabalhar com as matrizes obtidas no passo anterior, foi necessário utilizar um modelo para transformar cada matriz em um valor discreto numérico para assim ser aplicado em uma tarefa de aprendizado de máquina. Desta forma, com base na leitura bibliográfica (CHAUHAN *et al.*, 2008), foi considerado adequado utilizar o HMM, uma vez que no trabalho de Chauhan *et al.* (2008) foi utilizado um sistema baseado no sinal MFCC e HMM para classificação de sons.

Para o HMM será apresentado a matriz retornada da extração de recursos do áudio, para que seja obtido a probabilidade dos dados, com base nos modelos de Markov que são estimativas relacionadas ao estado de sequência da matriz (RABINER, 1989).

A biblioteca *hmmlearn* (HMMLEARN, 2018) foi utilizada para testar os modelos de Markov; a função *fit* foi utilizada para treinar o modelo a partir da matriz. Após, foi efetuada a chamada do método *decode*, que tem por meta encontrar a sequência de estado provável proporcional a matriz informada, na qual retorna um valor numérico do tipo *float*. Esta biblioteca *open source* é destinada à linguagem Python.

### 3.3.3 Naive Bayes

Naive Bayes é um algoritmo classificador baseado no teorema de Bayes, utilizado em tarefas de aprendizado supervisionado, onde as computações de probabilidades são geradas a partir dos dados de treinamento (FACELI *et al.*, 2011).

O algoritmo classificador Naive Bayes é eficaz ao trabalhar em grande bases de dados, em questões de velocidade é considerado um dos mais rápidos e mesmo por conta de atributos irrelevantes ou faltantes seu desempenho não diminui, sendo visto como um algoritmo relativamente simples (JADHAV; CHANNE, 2016; FACELI *et al.*, 2011).

### 3.3.4 Execução dos Testes

Os testes também foram realizados utilizando-se a linguagem de programação JAVA, pois possui biblioteca própria para uso do WEKA (descrito na seção 3.5.3). O algoritmo Naive Bayes foi aplicado para classificar os arquivos de áudio, sendo acessado via biblioteca WEKA.

Realizou-se a montagem da base de conhecimento utilizando-se dois atributos extraídos (MFCC e a escala *Mel*) e aplicados ao HMM, sendo que os áudios foram coletados de forma aleatória, separando os áudios para grupo de treinamento e de teste. O atributo meta contendo valor nominal de “sopro” para os áudios relacionados ao ciclo cardíaco com sopro e “saudável” para áudios de ciclo cardíaco normal. Estes atributos e os dados foram montados em um arquivo de extensão .arff, como pode ser visualizado na Figura 14.

Para o treinamento da máquina foi aplicado ao algoritmo Naive Bayes a base de conhecimento para construção do modelo. Assim, quando extraídos novos atributos do arquivo de áudio, este registro foi aplicado ao modelo gerado que devolvia uma probabilidade referente a qual classe (“sopro” ou “saudável”) o novo registro pertencia.

## 3.4 Obtenção da Base de Dados

Ainda durante a concepção deste projeto, realizou-se a busca de uma base de dados na área médica que fosse disponível publicamente e que possibilitasse a

realização de uma tarefa de classificação.

O portal Kaggle (KAGGLE INC, 2017b) é uma plataforma de referência para profissionais e estudantes voltados à área de Análise de Dados em que utiliza-se, dentre outras, as técnicas de Aprendizado de Máquina. Esta plataforma permite a colaboração entre as pessoas interessadas em trabalhar com Análise de Dados de forma que é possível encontrar bases de dados nas mais diversas áreas do conhecimento, desde dados sobre saúde, jogos, meio ambiente até populacionais ou de criminalidade de uma determinada região. Além de disponibilizar diferentes bases de dados, o portal promove o estudo e a prática de mineração de dados por meio de competições que concedem prêmios de centenas a milhares de dólares (KAGGLE INC, 2017b).

A base de dados utilizada neste projeto foi publicada por King (KAGGLE INC, 2017a). Esta base é constituída por arquivos de áudio de extensão .wav (ou WAVE), a qual é composta por sequências numéricas e se caracteriza por ser um formato de alta qualidade no armazenamento de áudios digitais (SAYÃO, 2007).

Esta base de dados encontra-se separada em dois grupos de acordo com a fonte da coleta: um grupo possui arquivos de áudio provenientes do aplicativo de celular iPhone iStethoscope Pro, ou seja, os arquivos de áudio foram gerados pelo público. Já o outro grupo de arquivos de áudio foram gerados a partir de estetoscópios digitais em hospitais (KAGGLE INC, 2017a). Para este trabalho escolheu-se utilizar o segundo grupo, pois o mesmo foi coletado em hospitais e, assim, pode-se considerar que o diagnóstico foi estimado por um profissional da área da saúde e é, portanto, mais confiável.

Este grupo escolhido possui 641 itens no total, onde cada arquivo de áudio, em seu nome, contém a sua classificação entre “murmur”, “normal”, “extrastole” e “bunlabelledtest”. Entretanto, como o foco deste projeto é indicar se há presença ou ausência de sopro cardíaco, foram utilizados somente os arquivos intitulados “murmur” e “normal”, totalizando 257 arquivos de áudio, no qual há 192 arquivos com sons normais do ciclo cardíaco e 65 arquivos de áudio com sopro cardíaco.

Assim, com uma base contendo 257 arquivos de áudio, foram utilizados um total de 130 arquivos, os quais foi organizado um grupo de treinamento, para gerar o modelo do sistema e um grupo organizado para teste do modelo gerado, conforme pode ser visualizado no Quadro 4.

Quadro 4 – Quantidade de arquivos de áudio em cada grupo

Grupo	Murmur	Normal	Total de Arquivos
Grupo Treinamento	55	55	110
Grupo Testes	10	10	20
			130

Fonte: O autor, 2018

Analisando o Quadro 4, percebe-se que não foram selecionados todos os arquivos nomeados “normal”, restando 127 arquivos. Dessa maneira, o Grupo de Treinamento fica balanceado, isto é, mesma quantidade de registros para classes diferentes.

### 3.5 Construção dos Módulos e Base de Dados

Nesta seção será explicado o desenvolvimento dos módulos principais desta solução, bem como a linguagem de programação, bibliotecas e ferramentas utilizadas e também a montagem da base de dados para treinamento e testes da solução.

#### 3.5.1 Linguagem de Programação Python

A linguagem de programação Python é uma das mais populares linguagens para DataScience (Ciência dos Dados, na tradução), o qual dispões de várias bibliotecas com o objetivo de trabalhar com métodos de Aprendizado de Máquina e Análise de Dados, sendo aplicada em projetos de diversas áreas, como economia, educação e saúde. Além do mais, possui bibliotecas para realizar leitura, coleta e manipulação de dados provenientes de arquivos de áudio (RASCHKA, 2016). Python também é considerada uma linguagem completa, pois é capaz de ser utilizada nos principais sistemas operacionais, suporta tanto o paradigma de programação estruturada como orientado a objetos (MENEZES, 2014).

Desta forma, a linguagem Python foi escolhida, tendo em vista que esta linguagem possui uma variedade considerável de bibliotecas que são relevantes para a construção desta solução.

### 3.5.2 Bibliotecas Utilizadas

Para o desenvolvimento dos módulos e da interface gráfica desta solução, houve o auxílio de bibliotecas de código aberto, desenvolvidas em Python, as quais estão descritas a seguir.

Uma das bibliotecas utilizadas é *Scikit-learn* (SCIKIT-LEARN, 2018), que disponibiliza um grande leque de algoritmos de aprendizado de máquina, tanto para Aprendizado Supervisionado como para o Aprendizado Não Supervisionado, na qual é focada em projetos de AM para não especialistas e também incentiva seu uso em área acadêmica e comercial, pois possui licença BSD (*Berkeley Software Distribution*) (SCIKIT-LEARN, 2018).

Em seu trabalho, Komer *et al.* (2014) cita que esta biblioteca é comumente utilizada em projetos científicos da comunidade Python e também afirma que os algoritmos suportam muitas áreas de aplicação de AM com boa performance e velocidade.

