

# Detecção de Cardiopatias pela análise de sons da auscultação através de redes neurais artificiais

Camila Acácio de Paiva<sup>1</sup>, Ricardo Costa P Santos<sup>2</sup>, Silvana Facerolli<sup>3</sup>

<sup>1</sup>Instituto Federal de Educação Ciência e Tecnologia do Sudeste de Minas – Campus Juiz de Fora – MG – Brasil

<sup>2</sup>Orientador - Instituto Federal de Educação Ciência e Tecnologia do Sudeste de Minas – Campus Juiz de Fora – MG – Brasil

<sup>3</sup>Coorientador(a) - Instituto Federal de Educação Ciência e Tecnologia do Sudeste de Minas – Campus Juiz de Fora. – MG - Brasil

{camila.acacio.paiva@gmail.com, ricardo.cpsantos@gmail.com,  
silvana.faceroli@ifsudestemg.edu.br}

**Abstract.** *Determination of heart condition by heart auscultation is a difficult task and requires special training of medical staff. Computerized techniques suggest objective and more accurate results in a fast and easy manner. Hence, in this study it is aimed to perform computer-aided heart sound analysis to give support to medical doctors in decision-making. In this study, a method is presented for the classification of heart sounds. Artificial neural networks were used to classify three types of sounds, normal heart, premature beat and murmur sound. A comparison with previous studies was made and we had good results were obtained.*

**Resumo.** *Determinação da condição do coração por ausculta cardíaca é uma tarefa difícil e requer treinamento especial da equipe médica. Técnicas computadorizadas sugerem resultados objetivos e mais precisos, de forma fácil e rápida. Assim, no presente estudo pretende-se realizar uma análise dos sons auxiliado por computador para dar suporte aos médicos na tomada de decisão. Neste estudo, um método é apresentado para a classificação dos sons. Redes neurais artificiais foram utilizadas para a classificação de três tipos de sons, normais, sopro cardíaco e bulha cardíaca. Uma comparação com estudos já realizados foi feita e tivemos bons resultados foram obtidos.*

## 1. Introdução

A bioinformática é o estudo da aplicação de técnicas computacionais e matemáticas na área da medicina ou biologia. De acordo com (LUSCOMBE et al., 2001) bioinformática é uma gerenciamento de sistemas de informação para a biologia e possui várias aplicações. O livro (ROBERT L. MCCARTHY, KENNETH W. SCHAFERMEYER, 2011) definiu como a pesquisa, desenvolvimento e aplicação de ferramentas computacionais e abordagens de expansão do uso de dados de saúde, ou biológicos, incluindo aqueles para adquirir, armazenar, organizar, arquivar, analisar e visualizar esses dados. Sendo assim, a bioinformática foi desenvolvida com o intuito de auxiliar os

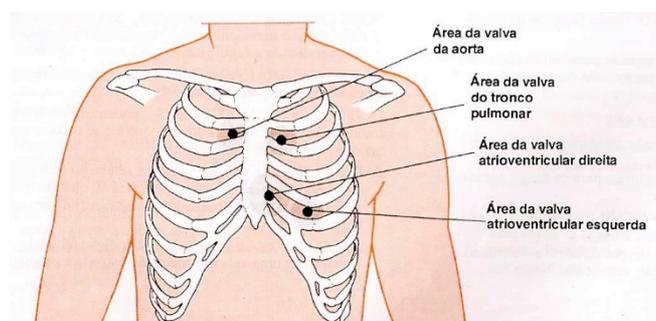
profissionais da área de saúde a coletarem e processarem os dados mais rapidamente, com maior detalhamento e possibilitando o desenvolvimento de novas soluções.

Dentro do segmento da bioinformática, é possível utilizar diversas técnicas para auxílio nas inferências e tomadas de decisões como, por exemplo, o método de Redes Neurais Artificiais, que é uma técnica computacional inspirada na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência. As redes neurais podem ser aplicadas em diversas áreas para executar a tarefa de reconhecimento de padrões.

O objetivo dessa pesquisa é desenvolver um classificador de doenças cardíacas pela análise dos sons da auscultação. Para isso, as redes neurais artificiais foram utilizadas para que um processo de classificação que tem por objetivo separar os sons “normais” dos sons identificados como “patológicos” possa ser concretizada. Os três tipos de classes utilizadas na pesquisa foram: normal, sopro cardíaco e extra-sístole. Os dois últimos tipos de sons citados estão associados com disfunções cardíacas.

A ausculta cardíaca é parte da medicina, dentro de um contexto chamado “semiologia”, de fundamental importância, que possibilita o estudo dos sons gerados pelos ciclos cardíacos. Através dela, é possível realizar o diagnóstico, e muitas vezes, avaliar a gravidade da enfermidade apresentada pelo paciente. No exame, que faz uso de um aparelho denominado como estetoscópio, deve-se certificar de que médico e paciente estejam em um local apropriado, sem barulho, e em uma posição confortável para ambos, a fim de garantir a veracidade do exame (DA; APOIO, 2001).

As áreas do tórax onde se pode colocar um estetoscópio a fim de se detectar com precisão os sons cardíacos às diferentes valvas, estão indicados na Figura 1.



**Figura 1- Áreas da parede torácicas**

**Fonte Spence (1991)**

A identificação de uma disfunção cardíaca pode ser de extrema importância no auxílio ao diagnóstico, visto que, de acordo com o IBGE, as doenças cardiovasculares são a principal causa de morte no Brasil. Em 2013, 4,2% (6,1 milhões) de pessoas de 18 anos ou mais de idade tiveram diagnóstico médico de alguma doença do coração. De acordo com os indicadores Sócio demográficos e de Saúde no Brasil, realizado pelo IBGE em 2009, em 1950, as doenças cardiovasculares eram causa de 12% das mortes e, atualmente, representam mais de 40%. Em menos de 40 anos, o Brasil passou de um perfil de mortalidade típico de uma população jovem para um desenho caracterizado por enfermidades complexas e mais onerosas, próprias das faixas etárias mais avançadas (IBGE, 2009).