A biblioteca *PyBrain* (SCHAUL *et al.*, 2010) foi selecionada, pois oportuniza acesso a algoritmos de redes neurais para tarefas de Aprendizado de Máquina. Assim, junto com a biblioteca *Scikit-learn*, foi possível testar diferentes algoritmos classificadores e avaliar qual é o mais adequado para esta solução. Estes testes estão descritos no decorrer desta seção.

Além dessas, a biblioteca *numpy* também foi utilizada pois “[...] é um pacote fundamental para computação científica com o Python” (NUMPY, 2018), cujo este pacote possibilita realização de cálculos com vetores e matrizes multidimensionais (NUMPY, 2018). Esta foi aplicada em cálculos com matrizes, conforme mencionado posteriormente.

Por fim, a biblioteca de alta performance *pandas* (PANDAS, 2018) fornece ferramentas para processamento, análise e manipulação de dados, onde foi utilizada para realizar a leitura da base de dados e separar os dados de atributos e do atributo meta.

As funções das bibliotecas *PyQt5* (PYPI, 2018; RIVERBANK, 2018) e *PyLab* (SCIPY, [201-?]) foram utilizadas para construir a interface gráfica desta solução; *PyQt* é uma biblioteca desenvolvida na linguagem C++ que, além de disponibilizar recursos para construção de interface gráfica do usuário, também possui serviços de localização e posicionamento, conectividade multimídia, entre outros. A partir da

versão 5 possui implementações para a linguagem Python (PYPI, 2018; RIVERBANK, 2018). E a biblioteca *PyLab* é destinada para realizar plotagem em modo 2D, como gráficos e ondas (SCIPY, [201-?]).

### 3.5.3 Ferramenta WEKA

O WEKA (*Waikato Environment Knowledge for Analysis*) é um *software* desenvolvido em linguagem Java por uma equipe da Universidade de Waikato (Nova Zelândia). Atualmente, o WEKA e seu código fonte estão em domínio público, regidos pela GPL (*General Public License*, ou Licença Pública Geral). Seu propósito inicial é trabalhar com mineração de dados, valendo-se de diversos algoritmos e ferramentas de aprendizado de máquina para resolução de problemas de associação, classificação, regressão e agrupamento. Com esta ferramenta é possível ter acesso a tarefas referentes ao aprendizado supervisionado e não supervisionado. Também oferece métodos de pré-processamento e filtragem (UNIVERSITY..., [201-?]).

WEKA permite amostra de dados provenientes de arquivos, em formato CSV (*Comma-Separated Values*) e provenientes de consultas em bases de dados utilizando SQL (*Structure Query Language*). Nesta figura, na parte superior, é possível visualizar abas que são referentes aos tipos de tarefa que podem ser realizadas: “classificar”, “agrupar” e “associar”. Na aba “classificar”, são disponibilizados algoritmos para as tarefas de aprendizado supervisionado e não supervisionado.

O WEKA utiliza um formato específico de arquivo o qual recebe a extensão ARFF (*Attribute-Relation File Format*) (UNIVERSITY..., 2008). Este arquivo armazena os dados de uma maneira específica capaz de ser lida pela ferramenta. É composto de duas partes: um cabeçalho e a seção com o conjunto de dados.

A definição do arquivo inicia-se com a declaração da relação no cabeçalho. Assim, deve-se definir um nome para a relação na primeira linha do arquivo da seguinte maneira: *@relation <nome da relacao>*.

Em seguida e ainda no cabeçalho, deve-se declarar os atributos por meio de uma sequência ordenada. Cada atributo deve possuir sua própria declaração usando a expressão *@attribute* a qual identifica unicamente o nome deste atributo. A ordem em que são declarados indicam a ordem em que aparecem no conjunto de

dados (instâncias). Assim, deve-se declarar para cada atributo utilizando o seguinte formato: `@attribute <nome do atributo> <tipo de dado>`.

Cada atributo deve ter o seu tipo de dados definidos. Os tipos de dados suportados pelo WEKA normalmente são: números (reais ou inteiros), texto livre ou pré-determinado e data com um formato definido (p.e.: dd-mm-aaaa).

Por fim, devem ser declaradas as instâncias na seção do conjunto de dados. A declaração deve-se iniciar pela expressão `@data` e ser seguida da lista de instâncias devendo ser declarada uma instância por linha.

Um exemplo de um arquivo no formato ARFF é apresentado na Figura 14 seguir.

Figura 14 – Exemplo de arquivo ARFF

```
@RELATION analiseDeSopro

@ATTRIBUTE mfcc NUMERIC
@ATTRIBUTE melspectrogram NUMERIC
@ATTRIBUTE condicao {saudavel, sopro}

@DATA
-377.82155666978815, -572.1750845007649, saudavel
-507.9295886604381, 1775.101518884849, saudavel
-594.0013256168958, 6447.093423644186, saudavel
-330.1913585777361, 179.5286971862667, saudavel
-233.0678556821509, -1194.629157843254, saudavel
-33.02794490293678, -80.45069170214767, saudavel
-546.4772492285333, 736.4103777882127, saudavel
-390.4772101987087, 1460.04241292887, saudavel
-473.26956299839316, 573.2124213765441, saudavel
-482.0289354281654, -2057.123128705004, saudavel
-302.54423374573446, -400.15091405735285, sopro
-477.25975022415497, -1220.4831045265823, sopro
-198.92280690420037, -357.5919030306625, sopro
-580.3533611324756, -1009.8245590976635, sopro
-413.29641469533306, 1866.2506777528283, sopro
-426.7545054308865, 2563.8055623251457, sopro
-323.707270497972, -6881.943180033719, sopro
-379.8191767737052, 1914.9012931010752, saudavel
-128.59120649120268, 1141.5131565774238, saudavel
-266.939982782147, 1337.3856018810557, sopro
-372.18081543421386, -1540.039296782886, sopro
```

Fonte: O autor (2018).

Esta ferramenta foi utilizada com propósitos de melhor visualização dos dados da base de dados construída e a aplicação desta base de dados em algoritmos de classificação supervisionado fornecidos pela ferramenta. Após a

execução de cada algoritmo, verificava-se a matriz de confusão<sup>2</sup> gerada e a porcentagem da acurácia do algoritmo. Desta forma, algoritmos com melhores resultados foram selecionados para testes no Módulo Analisador de Dados, explicado na seção 3.5.6.

### 3.5.4 Módulo Processador de Áudio (MPA)

Como explanado e apresentado na Figura 13 anteriormente, o Módulo Processador de Áudio tem como objetivo realizar a leitura de um arquivo de áudio informado pelo usuário e extrair atributos que irão compor a base de dados. Para isso realizou-se pesquisas e testes sobre quais recursos de áudio poderiam ser candidatos a se tornar um atributo na base de dados.

Deste modo, utilizou-se dos métodos da biblioteca *libROSA* (LIBROSA, 2018a) para testes de coleta de recursos e a biblioteca *numpy* (NUMPY, 2018) para transformar os dados obtidos em valores discretos numéricos. Seguidamente, é detalhado o processamento do MPA.

Após realizada a leitura do arquivo de áudio, obtém-se uma matriz contendo os valores numéricos da onda (ou *waveform*) do som. Assim, nas demais funções pesquisadas e experimentadas que estão descritas a seguir, foi utilizado como parâmetro de entrada esta matriz de *waveform*:

- *librosa.stft*: decompõem o áudio em blocos de construção que são mais acessíveis para as etapas de processamento subsequentes. Esta decomposição é feita utilizando a técnica de *short-time Fourier transform* ou STFT (Transformada de Fourier de curta duração, na tradução) (MÜLLER, 2015; LIBROSA, 2018a);
- *librosa.decompose.hpss*: decompõem o áudio retornando componentes de fonte percussiva e harmônica (LIBROSA, 2018a);
- *librosa.segment.recurrence\_matrix*: calcula a matriz de recorrência a partir da matriz de *waveform* (LIBROSA, 2018a);
- *librosa.feature.poly\_features*: obtem-se coeficientes de um polinômio a partir de blocos de frequências de vibração do áudio (LIBROSA, 2018a).
- *librosa.feature.tonnetz*: calcula a rede harmônica (rede de tons) do áudio

---

<sup>2</sup> “A matriz de confusão é a forma de representação da qualidade obtida de uma classificação [...], sendo expressa por meio da correlação de informações dos dados de referência [...] com os dados classificados.” (PRINA; TRENTIN, 2015, p. 132)

(HARTE; SANDLER; GASSER, [2006]; LIBROSA, 2018a);

- *librosa.core.irrt*: retorna domínios de tempo e frequência, no qual utiliza filtros de resposta impulsiva infinita (IIR); e
- *librosa.core.magphase*: retorna a magnitude calculada a partir da *waveform* (LIBROSA, 2018a).

As funções da biblioteca *libROSA* usadas no teste de viabilidade continuaram a ser utilizadas na construção do módulo.

Após a execução de cada função descrita acima, é retornado uma matriz, onde deve ser transformada em um valor numérico discreto. Para isso foi calculado a norma de Frobenius (ou norma Euclidiana) da matriz, utilizando a função *numpy.linalg.norm*, proveniente da biblioteca *numpy*, que recebe uma matriz ou vetor como valor de entrada retornando, assim, um valor discreto não negativo.

Este processamento será realizado primeiramente toda vez que informado um novo arquivo de áudio e solicitada a sua classificação, conforme pode ser visto na Figura 13.

### 3.5.5 Construção da Base de Dados

Na construção da base de dados para treinamento e teste do sistema, utilizou-se o módulo MPA e o Grupo de Treinamento e Teste organizado com os arquivos de áudio obtidos no portal Kaggle (KAGGLE INC, 2017a), conforme explicado anteriormente.

Desta forma, cada arquivo de áudio foi aplicado ao módulo e o dado retornado das funções utilizadas, isto é, o valor discreto numérico não negativo, se tornava um atributo na base de dados. Ao fim do processamento de um arquivo, obteve-se 10 (dez) atributos que formam um registro na base.

Desta forma, os arquivos de áudio processados provenientes do Grupo de Treinamento formaram a base de dados de treinamento do sistema, a mesma que gera o modelo do algoritmo. E o restante dos arquivos, isto é, arquivos do Grupo de Teste, formaram a base de dados de teste, para validação do modelo gerado.

Tuplas formadas por atributos de arquivos de áudio com nome “murmur” receberam o valor 0 (zero). Já os registros formados por atributos de arquivos de áudio com nome “normal” foi atribuído o valor 1 (um) ao atributo meta.

Por finalmente, possui-se uma base de treinamento com 110 registros, sendo 55 registros provenientes de arquivos de áudio com sopro e outros 55 provenientes de arquivos de áudio com sons normais do ciclo cardíaco. E, para a base de testes contendo 20 registros, 10 com presença de sopro e outros 10 normais.

### 3.5.6 Módulo Analisador de Dados (MAD)

Seguindo a arquitetura proposta, o Módulo Analisador de Dados receberá um registro, proveniente do módulo MPA, e aplica métodos de análise de dados para identificação de padrões para, assim, classificar o arquivo de áudio informado, cujo estes métodos de análise de dados dizem respeito aos algoritmos classificadores que foram testados.

Os algoritmos testados foram acessados via biblioteca *Scikit-learn* e *Pybrain*, utilizando a base de dados de treinamento para gerar o modelo e aplicando os registros da base de testes para classificá-los e avaliar, assim, a eficiência e assertividade de cada algoritmo, conforme especificações de cada algoritmo.

O processamento deste módulo pode ser visualizado na Figura 13 e se dá pela seguinte forma:

- a) Leitura da base de dados de treinamento, utilizando a função *read\_csv* da biblioteca *pandas*;
- b) É realizado a separação dos dados dos atributos para o vetor  $X$  e suas respectivas classificações, isto é, o valor do atributo meta, é atribuído a um vetor  $y$ ;
- c) O treinamento do algoritmo é efetuado utilizando os vetores  $X$  e  $y$ ;
- d) É feita a predição, ou classificação, informando o registro resultante do MPA.

Os algoritmos que foram testados estão explicados a seguir:

- *sklearn.ensemble.BaggingClassifier*: possui um conjunto de métodos que combina predições a partir de múltiplos algoritmos de AM;
- *sklearn.tree.DecisionTreeClassifier*: em seu treinamento, o algoritmo de Árvore de Decisão gera sequências de regras simples, que são aplicadas na predição de um registro. Essas regras são perguntas que, dependendo da resposta, levam a um novo nó da árvore que contém uma nova

pergunta. Assim, sucessivamente, até chegar a uma classificação;

- *sklearn.neural\_network.MLPClassifier*: rede neural classificadora *Mult Layer Perceptron* possui função para não entrar em *log-loss*, isto é, perda de performance;
- *Backpropagation*: rede neural que utiliza método de *Backpropagation* para treinamento, acessado via biblioteca *PyBrain*, onde o número de neurônios de entradas e a quantidade de camadas ocultas é equivalente a quantidade de atributos contidos na base de treinamento;
- *sklearn.svm.SVC*: o algoritmo de Máquina de Vetor de Suporte *SVC* (*Support Vector Classification*, na tradução, Vetor de Suporte de Classificação), fundamenta-se em estatísticas para realizar o treinamento (LORENA; CARVALHO, 2003);
- *sklearn.svm.LinearSVC*: Vetor de Suporte Linear também é baseado em estatística para realizar o treinamento, entretanto utiliza conjunto linear de métodos para realizar combinações de dados (LORENA; CARVALHO, 2003);
- *sklearn.svm.NuSVC*: Nu-Vetor de Suporte é similar ao *SVC*, mas usa parâmetros que limitam a quantidade de vetores de suporte;
- *sklearn.neighbors.KNeighborsClassifier*: este algoritmo aplica cada registro da base de dados de treinamento para formar pontos criando uma “vizinhança”. Assim, classifica novos registros analisando qual registro (ou “vizinho”) é mais próximo;
- *sklearn.ensemble.RandomForestClassifier*: é um algoritmo estimador que se ajusta conforme dados de entrada, formando várias árvores de decisão;
- e
- *sklearn.ensemble.ExtraTreesClassifier*: semelhante ao *RandomForest*, *ExtraTrees* randomiza a construção de Árvores de Decisão onde utiliza estimadores para limitar a profundidade da árvore.

Como explicado anteriormente, a base de dados de teste é composta de 20 arquivos de áudio, ou seja, após aplicados no módulo MPA, têm-se 20 registros para a serem testados nos 10 algoritmos que foram apresentados.

### 3.6 Considerações Finais

Nesta seção, inicialmente foram abordados aspectos referentes à descrição da solução desenvolvida, foram listados os requisitos funcionais e os não funcionais da solução proposta e, de mesma forma, foi explanado sobre o estudo de viabilidade, esclarecendo seu motivo e como decorreu o estudo.

Posteriormente, a base de dados (que é essencial para este trabalho) foi apresentada, descrevendo sua origem e organização. Uma abordagem sobre a linguagem de programação que foi escolhida para codificar esta solução foi feita, assim como suas características e o motivo de sua escolha, tal como as bibliotecas utilizadas para o desenvolvimento das funcionalidades. A ferramenta WEKA que, tanto usada no estudo de viabilidade como foi usada nos testes, foi exibida, bem como descrito sobre o formato ARFF que esta ferramenta utiliza.

Por fim, foi descrito sobre a construção da base de dados para treinamento e testes da solução, assim como sobre o desenvolvimento dos módulos, listando as funções utilizadas, os atributos extraídos e algoritmos utilizados.

## 4 RESULTADOS OBTIDOS

Neste capítulo são apresentados os resultados obtidos nos testes do sistema para escolha dos atributos e do algoritmo classificador. Também apresentada a interface gráfica desenvolvida para o usuário ter acesso as funcionalidades do sistema.

### 4.1 Resultados dos testes

Para esta solução se tornar eficaz em seu objetivo, foram realizados diversos testes e pesquisas para a construção dos módulos MPA e MAD. De mesma forma, a partir da base de dados de treinamento construída, foram elaboradas outras 11 (onze) base de dados, realizando combinações diferentes entre os atributos, de forma empírica.