Conforme dados citados anteriormente, a utilização de tecnologias e métodos científicos é de interesse para a coletividade. A criação destes dispositivos ou sistemas e sua disponibilização aos agentes de saúde e aos médicos, quando idealizados para servirem como ferramentas auxiliares na identificação de patologias, podem acelerar o diagnóstico, facilitando principalmente a triagem e encaminhamentos aos exames de maior complexidade. Sendo assim, a principal motivação deste trabalho é apresentar um modelo de classificação de sons cardíacos que possibilite auxiliar os médicos nos diagnósticos das disfunções.

## **2. Fisiologia do Músculo Cardíaco**

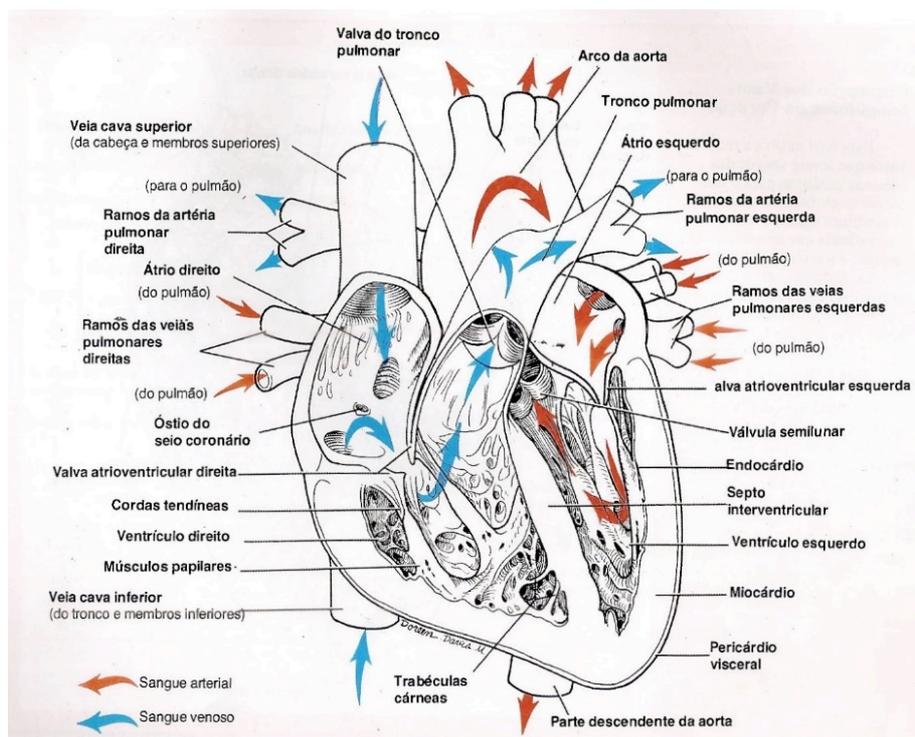
### **2.1. Anatomia do Coração**

De acordo com (SPENCE, 1991), o coração é formado principalmente por músculo cardíaco, ancorado a um esqueleto fibroso. Esse consiste em quatro câmaras: átrio direito, átrio esquerdo, ventrículo direito e ventrículo esquerdo. Os átrios são menores, e se localizam na região superior do coração. Os ventrículos são maiores, e constituem no principal volume do órgão. Os átrios são separados pelo septo interarterial e, os ventrículos, pelo septo interventricular.

Vários vasos sanguíneos de grande dimensão entram e saem do coração pela sua base e margem superior. Dentre eles estão: veia cava superior e veia cava inferior, que trazem o sangue venoso do corpo para o átrio direito; artéria tronco pulmonar, que se divide em artérias pulmonares direita e esquerda, que levam o sangue do ventrículo direito para os pulmões; veias pulmonares que trazem o sangue de pulmão para o átrio esquerdo; e artéria aorta, que leva o sangue do ventrículo esquerdo para o corpo (SPENCE, 1991).

Existem quatro grupos de válvulas que direcionam o fluxo sanguíneo através das câmaras cardíacas. As valvas atrioventriculares estão localizadas entre os átrios e os ventrículos. A valva localizada no lado direito, denominada valva tricúspide, e a localizada no lado esquerdo, denominada valva mitral, são forçadas para cima e se fecham quando a pressão dos ventrículos aumenta, impedindo assim que o sangue retorne aos átrios quando da contração ventricular. As valvas das artérias, tronco pulmonar e da aorta, impedem o retorno do sangue aos ventrículos (SPENCE, 1991).

A Figura 2 apresenta a estrutura do coração com um corte frontal.