Os algoritmos classificadores foram aplicados em cada base de dados de treinamento a fim de realizar seu respectivo treinamento. Para cada registro da base de teste foi solicitada a sua classificação para validar o modelo gerado.

Portanto, registros de teste oriundos de arquivos de áudio com nome “murmur” deveriam retornar como classificação o valor 0 (zero) e arquivos de áudio com nome “normal” retornaria classificação com o valor 1 (um), pois na base de treinamento o atributo meta possui valor 0 para registros classificados com sopro e 1 para registros classificados como normais.

Durante a realização dos testes observou-se que a base de treinamento com a combinação entre os atributos *mfcc* – *poly* – *tonnetz* – *melspectrogram* e *magnitude*, obteve-se melhores resultados em certos algoritmos, como pode ser visualizado no Quadro 5 abaixo, o qual mostra uma relação entre esta base de dados e a quantidade de classificações corretas dos algoritmos testados, utilizando cada arquivo de áudio da base de testes.

Quadro 5 – Relação entre algoritmos x corretitude na classificação do arquivo

Algoritmo	Sopro	Normal
<i>Bagging</i>	5	8
<i>DecisionTree</i>	5	5
<i>MLP Classifier</i>	6	8
<i>Backpropagation</i>	6	3
<i>Vetor de Suporte</i>	2	7
<i>Nu-Vetor de Suporte</i>	0	10
<i>Vetor de Suporte Linear</i>	7	8
<i>KneighborsClassifier</i>	5	8
<i>RandomForest</i>	5	7
<i>ExtraTreesClassifier</i>	5	6

Fonte: O autor, 2018.

Analisando o quadro acima, conclui-se que o algoritmo adequado a compor o Módulo Analisador de Dados é o Vetor de Suporte Linear, acertando 70% arquivos de áudio com sopro e acertando 80% arquivos de áudio com sons normais do ciclo cardíaco.

Outro algoritmo que alcançou bons resultados foi a rede neural *MLP Classifier*, onde acertou a mesma quantidade de arquivos de áudio normais que o algoritmo Vetor de Suporte de Linear e um a menos de arquivos com sopro cardíaco.

Acredita-se que a acurácia foi baixa, pois a base de treinamento é relativamente pequena; 110 registros no total, sendo 55 registros para treinamento com sopro e 55 para treinamento com normal. Por esta razão, utilizando-se arquivos de áudio que restaram na composição do Grupo de Treinamento, isto é, 127 arquivos da classe “normal”, foi montada uma base de treinamento com mais registros: 237 registros no total, sendo 182 registros para treinamento como normal e 55 para treinamento como sopro (mesma quantidade de tuplas da primeira base testada). Para esta nova base de treinamento também foram criadas outras 11 (onze) bases de forma empírica, realizando combinações entre os atributos e aplicando-os nos algoritmos classificadores para geração do modelo.

Nos testes, o melhor algoritmo classificador foi o *DecisionTree* (Árvore de Decisão, na tradução) com a combinação de atributos *stft – decompA – decompB* e *relacaoRecorrendencia*, obtendo-se uma acurácia de 40% em classificações de registros com sopro e 70% de acerto em registros compostos por sons normais do

ciclo cardíaco.

Comparando os resultados obtidos desta solução com os resultados dos trabalhos correlatos, vê-se que a acurácia foi baixa. Com base nisso, o autor considera que ao aumentar a base de treinamento com quantidade de registros equivalentes, isto é, mesma quantidade de registros derivados com sopro e normal, pode haver aumento na acurácia do sistema.

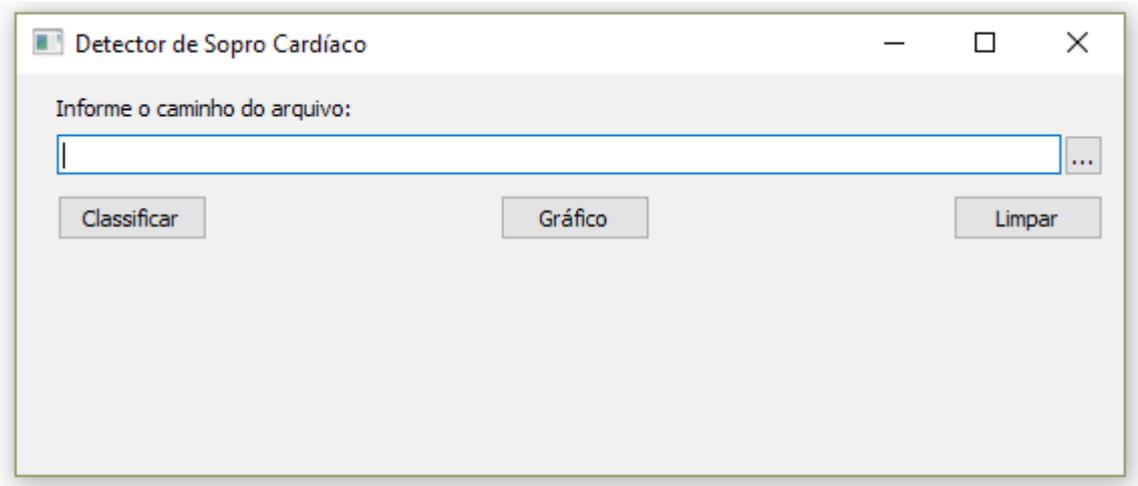
Por ora, conclui-se que para esta solução é adequado utilizar a base de dados reduzida, com 110 registros, junto com algoritmo Vetor de Suporte Linear para realizar a geração do modelo e classificação de registros.

## 4.2 Interface gráfica

Foi desenvolvida uma interface gráfica para o usuário informar o arquivo de áudio a ser classificado, o acesso à solicitação de classificação e também a funcionalidade de gerar uma plotagem da *waveform* do arquivo de áudio informado. Para isso foram utilizadas as funções das bibliotecas *PyQt5* e *PyLab*.

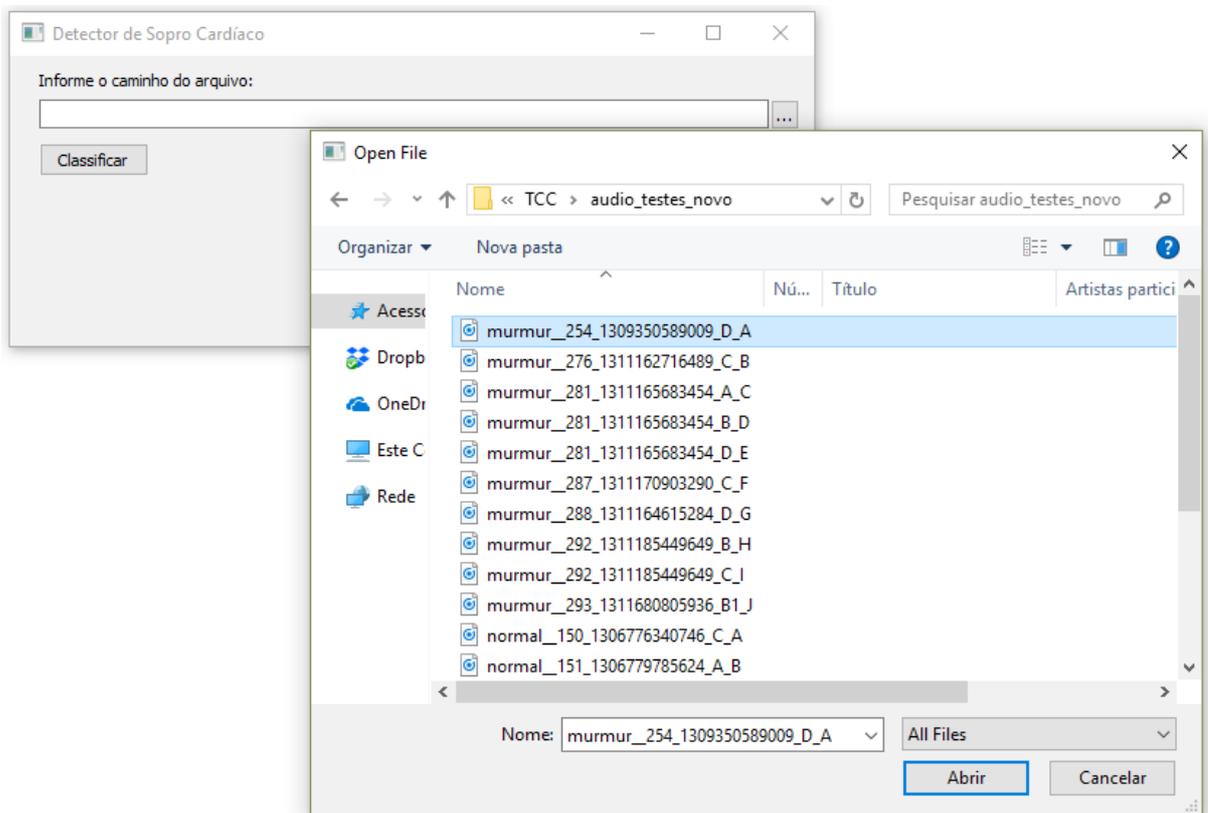
A Figura 15 mostra a tela inicial do sistema, onde é possível visualizar o campo para informar o arquivo de áudio e o explorador de arquivos para selecionar o arquivo é mostrado na Figura 16. Também é possível visualizar o botão “Classificar”, que, uma vez informado o arquivo, passa pelos módulos MPA e MAD e apresenta a classificação em forma de texto, como pode ser visualizado na Figura 17. A Figura 18, apresenta uma plotagem do arquivo de áudio, após ser clicado no botão “Gráfico”, onde é possível acessar funcionalidades como ampliar determinada parte do gráfico, transcorrer pelo gráfico ampliado, voltar para o tamanho original e salvar o gráfico como imagem. Por fim, o botão “Limpar” serve para retirar a informação da classificação e limpar o campo onde é informado o caminho do arquivo de áudio.

Figura 15 – Tela inicial do sistema



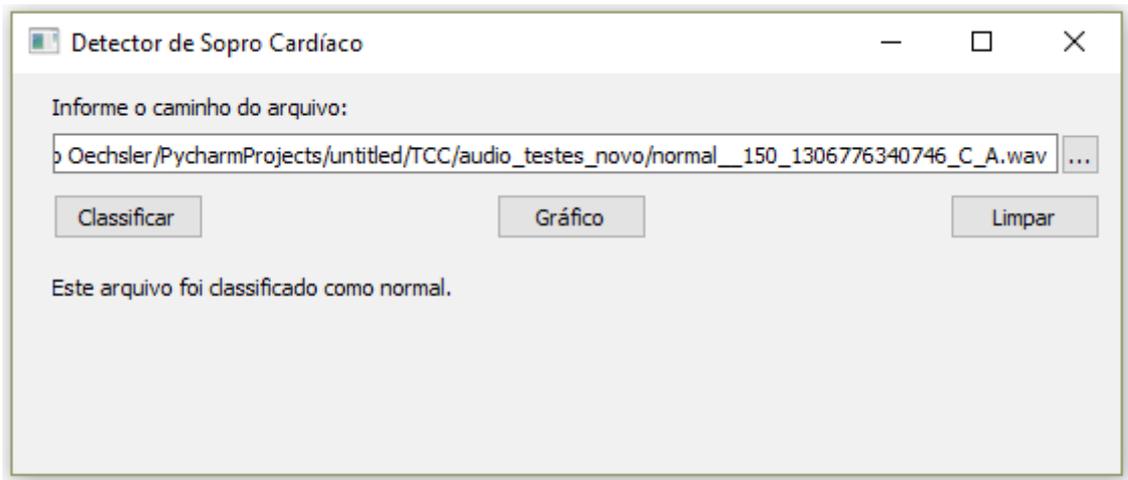
Fonte: O autor (2018).

Figura 16 – Explorador de arquivos para seleção de arquivo de áudio



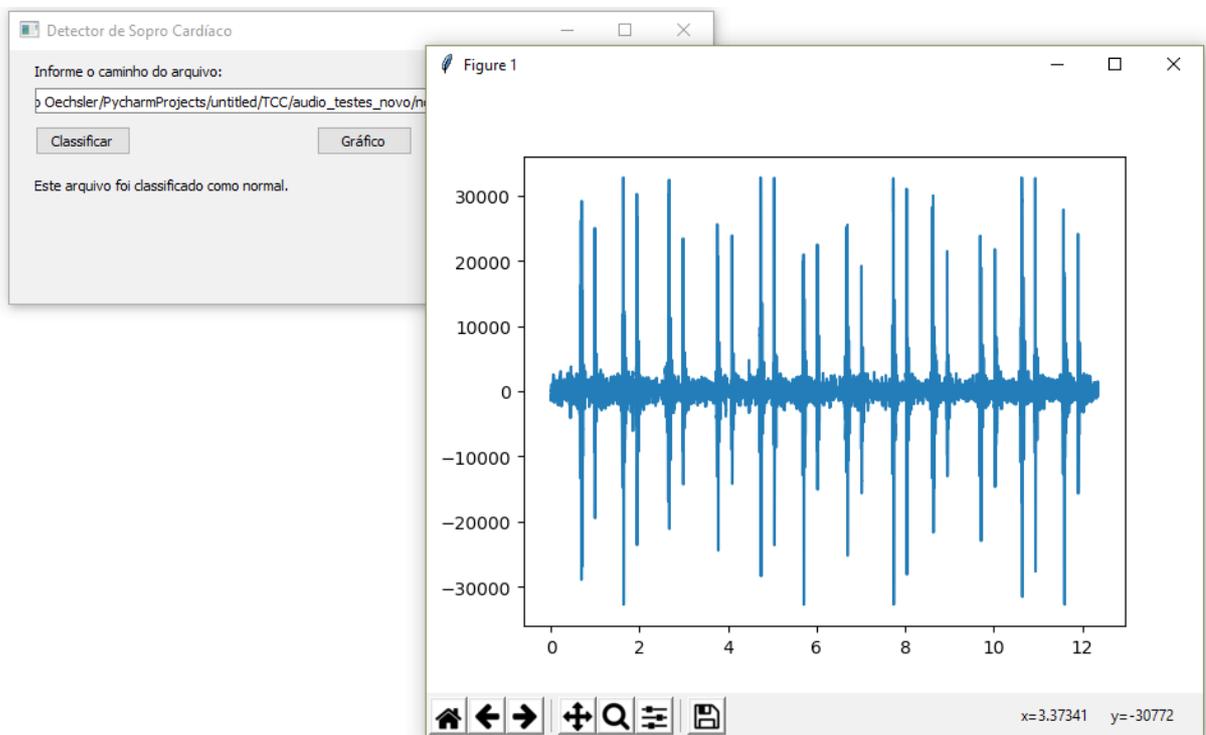
Fonte: O autor (2018).

Figura 17 – Exemplo de classificação de arquivo normal



Fonte: O autor (2018).

Figura 18 – Exemplo de plotagem do arquivo informado



Fonte: O autor (2018).

## 5 CONCLUSÃO

Ao fim deste projeto, foi possível ter conhecimento que doenças cardíacas são um sério problema, pois é o principal causador de mortes a nível global e também nacional. Além disso, explicou-se que o mau funcionamento das valvas cardíacas podem causar sérios problemas, inclusive, se não reconhecido a patologia com antecedência e tratado corretamente, pode causar o óbito do paciente. Também foi mencionado que este mal funcionamento valvar pode ser descoberto por meio da ausculta cardíaca, detectando, durante o ciclo cardíaco, o sopro cardíaco. Entretanto há chances de existir falhas durante a análise auscultatória do paciente, que podem ser devido a questões da capacidade do ouvido humano de escutar ruídos de baixa frequência ou pela inexperiência do profissional. Assim, um diagnóstico incorreto pode ser realizado.