**Figura 2 - Estrutura do Coração**

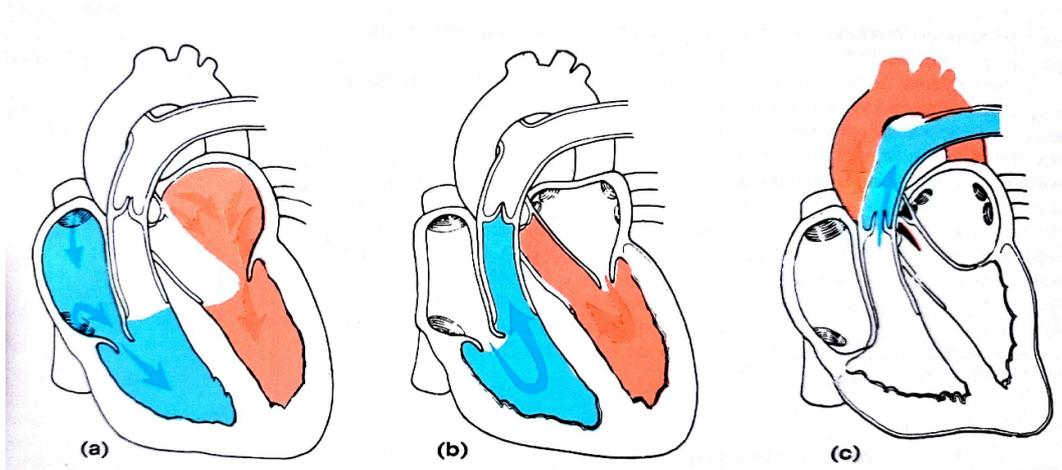
**Fonte: Spence (1991)**

## 2.2. Circulação através do coração

Devido a separação das câmaras cardíacas do lado direito com as do lado esquerdo através dos septos, o coração funciona como uma bomba dupla. Cada uma possui uma câmara de recebimento (átrio) e propulsão (ventrículo). Do átrio direito, o sangue passa para o ventrículo direito, que impulsiona para o tronco pulmonar e artérias pulmonares, até a rede de capilares dos pulmões. Nos pulmões o sangue deixa o gás carbônico e recebe oxigênio (SPENCE, 1991).

A bomba do lado esquerdo recebe o sangue recentemente oxigenado pelos pulmões e envia para o corpo. O lado direito e o lado esquerdo trabalham em uníssono. Quando dos batimentos cardíacos, ambos os átrios se contraem, e em seguida, ambos os ventrículos.

A contração simultânea de ambos os átrios comprime mais sangue para o interior dos ventrículos. Posteriormente, a contração simultânea de ambos os ventrículos fecha as valvas atrioventriculares e força o sangue a passar pelas valvas das artérias e penetrar no interior do tronco pulmonar e no interior da aorta. A Figura 3, mostra o fluxo sanguíneo através do coração (SPENCE, 1991).



**Figura 3 - Circulação do Sangue através do Coração**

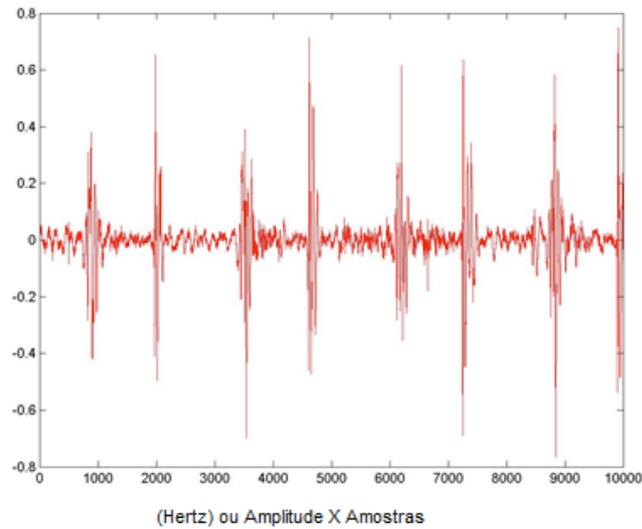
**Fonte - Spence (1991)**

### **2.3. Algumas Doenças Cardíacas**

Para a pesquisa utilizou-se, além dos sons cardíacos “normais”, sons do tipo “sopro cardíaco” e “extra-sístole”. Abaixo uma breve explicação e exemplificação de cada um deles.

Segundo SPENCE, Alexander P.: Anatomia Humana Básica. 2. ed. São Paulo: Editora Manole Ltda., 1991. p.304.

*“Existem dois sons cardíacos principais que normalmente ocorrem quando o sangue se move pelo interior do coração, durante um ciclo cardíaco. Esses sons são melhores descritos como “lub-dup”. O primeiro deles (o “lub”) está associado com o fechamento das valvas atrioventriculares no início da contração ventricular (sístole). Ele ocorre devido a vibração das valvas atrioventriculares esticadas imediatamente após o seu fechamento e também à vibração das paredes do coração e grandes vasos da base. O segundo som (“dup”) está associado com o fechamento das valvas das artérias (aorta e tronco pulmonar) quando os ventrículos começam a se descontraír (diástole). Esse som se deve a vibrações das válvulas semilunares esticadas e a vibrações da parede da artéria aorta, do tronco pulmonar, e da parede dos ventrículos (em parte).”*