Tendo em vista este panorama, foi desenvolvida uma solução que tem por principal objetivo auxiliar no diagnóstico de ausculta cardíaca, classificando um arquivo de áudio proveniente da ausculta cardíaca entre “com presença de sopro” e “saudável”. Para isso, empregou-se técnicas de Processamento de Áudio para coleta de dados do arquivo de áudio e métodos de Aprendizado de Máquina para análise de padrões e classificação deste arquivo, ou seja, o sistema foi desenvolvido em dois módulos principais: Módulo Processador de Áudio (MPA) e Módulo Analisador de Dados (MAD), sendo estes módulos desenvolvidos utilizando a linguagem de programação Python e suas bibliotecas.

Após os testes experimentados extraindo características dos arquivos de áudio da base de dados obtida no portal Kaggle (KAGGLE, 2017a), foi constatado que no MPA, os atributos significativos a serem extraídos do arquivo de áudio estão relacionados à escala, frequência, tonalidade e magnitude do áudio. No MAD, o algoritmo adotado a ser responsável pela análise de dados e realizar a classificação do arquivo de áudio em “presença de sopro” ou “saudável” é o Vetor de Suporte Linear.

Desta forma, profissionais da área da saúde, ao utilizar este sistema complementarmente ao exame clínico e de ausculta, podem se certificar sobre a presença de sopro cardíaco em um paciente ou se o mesmo se encontra normal, reduzindo o número de diagnósticos incorretos, descobrindo doenças em pacientes que seriam considerados saudáveis e evitando o encaminhamento de um paciente

saudável a exames desnecessários ou mesmo à internação.

Este projeto ademais, disponibiliza a realização de trabalhos futuros que podem aperfeiçoar ainda mais este sistema, como este vir a ser uma aplicação em plataforma WEB ou com acesso via dispositivo móvel e ter como atributos, além dos recursos extraídos de áudio, informações sobre o paciente como peso, altura, idade, etc. Assim, além de classificar o arquivo entre “presença de sopro” ou “saudável”, também poderá ser indicado o tipo de sopro. Pode-se, ainda, serem estudadas outras formas de coletar dados do arquivo de áudio e de classificá-lo, utilizando tecnologias diferentes das mencionadas neste projeto e inclusive a utilização de métodos de verificação dos atributos relevantes para compor a base de conhecimento, como, por exemplo, a Análise dos Componentes Principais (ACP) (HONGYU *et al.*, 2015), com o objetivo de aumentar a acurácia na classificação.

O autor ainda sugere uma validação prática, junto a uma clínica, hospital ou profissional da área da saúde, coletando arquivos de áudio de pacientes com valvopatia e aplicando ao sistema para realizar sua classificação e avaliar a sua acurácia. Para isso deve-se atentar que, para realizar coleta de dados de seres humanos, é necessário o Termo de Consentimento Informado e o mesmo ser aprovado por uma comissão de ética.

## REFERÊNCIAS

ALMEIDA, Ulisses Nairne de. **Reconhecimento de ritmo musical por análise de sinais de áudio de amplitude e frequência**. 2009. 43 p. Trabalho de conclusão de curso (Graduação em Ciência da Computação) – Centro Universitário La Salle, Canoas, RS, 2009. Disponível em: <[https://biblioteca.unilasalle.edu.br/docs\\_online/tcc/graduacao/ciencia\\_da\\_computacao/2009/unalmeida.pdf](https://biblioteca.unilasalle.edu.br/docs_online/tcc/graduacao/ciencia_da_computacao/2009/unalmeida.pdf)>. Acesso em : 29 abr. 2018.

AMARAL, Fernando. **Aprenda mineração de dados: teoria e prática**. Rio de Janeiro: Alta Books, 2016a. Disponível em: <<https://bit.ly/2kCV5WB>>. Acesso em: 30 maio 2018.

AMARAL, Fernando. **Introdução à ciência de dados: mineração de dados e big data**. Rio de Janeiro: Alta Books, 2016b.

BRASIL. **Cerca de 300 mil brasileiros morrem de doenças cardiovasculares por ano**. 2017. Disponível em: <<http://www.brasil.gov.br/saude/2017/09/cerca-de-300-mil-brasileiros-morrem-de-doencas-cardiovasculares-por-ano>>. Acesso em: 26 fev. 2018.

CHAUHAN, Sunita *et al.* A computer-aided MFCC based HMM system for automatic auscultation. **Computers in Biology and Medicine**, v. 38, p. 221-233, feb. 2008. Disponível em: <<https://goo.gl/kVTDxL>>. Acesso em: 10 abr. 2018.

CONTI, C. Richard. **Sistema cardiovascular**. Rio de Janeiro: Elsevier, 2015. (Netter de ilustrações médicas; 8). Disponível em: <<https://bit.ly/2juAMdv>>. Acesso em: 03 abr. 2018.

COSTALONGA, Leandro L. *et al.* **Bibliotecas Java aplicadas a computação musical**. 2005. Disponível em: <<https://goo.gl/4vRPqf>>. Acesso em: 17 maio 2018.

DELGADO-TREJOS, Edilson *et al.* Digital auscultation analysis for heart murmur detection. **Annals of Biomedical Engineering**, v. 37, p. 337-353, feb. 2009. Disponível em: <<https://link.springer.com/content/pdf/10.1007%2Fs10439-008-9611-z.pdf>>. Acesso em: 25 maio 2018.

FACELI, Katti *et al.* **Inteligência artificial: uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC, 2011.

FERRARA, Marcos Rogério. **Utilização de redes neurais artificiais para a identificação do diabetes mellitus**. 2005. 74 p. Monografia (Bacharel em Ciência da Computação) – Curso de Ciência da Computação, Fundação de Ensino “Eurípides Soares da Rocha”, Centro Universitário Eurípides de Marília, Marília, SP, 2005. Disponível em: <<https://bit.ly/2rgwNpc>>. Acesso em: 10 abr. 2018.

FILHO, Moacir da Cruz Souza. **Classificação automática de gêneros de áudio digital**. 2006. 60 p. Monografia (Bacharel em Engenharia da Computação) – Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, PE. 2006. Disponível em: <<http://tcc.ecomp.poli.br/20062/MoacirFilho.pdf>>. Acesso em: 07 maio 2018.

GIANNAKOPOULOS, Theodoros. pyAudioAnalysis: An open-source Python library for audio signal analysis. **PLOS One**, v. 10, n. 12, p. 1-17, dec. 2015. Disponível em: <[goo.gl/88ZkFd](http://goo.gl/88ZkFd)>. Acesso em: 16 jun. 2018.

GRUS, Joel. **Data science do zero**. Rio de Janeiro: Alta Books, 2016.

GUARIZI, Débora D. *et al.* Estudo da inteligência artificial aplicada na área as saúde. **Colloquium Exactarum**, Presidente Prudente, v. 06, n. esp., p. 26-37, jul./dez. 2014. Disponível em: <<https://goo.gl/STKvtD>>. Acesso em: 26 mar. 2018.

HALL, John E. **Tratado de fisiologia médica**. 12. ed. Rio de Janeiro: Elsevier, 2011.

HARTE, Christopher; SANDLER, Mark; GASSER, Martin. **Detecting harmonic change in musical audio**. [2006]. Disponível em: <<http://www.ofai.at/~martin.gasser/papers/oefai-tr-2006-13.pdf>>. Acesso em: 01 out. 2018.

HAUERT, Sabine. Eight ways intelligent machines are already in your life. **BBC News**, 25 abr. 2017. Disponível em: <<http://www.bbc.com/news/uk-39657382>>. Acesso em: 28 mar. 2018.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. New Jersey: Pearson, 2009. Disponível em: <<http://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf>>. Acesso em: 23 abr. 2018.

HERRERA, Christian Gonçalves. **Projeto de sistemas de processamento digital de sinais de áudio utilizando metodologia científica**. 2004. 101 p. Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, MG, 2005. Disponível em: <<https://www.ppgee.ufmg.br/defesas/486M.PDF>>. Acesso em: 29 abr. 2018.

HMMLEARN. 2018. Disponível em: <<http://hmmlearn.readthedocs.io/en/latest/index.html>>. Acesso em: 02 mar. 2018.

HONDA. **Honda debuts new humanoid robot "ASIMO"**. 2000. Disponível em: <<http://world.honda.com/news/2000/c001120b-eng.html>>. Acesso em: 25 maio 2018.

HONGYU, Kuang *et al.* Análise de Componentes Principais: resumo teórico,

aplicação e interpretação. **E&S – Engineering and Science**, v.1, 5 ed., 2015. Disponível em: <<https://goo.gl/efSKaz>>. Acesso em: 21 nov. 2018.

ISMAIL, Kamarulafizam Bin. **Heart murmur detection and analysis using multipoint auscultation system**. 2015. 43 p. Tese (Doutorado em Engenharia Biomédica) - Universiti Teknologi Malaysia, Faculty of Biosciences and Medical Engineering, Malásia, 2015. Disponível em: <<https://goo.gl/3xxfTG>>. Acesso em: 13 jun. 2018.

ITTICHAICHAREON, Chadawan; SUKSRI, Siwat; YINGTHAWORNSUK, Thaweesak. Speech recognition using MFCC. In: INTERNATIONAL CONFERENCE ON COMPUTER GRAPHICS, SIMULATION AND MODELING, 2012, Pattaya, Tailândia. **Anais...** Pattaya, Tailândia, 2012. p. 135-138. Disponível em: <<https://goo.gl/Nmtxc9>>. Acesso em: 29 abr. 2018.

JADHAV, Sayali D.; CHANNE H. P. Comparative study of K-NN, Naive Bayes and Decision Tree classification techniques. **International Journal of Science and Research (IJSR)**, v. 5, n. 1, p. 1842-1845, jan. 2016. Disponível em: <<https://pdfs.semanticscholar.org/51c0/68c263ee197a292df5b74b58c8c55df9f9ca.pdf>>. Acesso em: 14 jun. 2018.

JIMENEZ, Joe A. *et al.* Heart murmur detection using ensemble empirical mode decomposition and derivations of the mel-frequency cepstral coefficients on 4-area phonocardiographic signals. **Computing in Cardiology**, v. 41, p. 493-496, 2014. Disponível em: <<http://www.cinc.org/archives/2014/pdf/0493.pdf>>. Acesso em: 4 maio 2018.

JUSTO, Daniela Sbizera. **Similaridade comportamental do consumo residencial de eletricidade por rede neural baseada na teoria da ressonância adaptativa**. 2016. 158 p. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual Paulista, Faculdade de Engenharia, Ilha Solteira, SP, 2016. Disponível em: <[https://repositorio.unesp.br/bitstream/handle/11449/143947/justo\\_ds\\_dr\\_ilha.pdf?sequence=3&isAllowed=y](https://repositorio.unesp.br/bitstream/handle/11449/143947/justo_ds_dr_ilha.pdf?sequence=3&isAllowed=y)>. Acesso em: 26 abr. 2018.

KAGGLE INC. **Heart beat sounds**. 2017a. Disponível em: <<https://www.kaggle.com/kinguistics/heartbeat-sounds>>. Acesso em: 05 dez. 2017.

KAGGLE INC. **Kaggle**. 2017b. Disponível em: <<https://www.kaggle.com/>>. Acesso em: 09 ago. 2017.

KOBINGER, Maria Elisabeth B. A. Avaliação do sopro cardíaco na infância. **Jornal de Pediatria**. v. 79, supl. 1, p. S87-S96, 2003. Disponível em: <<http://www.scielo.br/pdf/%0D/jped/v79s1/v79s1a10.pdf>>. Acesso em: 30 mar. 2018.

KOMER, Brent *et al.* Hyperopt-Sklearn: automatic hyperparameter configuration for scikit-learn. **13th Python In Science Conf**, 2014. Disponível em

<<http://compneuro.uwaterloo.ca/files/publications/komer.2014b.pdf>>. Acesso em: 10 out. 2018.

KISHIMOTO, André. **Inteligência artificial em jogos eletrônicos**. 2004. Disponível em: <[http://www.karenreis.com.br/pdf/andre\\_kishimoto.pdf](http://www.karenreis.com.br/pdf/andre_kishimoto.pdf)>. Acesso em: 10 abr. 2018.

LATHA, R.; SABANAYAGAM, A.; ANEESH, Y. Mohammed. Heart sound and abnormal heart sound detection method based on signal characteristic. **International Journal of Mathematical Sciences and Engineering (IJMSE)**, v. 5, n. 2, p. 99-103, mar. 2017. Disponível em <<http://vietw.ac.in/pdf/ijmse/08/16.pdf>>. Acesso em: 13 jun. 2018.

LEVIATHAN, Yaniv; MATIAS, Yossi. **Google duplex**: an AI system for accomplishing real-world tasks over the phone. 2018. Disponível em: <<https://ai.googleblog.com/2018/05/duplex-ai-system-for-natural-conversation.html>>. Acesso em: 14 maio 2018.

LIBROSA. 2018a. Disponível em: <<https://librosa.github.io/librosa/>>. Acesso em: 02 mar. 2018.

LIBROSA: tutorial. 2018b. Disponível em: <<https://librosa.github.io/librosa/tutorial.html>>. Acesso em: 02 mar. 2018.

LORENA, Ana Carolina; CARVALHO, Andre C. P. L. F. de. Introdução às máquinas de vetores suporte (support vector machines). **Relatórios Técnicos Do ICMC**. São Carlos – SP, n. 192, abr. 2003. Disponível em: <[http://conteudo.icmc.usp.br/CMS/Arquivos/arquivos\\_enviados/BIBLIOTECA\\_113\\_RT\\_192.pdf](http://conteudo.icmc.usp.br/CMS/Arquivos/arquivos_enviados/BIBLIOTECA_113_RT_192.pdf)>. Acesso em: 26 out. 2018.

MARTINS, Paula *et al.* O sopro num coração normal. **Rev. Port. Cardiol.**, Coimbra, Portugal, v. 27, n. 6, p. 815-831, jun. 2008. Disponível em: <<http://rihuc.huc.min-saude.pt/bitstream/10400.4/1367/1/Innocent%20heart%20murmurs.pdf>>. Acesso em: 26 fev. 2018.

MAYO CLINIC. **Heart murmurs**. 2018a. Disponível em: <<https://www.mayoclinic.org/diseases-conditions/heart-murmurs/symptoms-causes/syc-20373171>>. Acesso em: 14 mar. 2018.

MAYO CLINIC. **Heart disease**. 2018b. Disponível em: <<https://www.mayoclinic.org/diseases-conditions/heart-disease/symptoms-causes/syc-20353118>>. Acesso em: 14 mar. 2018.

MENEZES, Nilo Ney Coutinho. **Introdução à programação com Python**: algoritmos e lógica de programação para iniciantes. 2. ed. São Paulo: Novatec,

2014.

MILETTO, E. M. *et al.* Introdução à computação musical. In: CONGRESSO BRASILEIRO DE CIÊNCIA DA COMPUTAÇÃO, 4., 2004, [S. l.]. **Anais...** [S.l.]: Univali, 2004. ed. esp. 39. Disponível em: <[http://www.evandromanara.net/files/UFRGS/Mini-cursoIntrodCM\\_CBC2004.pdf](http://www.evandromanara.net/files/UFRGS/Mini-cursoIntrodCM_CBC2004.pdf)>. Acesso em: 09 maio 2018.

MOHRMAN, David E; HELLER, Lois J. **Fisiología cardiovascular**. 6. ed. Cidade do Mexico: Mc Graw-Hill Interamericana, 2007. (Lange de fisiología). Disponível em: <[goo.gl/iDVE7j](http://goo.gl/iDVE7j)>. Acesso em: 03 abr. 2018.

MONARD, M. C.; BARANAUSKAS, J. A.. Conceitos sobre aprendizado de máquina. In: REZENDE, S. O. (Ed.). **Sistemas inteligentes: fundamentos e aplicações**. Barueri, SP: Manole, 2003. p. 89-114. Disponível em: <<http://dcm.ffclrp.usp.br/~augusto/publications/2003-sistemas-inteligentes-cap4.pdf>>. Acesso em: 12 abr. 2018.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. **Curiosity overview**. 2017. Disponível em: <[https://www.nasa.gov/mission\\_pages/msl/overview/index.html](https://www.nasa.gov/mission_pages/msl/overview/index.html)>. Acesso em: 25 maio 2018.