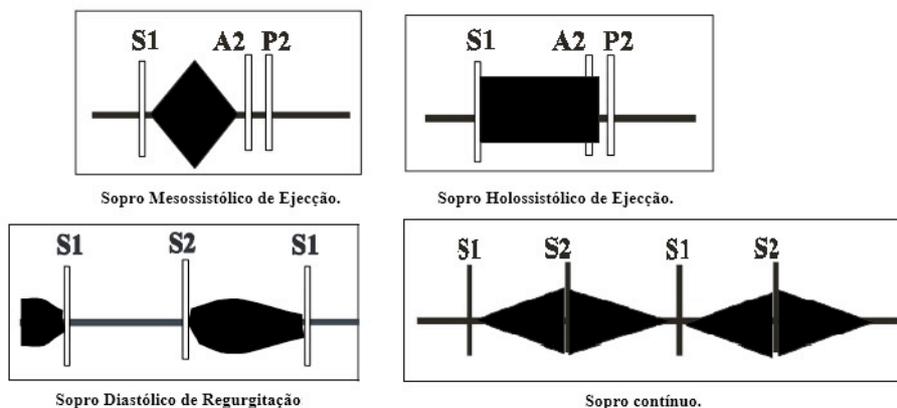


**Figura 4 - Gráfico do som cardíaco do tipo Normal**

**Fonte – Simulação no Matlab**

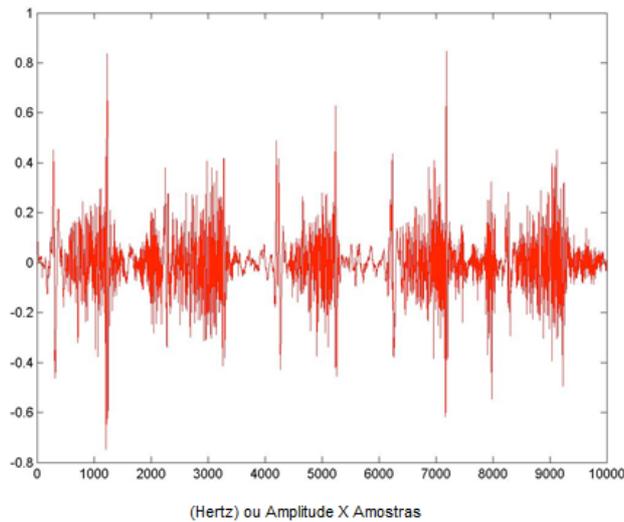
Sopros cardíacos caracterizam-se como lesões oro-valvulares ou quando há o fluxo normal através de uma área pequena ou irregular. A insuficiência valvular caracteriza-se como um distúrbio no fechamento das válvulas, permitindo um retorno do sangue; esse refluxo é que caracteriza o sopro. A intensidade de um sopro é diretamente proporcional à velocidade do fluxo sanguíneo, que por sua vez depende da pressão.

De acordo com (DA; APOIO, 2001), os sopros cardíacos são divididos em quatro categorias, são elas: Sopros Mesossistólicos de Ejeção, Sopros Holossistólicos de Regurgitação, Sopros Diastólicos de Regurgitação e Sopros Contínuos. A Figura 5 exemplifica cada um deles, porém, vale salientar que, nesse trabalho, a classificação dos sons ocorre pela presença ou ausência do sopro, ou seja, não ocorre a classificação das categorias.



**Figura 5 - Tipos de sopros cardíacos**

**Fonte - Auscultação Cardíaca (DA; APOIO, 2001)**

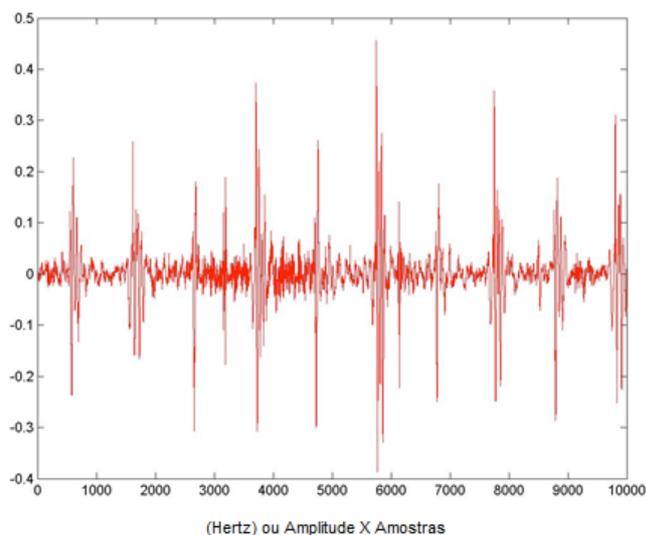


**Figura 6 - Gráfico do som cardíaco do tipo Sopro Cardíaco**

**Fonte - Simulação no Matlab**

Extra-sístole é uma doença cardíaca na qual o ventrículo se contrai de maneira prematura. O batimento cardíaco é causado por sinais elétricos, o pulso elétrico causa a contração dos ventrículos que bombeiam sangue rico em oxigênio para todo o corpo. Uma contração ventricular prematura é o batimento cardíaco muito rápido originários dos ventrículos e perturba o ritmo cardíaco normal.

Existem três tipos de extra-sístole, são elas: extra-sístole bigeminada, extra-sístole tri geminada e extra-sístole quadrigêmea. Assim como nos sopros cardíacos, esse trabalho, visa detectar a presença ou ausência da extra-sístole, sem a distinção de tipo.



**Figura 7 - Gráfico do som cardíaco do tipo Extra-Sístole**

**Fonte - Simulação no Matlab**

### 3. Redes Neurais artificiais

As Redes Neurais Artificiais (RNA) são modelos matemáticos que se assemelham às estruturas neurais biológicas e que têm a capacidade computacional adquirida por meio de aprendizado e generalização (LUIZ; SOARES). (PAULO et al.) define uma rede neural como uma técnica matemática realizada, dentro de um fluxograma sequencial de cálculo projetado, para obter resultados a partir de entradas de dados. As RNAs são capazes de resolver problemas tais como: classificação, aproximação, otimização, predição e categorização.

A característica mais importante das Redes Neurais é a capacidade de aprender a partir de exemplos, e de gradualmente melhorar seu desempenho de inferência. O aprendizado está associado à capacidade de que a rede tem de adaptar seus parâmetros, como consequência da com o meio externo. Através dos processos iterativos as RNAs melhoram seu desempenho gradativamente.

Pesquisas anteriores, (ÖLMEZ; DOKUR, 2003) e (DOKUR; ÖLMEZ, 2008), nos mostram que existem quatro razões para utilizamos Redes Neurais Artificiais para a classificação, a primeira delas, os pesos representativos da solução são encontrados por treinamento iterativo. Segunda, as RNAs possuem uma estrutura simples e de fácil implementação. Terceira, pode facilmente mapear classes complexas e, por fim, propriedade de generalização das RNAs produz resultados adequados para vetores de entrada que não estão introduzidos no conjunto de treino.