NUMPY. 2018. Disponível em: <<http://www.numpy.org/>>. Acesso em: 15 jun. 2018.

OBERMEYER, Ziad; EMANUEL, Ezekiel J. Predicting the Future — Big Data, Machine Learning, and Clinical Medicine. **Department of health and human services - USA**. v. 13, 375 ed., p. 1216 -1219. Disponível em: <<https://goo.gl/QDQLX3>>. Acesso em: 25 nov. 2018.

O'GARA, Patrick; LOSCALZO, Joseph. Cardiopatia valvar. In: LONGO, Dan L. *et al.* **Medicina interna de Harrison**. 18. ed. Porto Alegre: AMGH, 2013a. v. 2, cap. 237.

O'GARA, Patrick; LOSCALZO, Joseph. Exame físico do sistema cardiovascular. In: LONGO, Dan L. *et al.* **Medicina interna de Harrison**. 18. ed. Porto Alegre: AMGH, 2013b. v. 2, cap. 227.

PADILHA, Victor Alexandre; CARVALHO, André Carlos Ponce de Leon Ferreira de. **Mineração de dados em Python**. [S.l.]: ICMC-USP, 2017. Disponível em: <[goo.gl/MRuab2](http://goo.gl/MRuab2)>. Acesso em: 16 jun. 2018.

PANDAS. 2018. Disponível em: <<https://pandas.pydata.org/>>. Acesso em: 01 jun. 2018.

PATEL, Patel; Rao, Y. Srinivas. Speech recognition using hmm with mfcc: an

analysis using frequency spectral decomposition technique. **Signal & Image Processing : An International Journal(SIPIJ)**, v. 1, n. 2, dez. 2010. Disponível em: <<https://pdfs.semanticscholar.org/15d9/33c1b3893297d9a51134ed6f0a21c571d273.pdf>>. Acesso em: 11 maio 2018.

PELECH, Andrew N. The physiology of cardiac auscultation. **Pediatr. Clin. N. Am.**, v. 51, n. 6, p. 1515–1535, dec. 2004. Disponível em: <[goo.gl/wxRufT](http://goo.gl/wxRufT)>. Acesso em: 14 mar. 2018.

PISSARDINI, Rodrigo de Sousa; MIN WEI, Daniel Chin; FONSECA JUNIOR, Edvaldo Simões da. Veículos autônomos: conceitos, histórico e estado-da-arte. In: CONGRESSO DE ENSINO E PESQUISA EM TRANSPORTES, 27., 2013, Belém do Pará. **Anais...** Belém do Pará, 2013.. Disponível em: <<https://goo.gl/6CPXxe>>. Acesso em: 26 maio 2018.

PRINA, Bruno Zucuni; TRENTIN, Romario. GMC: geração de matriz de confusão a partir de uma classificação digital de imagem do ArcGIS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. 2015, João Pessoa, PB. **Anais...** João Pessoa, PB, 2015. Disponível em: <<http://www.dsr.inpe.br/sbsr2015/files/p0031.pdf>>. Acesso em: 01 out. 2018.

PYPI: PyQt5. 2018. Disponível em: <<https://pypi.org/project/PyQt5/>>. Acesso em: 25 out. 2018.

RABINER, Lawrence R. A tutorial on hidden markov models and selected applications in speech recognition. **Proceedings of the IEE**, v. 77, n. 2, feb. 1989. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=18626>>. Acesso em: 02 mar. 2018.

RASCHKA, Sebastian. **Python machine learning**. Birmingham: Packt Publishing, 2016. Disponível em: <<https://books.google.com.br/books?hl=pt-BR&lr=&id=GOVOCwAAQBAJ&oi=fnd&pg=PP1&dq=Why+you+should+use+Python+for+machine+learning&ots=NcaDKcRP0l&sig=q-QibrrR9q6P-EcLYE01-4WL47A#v=onepage&q&f=false>>. Acesso em: 01 out. 2018.

RIVERBANK: Computing limited. 2018. Disponível em: <<https://www.riverbankcomputing.com/software/pyqt/intro>>. Acesso em: 25 out. 2018.

RUSSEL, Stuart J. **Artificial intelligence: a modern approach**. New Jersey: Pearson, 2003. Disponível em: <<https://goo.gl/oFmbHC>>. Acesso em: 10 abr. 2018.

SAYÃO, Luís Fernando. Padrões para bibliotecas digitais abertas e interoperáveis. **Enc. Bibli: R. Eletr. Bibliotecon. Ci. Inf.**, Florianópolis, n. esp., p. 18-47, 1. sem. 2007. Disponível em: <<http://www.redalyc.org/html/147/14720411003/>>. Acesso em: 10 maio 2018.

SCHAUL, Tom *et al.* **PyBrain**: the Python machine learning library. 2010. Disponível em: <<http://pybrain.org/pages/home>>. Acesso em: 01 jun. 2018.

SCIKIT-LEARN: machine learning in Python. 2018. Disponível em: <<http://scikit-learn.org/stable/>>. Acesso em: 01 jun. 2018.

SCIPY: PyLab. [201-?]. Disponível em: <<https://scipy.github.io/old-wiki/pages/PyLab>>. Acesso em: 25 out. 2018.

SIQUEIRA, Alessandra de S. E. *et al.* Análise do impacto econômico das doenças cardiovasculares nos últimos cinco anos no Brasil. **Arq Bras Cardiol**. v. 109, n. 01, p. 39-46, marc. 2017. Disponível em: <<http://draalessandrasiqueira.com.br/media/analisedeimpacto.pdf>>. Acesso em: 26 mar. 2018.

UNIVERSITY OF WAIKATO. Machine Learning Group. **Attribute-relation file format (ARFF)**. 2008. Disponível em: <<https://www.cs.waikato.ac.nz/ml/weka/arff.html>>. Acesso em: 09 ago. 2017.

UNIVERSITY OF WAIKATO. Machine Learning Group. **Weka 3**: data mining software in Java. [201-?]. Disponível em: <<https://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 09 ago. 2017.

VASCONCELOS, Livia Maria Rocha de; CARVALHO, Cedric Luiz de. **Aplicação de regras de associação para mineração de dados na web**. 2004. Disponível em: <[http://www.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF\\_004-04.pdf](http://www.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_004-04.pdf)>. Acesso em: 25 maio 2018.

WORLD HEALTH ORGANIZATION. **Cardiovascular diseases (CVDs)**. 2017a. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs317/en/>>. Acesso em: 26 fev. 2018.

WORLD HEALTH ORGANIZATION. **The top 10 causes of death**. 2017b. Disponível em: <<http://www.who.int/en/news-room/fact-sheets/detail/the-top-10-causes-of-death>>. Acesso em: 04 abr. 2018.

ZAMBON, Lucas Santos. A segurança do paciente e o diagnóstico. In: SOUSA, Paulo (Org.). **Segurança do paciente**: conhecendo os riscos nas organizações de saúde. Rio de Janeiro: EaD/ENSP, 2014. p. 203-225.

ZHONG, Lisha *et al.* Heart murmur recognition based on hidden markov model. **Journal of Signal and Information Processing**, v. 4, p. 140-144, maio 2013. Disponível em: <<https://goo.gl/jo7BBk>>. Acesso em: 02 maio 2018.

## GLOSSÁRIO

Angina de peito: Dor no peito.

Arritmia: Frequência cardíaca anormal, seja acelerada ou muito lenta.

Ascite: Acúmulo de fluidos dentro da cavidade abdominal.

Caqueixa: Grau extremo de enfraquecimento.

Cianose periférica: Descoloração azulada nos pés e mãos.

Dispneia: Falta de ar.

Edema: Inchaço causado pelo excesso de líquidos nos tecidos do corpo.

Extrassístole: Batimento cardíaco extra.

Hepatomegalia: Aumento anormal do volume do fígado.

Ortopneia: Dificuldade de respiração.

Palpitação: Batimento irregular do coração.

Síncope: Perda dos sentidos devido à deficiência de irrigação sanguínea no encéfalo (desmaio).

Taquicardia sinusal: Frequência cardíaca é superior a 100 batimentos por minuto.