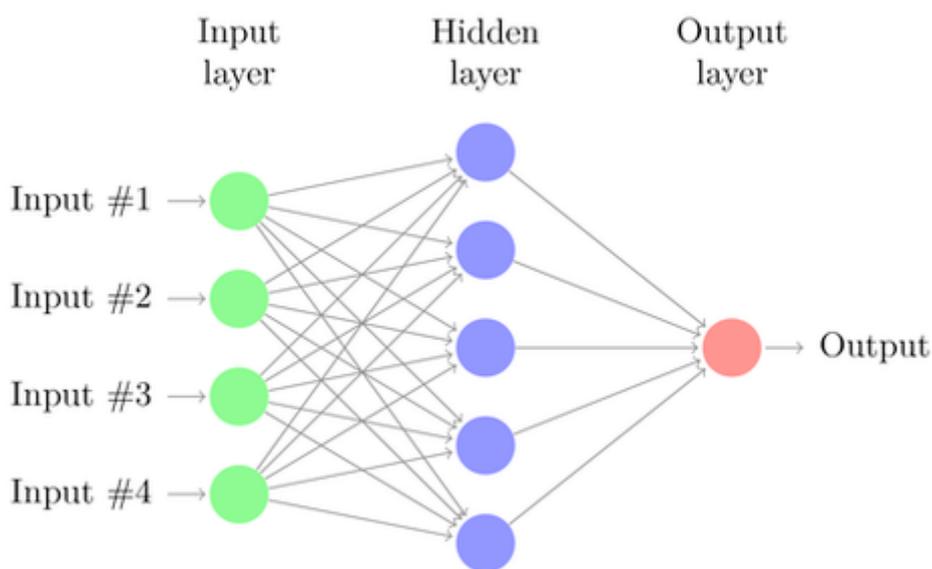


Figura 8– Diagrama esquemático da arquitetura da RNA

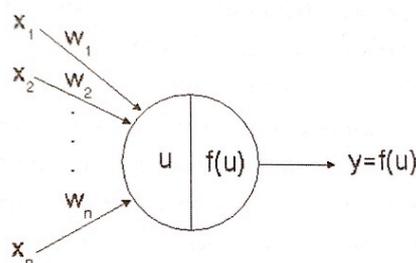
Fonte: (SATVIK BERI, 2013)

A Figura 8 mostra a arquitetura de uma Rede Neural Artificial, na qual há uma camada de entrada, responsável por receber os “inputs”, que são, nada mais nada menos, os dados coletados para o trabalho. O vetor de entrada se propaga pela rede, através de uma ou mais camadas intermediárias, que são responsáveis pelo processamento dos dados. Todos os neurônios estão interligados entre si, definindo as sinapses neuronais, sendo dimensionadas através dos pesos. Na prática, pesos mais altos, definem sinapses

mais importantes para o processo de inferência e pesos mais baixos, caracterizam sinapses menos relevantes. A camada de saída representa a resposta decorrente de todas as interações da rede. Considerando que, durante o processo de treinamento de uma RNA, normalmente, utiliza-se dados que possuem saídas conhecidas, o erro na inferência de uma rede pode ser calculado, proporcionando uma referência para que ajustes possam ser feitos nas próximas iterações.

Descrevendo, em termos matemáticos uma Rede Neural, de acordo com (REZENDE, 2003), “O processamento das informações em RNAs é realizado por meio de estruturas neurais artificiais em que o armazenamento e o processamento da informação são realizados de maneira paralela e distribuída por elementos processadores relativamente simples”, chamados de neurônios artificiais. De acordo com o diagrama da Figura 9, as entradas do neurônio correspondem ao vetor de entrada  $X = [x_1, x_2, \dots, x_n]^T$  de dimensão  $n$ .

De acordo com a Figura 9, cada uma das entradas  $x_i$  será ponderada por um peso correspondente  $w_i$  na entrada dos neurônios. O somatório do produto de  $x_i$  com  $w_i$  é chamada de saída linear  $u$  ( $u = \sum_i w_i x_i$ ). A saída  $y$  do neurônio, chamada de saída ativada, é obtida pela aplicação de uma função  $f$  à saída linear  $u$ , indicada por  $y = f(u)$ . A função  $f$  é chamada de função de ativação e pode assumir várias formas, geralmente não lineares e terão como função principal a limitação da escala de resposta obtida em  $u$  (REZENDE, 2003).



**Figura 9– Visão esquemática de um neurônio**

**Fonte – Rezende, O. S. et al, Sistemas Inteligentes (2003)**

O processo de aprendizagem da rede se faz através da propagação do erro em um conjunto de testes no sentido inverso ao do fluxo usual dos dados na rede (Backpropagation), que utiliza o gradiente da função de ativação escolhida, e que tem como objetivo o ajuste dos pesos sinápticos para que, nas próximas propagações, erros menores possam ser obtidos.

A etapa de treinamento será repetida até que o erro obtido atinja um limite mínimo. Esse limite é um dos parâmetros que deverão ser configurados antes do início do processo de treinamento, aonde o desenvolvedor da rede identifica qual a tolerância de erro a ser admitido no treinamento. Outros parâmetros básicos a serem definidos são: quantidade de camadas intermediárias, quantidade de neurônios na(s) camada(s) intermediária(s), funções de ativação, dentre outros.

Combinando diversos neurônios, como o da Figura 9, podemos formar o que é chamada de rede de neurônios, ou simplesmente uma rede neural, como mostrado na Figura 8. Cada neurônio, individualmente, executa funções simples, mas, a estrutura matemática de uma RNA permite com que ela consiga modelar problemas com uma alta complexidade.

Segundo REZENDE, O. S. et al: Sistemas Inteligentes. 1. ed. São Paulo: Editora Manole Ltda., 2003. p.145.

*“Uma das características mais importantes das RNAs é que as mesmas são aproximadores universais de função multivariáveis contínuas (Cybenko 1989). Em outras palavras, qualquer problema de funções contínuas pode ser resolvido através das RNAs, independentemente do número de variáveis envolvidas. O número de entradas e saídas depende da dimensionalidade dos dados, enquanto o número de neurônios nas camadas intermediárias depende da complexidade do problema. Quanto maior o número de neurônios nas camadas intermediárias, mais complexas serão as funções mapeadas com a RNA. A escolha da estrutura da rede neural determina diretamente a qualidade do modelo obtido. Mesmo para uma estrutura definida, pode haver um número grande ou mesmo infinito de soluções possíveis, o que resulta no grande desafio no desenvolvimento de modelos neurais: selecionar a melhor entre inúmeras soluções possíveis.”*

A fim de garantir que o processo de treinamento obtenha a acurácia necessária ao que foi dimensionado como sendo o ideal, nem todo o conjunto de dados é utilizado nesse processo. Parte dos dados podem formar um conjunto de validação e/ou um conjunto de testes, a fim de atingir um objetivo simples de testar o processo de treinamento com dados “novos”, que não foram utilizados no processo ajuste da rede.

#### **4. Materiais e Métodos**

Os artigos mais citados na área são dos autores *Tamer Ölmez e Zümray Dokur*. Seus estudos são baseados em métodos que utilizam Transformadas *Wavelets* aplicadas em dois períodos dos sons cardíacos, primeiro e segundo batimento. Análises são realizadas para extrair características de cada um desses segmentos. Após esses passos, vetores são formados utilizando *wavelet detail coefficients* em níveis de decomposição. Após, as melhores características dos elementos são processadas com as RNAs. Nesses trabalhos foram utilizados vários tipos de redes, tais como: *Grow and learn (GAL) network*, *linear vector quantization (LVQ) network* and *Kohonen's SOM network*. Os resultados obtidos foram ótimos e ficaram em torno de 99% de acerto.

Em decorrência dos estudos anteriores, optou-se por utilizar sons na íntegra, sem a utilização das transformadas *Wavelets* e sem a decomposição dos mesmos. Em relação a topologia da rede neural e a quantidade de neurônios, diante de testes preliminares, a função tangente hiperbólica se mostrou mais competente e os melhores resultados foram com vinte e quatro neurônios.

##### **4.1. Repositório de Dados**

Nesse trabalho utilizou-se um repositório de dados composto por um total de duzentos e cinquenta e nove sons divididos em três classes: 161 sons cardíacos do tipo normal, 46 sons do tipo sopro cardíaco e 52 sons do tipo extra-sístole. Sendo que, os dois últimos

tipos de sons citados, são sons que se associam com as disfunções cardíacas já descritas anteriormente.

O repositório de dados utilizado foi retirado do site (PETER BENTLEY, GLENN NORDEHN, MIGUEL COIMBRA, SHIE MANNOR, 2012) que tem como proposta lançar um desafio de classificação de sons cardíacos, em um concurso de classificações. Os dados foram obtidos a partir de um ensaio clínico em hospitais, utilizando o estetoscópio DigiScope digital. De acordo com o site, os dados foram reunidos em situações do mundo real e contém ruídos de todos os tipos imagináveis de fundo. Os arquivos de áudio são de comprimentos variados, entre 1 segundo e 30 segundos, alguns foram cortados para reduzir o ruído excessivo e fornecer o fragmento saliente do som.

A base original continha sons de vários tamanhos, muitos deles com poucos segundos e quantidades diferentes de amostras para as diferentes classes do problema. A fim de uniformizar os arquivos disponíveis na base de dados, optou-se por dividir os mesmos em vetores de 10000 pontos, que representam aproximadamente 3 segundos de áudio, procedendo, não só com a uniformização, indispensável para o processo de classificação a ser utilizado, quanto para o aumento da quantidade de exemplares, contribuindo, assim, com a melhora do processo de treinamento da rede.

Após a etapa de pré-processamento, foi conseguido um aumento significativo na quantidade de amostras. Após essa etapa, a base de dados ficou da seguinte forma: 213 sons normais, 228 sons do tipo sopro cardíaco e 124 sons do tipo extra-sístole. Para os testes, como padrão, 80% da quantidade total das amostras foram utilizadas para o treinamento da rede, 10% foram destinadas à validação e os outros 10% foram destinadas ao teste. Os dados dos conjuntos de testes e validação não entram no processo de treinamento. Sendo assim, a resposta obtida para esses elementos, são mais legítimas, traduzindo em uma importância maior na análise dos resultados.

Sabendo que, diferenças significativas de quantidades de exemplares das classes podem influenciar na qualidade do treinamento da rede neural, uma segunda base foi gerada através da equalização dessas quantidades de exemplares em cada classe, eliminando, de forma aleatória, elementos das classes mais numerosas. Sendo assim, obteve-se uma base com 372 sons, sendo 124 para cada classe.

Considerando que o objetivo maior é identificar uma doença cardíaca, optou-se por juntar as duas enfermidades em um mesmo grupo, a fim de obter um terceiro esquema para inferência e, por consequência, analisar possíveis vantagens serem alcançadas com essa variação no processo. Consequentemente, a base gerada contém 372 sons, sendo 124 para normais e 248 para disfunções cardíacas.

## **4.2. Toolbox Matlab**

O Matlab é um programa interativo que se destina a cálculos numéricos e gráficos científicos. Seu ponto forte está na manipulação e cálculos matriciais. Além disso, muitas funções especializadas já estão internamente implementadas dentro do software. Com a ferramenta, pode-se analisar os dados, desenvolver algoritmos e criar modelos e aplicações.

Nesse trabalho foi utilizado um Toolbox denominado como: Neural Network Start, ou NNStart. Esta ferramenta contém várias funções, dentre elas temos: Séries Temporais, Regressões, Clusterizações ou Análises de Agrupamentos e, por fim, o Módulo de

Reconhecimento de Padrões ou Classificação Supervisionada, alvo da pesquisa em questão.

Para que ocorra o processamento de forma ideal, foi preciso apenas de configurar as entradas (inputs), no caso desse trabalho, os sons cardíacos devidamente pré-processados; os “targets”, que são as classificações de cada um dos inputs; a quantidade de neurônios a ser utilizada na camada intermediária e, por fim, a função de ativação que melhor se adapta ao problema em questão, desenvolvendo combinações diante desses parâmetros.

### 4.3. Excel

Para tabular os resultados obtidos utilizou-se o editor de planilhas. Vários testes foram realizados, primeiramente com a variação do número de neurônios, dentro da quantidade estabelecida, mais uma gama de testes foi realizada para obtermos os melhores resultados. Com o objetivo de ajudar na organização e manter todos os dados juntos, criou-se uma tabela para melhor ter controle.

## 5. Resultados

Dentre os vários testes realizados modificando, apenas, a quantidade de neurônios da rede, o melhor resultado de classificação obtido foi com 24 neurônios, representado pela Figura 11.

Output Class	1	2	3	
1	176 31.2%	33 5.8%	32 5.7%	73.0% 27.0%
2	30 5.3%	190 33.6%	21 3.7%	78.8% 21.2%
3	7 1.2%	5 0.9%	71 12.6%	85.5% 14.5%
	82.6% 17.4%	83.3% 16.7%	57.3% 42.7%	77.3% 22.7%
	1	2	3	
	Target Class			

Figura 10 - Resultados obtidos para três classes

Fonte - Simulação no Matlab

A qual, cada coluna da matriz corresponde aos resultados obtidos para os tipos de som utilizado, sendo assim, a coluna de número um, corresponde aos resultados obtidos para os sons do tipo normal, ou seja, 176 amostras foram classificadas como normais, 30 amostras classificadas como sopro cardíaco e 7 amostras como extra-sístole. Resultando em um total de 82,6% de acerto. A coluna de número dois, corresponde aos resultados

sons do tipo sopro cardíaco e, a coluna de número três os resultados para extra-sístole. A diagonal da matriz mostra os percentuais de acerto para cada tipo e o percentual geral. Alcançou-se um percentual de 77,3% de acerto, sendo que, nessa matriz, obtivemos um total de 11,5% de falsos negativos, ou seja, 11,5% das amostras dos sons foram classificados de forma incorreta. Algo que poderia ser futuramente melhorado.

Com o objetivo de equilibrar as bases e observar se a quantidade de amostras influência nos resultados, outra classe foi criada e testada. Nesses teste as quantidades de amostras foram igualadas para cada tipo, sendo assim, ficou-se com cento e vinte quatro amostras para sons normais, sopro cardíaco e extra-sístole. Com a mesma quantidade de neurônios anterior, 24, obtivemos o melhor resultado, Figura 12. Sendo que, 9,7% dos sons foram classificados como falsos negativos

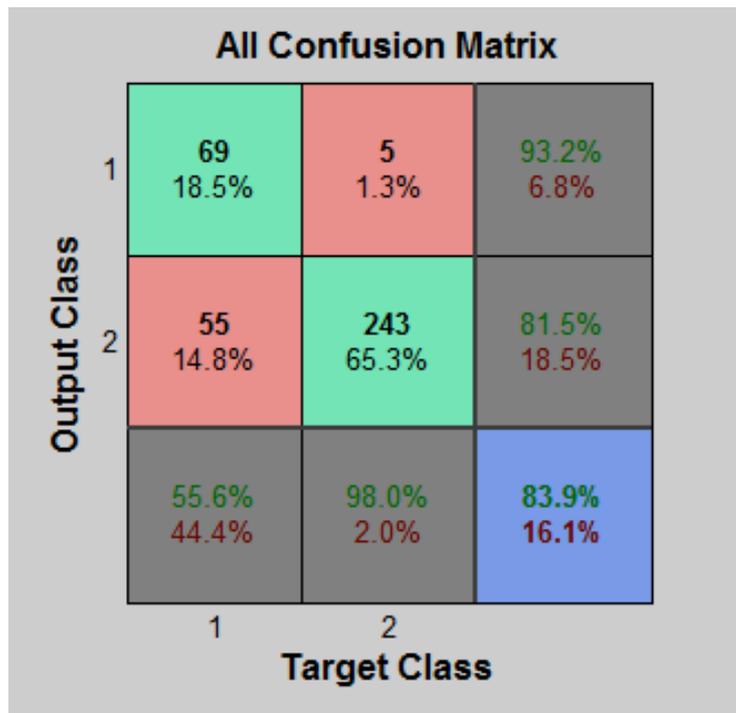
**All Confusion Matrix**

<b>Output Class</b>	1	118 31.7%	11 3.0%	25 6.7%	76.6% 23.4%
	2	3 0.8%	105 28.2%	8 2.2%	90.5% 9.5%
	3	3 0.8%	8 2.2%	91 24.5%	89.2% 10.8%
			95.2% 4.8%	84.7% 15.3%	73.4% 26.6%
		1	2	3	<b>Target Class</b>

**Figura 11 - Resultados obtidos para três classes balanceadas**

**Fonte - Simulação no Matlab**

Para finalizar, um último teste foi realizado, visando analisar se a classificação entre apenas duas classes, normais ou com alguma disfunção, poderia nos mostrar resultados melhores do que os anteriores. Para isso, manteve-se a quantidade de sons do segundo teste, cento e vinte quatro sons para cada classe, porém, 124 normais e 248 com disfunção. O melhor resultado obtido ocorreu em uma rede de 24 neurônios, com 83,9% de acerto, como mostra a Figura 13. Vale salientar que, neste teste obteve-se 1,3% de falsos negativos.



**Figura 12 - Resultados obtidos para duas classes**

**Fonte - Simulação no Matlab**

## 6. Conclusão

Nesse trabalho, definiu-se como principal objetivo criar uma rede neural visando classificar sons de ausculta cardíaca conforme o seu tipo: normal, extra-sístoles e sopro cardíaco, que pode, futuramente, auxiliar os médicos nos diagnósticos das disfunções.

Realizando uma análise dos resultados obtidos, chegou-se à seguinte conclusão: o primeiro resultado, Figura 11, não obteve a melhor classificação. Seus falsos negativos totalizaram um percentual de 11,5%, um número considerado elevado. Algo que vale salientar em relação a esse teste é a ocorrência de bases desequilibradas, sabendo que, diferenças significativas de quantidades de exemplos podem influenciar na qualidade do treinamento da rede neural.

Para o segundo teste, Figura 12, obtivemos uma melhora no percentual de acerto. Os falsos negativos somaram um percentual de 9,7%, indicando uma melhora no processo de treinamento.

Para o terceiro caso, onde as duas doenças cardíacas foram juntas, como mostra o resultado da Figura 13, o percentual de acerto foi de 83,9%, porém a quantidade de falsos negativos foi diminuída para 1,3%.

Considerando que a proposta desse trabalho é desenvolver uma ferramenta de auxílio na detecção de cardiopatias, a presença de altas quantidades de falsos negativos é prejudicial para o sistema, uma vez que uma pessoa não pode ser identificada sem problemas cardíacos, uma vez que, a mesma, é portadora de uma cardiopatia. Sendo assim, em função dos falsos negativos, o terceiro caso foi identificado como sendo o mais adequado para que seja utilizado.

Fazendo uma análise com os trabalhos já realizados na área, os resultados aqui obtidos não foram os melhores, visto que os percentuais de acerto dos principais trabalhos ficaram por volta de 99. Além disso, foram utilizados diversos tipos de cardiopatias. Vale salientar também, que a transformada Wavelet esteve presente em diversos trabalhos.

Para trabalhos futuros sugere-se um estudo com maior abrangência em relação às disfunções cardíacas, a fim de poder elevar os níveis de diagnósticos.

A Transformada Wavelet apresenta excelentes propriedades e tem sido aplicada em várias áreas, como por exemplo na compressão de imagens, ou para a remoção de ruídos. Para trabalhos futuros, essa ferramenta pode ser utilizada com o intuito de remover os ruídos dos sons, assim, mais testes poderão ser realizados, buscando uma melhora na classificação e uma diminuição dos falsos negativos.

## 7. Referências

- BRANDÃO, A. D. S.; BRANDÃO, A. D. S. Redes neurais artificiais para a classificação de sons vocálicos. *Neural Networks*.
- DA, R. E. N. E.; APOIO, T. DE. Faculdade de Medicina da Universidade do Porto Serviço de Fisiologia. , 2001.
- DOKUR, Z.; ÖLMEZ, T. Heart sound classification using wavelet transform and incremental self-organizing map. *Digital Signal Processing*, v. 18, p. 951–959, 2008.
- IBGE. Indicadores sociodemográficos e de saúde no Brasil. 2009.
- LUIZ, P.; SOARES, B. Aplicação de Redes Neurais Artificiais em Conjunto com o Método Vetorial da Propagação de Feixes na Análise de um Acoplador Direcional Baseado em Fibra Ótica. , p. 58–72.
- LUSCOMBE, N. M.; GREENBAUM, D.; GERSTEIN, M. What is bioinformatics? An introduction and overview. *Yearbook of Medical Informatics*, p. 83–100, 2001.
- ÖLMEZ, T.; DOKUR, Z. Classification of heart sounds using an artificial neural network. *Pattern Recognition Letters*, v. 24, p. 617–629, 2003. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865502002817>>. .
- PAULO, J.; RAMOS, S.; CASE, B. Redes Neurais Artificiais Na Classificação De Frutos: Ce- Fruit Sorting Using Artificial Neural Networks: , p. 1–7.
- PETER BENTLEY, GLENN NORDEHN, MIGUEL COIMBRA, SHIE MANNOR, R. G. Classifying Heart Sounds Challenge. Disponível em: <<http://www.peterjbentley.com/heartchallenge/>>. Acesso em: 1/8/2014.
- REZENDE, S. O. *Sistemas Inteligentes: Fundamentos e Aplicações*. 2003.
- ROBERT L. MCCARTHY, KENNETH W. SCHAFFERMEYER, K. S. P. *Introduction to Health Care Delivery*. 2011.
- SATVIK BERI, M. DUDE. Could someone explain how to create an artificial neural network in a simple and concise? Disponível em: <<http://www.quora.com/Could-someone-explain-how-to-create-an-artificial-neural-network-in-a-simple-and-concise-way-that-doesnt-require-a-PhD-in-mathematics>>. .
- SPENCE, E. M. *Anatomia Humana Básica*. 1991.

