

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE INFORMÁTICA
CURSO DE ENGENHARIA DE COMPUTAÇÃO**

FERNANDA GAPSKI MOREIRA

**ESTUDO SOBRE A ESTIMATIVA DA PRESSÃO ARTERIAL
UTILIZANDO DADOS DE FOTOPLETISMOGRAFIA DA BASE
MIMIC E UMA REDE NEURAL ARTIFICIAL**

TRABALHO DE CONCLUSÃO DE CURSO

PATO BRANCO
2018

FERNANDA GAPSKI MOREIRA

**ESTUDO SOBRE A ESTIMATIVA DA PRESSÃO ARTERIAL
UTILIZANDO DADOS DE FOTOPLETISMOGRAFIA DA BASE MIMIC
E UMA REDE NEURAL ARTIFICIAL**

Trabalho de Conclusão de Curso como requisito parcial à obtenção do título de Bacharel em Engenharia de Computação, do Departamento Acadêmico de Informática da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Fábio Luiz Bertotti
Coorientador: Prof. Dr. Dalcimar Casanova

PATO BRANCO

2018



TERMO DE APROVAÇÃO

Às 13 horas e 50 minutos do dia 28 de junho de 2018, na sala V107, da Universidade Tecnológica Federal do Paraná, Câmpus Pato Branco, reuniu-se a banca examinadora composta pelos professores Fabio Luiz Bertotti (orientador), Dalcimar Casanova (coorientador), Kathya Silvia Collazos Linares e Ricardo Bernardi para avaliar o trabalho de conclusão de curso com o título **Estudo Sobre a Estimativa da Pressão Arterial Utilizando Dados de Fotopletismografia da Base Mimic e uma Rede Neural Artificial**, da aluna **Fernanda Gapski Moreira**, matrícula RA 01260758, do curso de Engenharia de Computação. Após a apresentação a candidata foi arguida pela banca examinadora. Em seguida foi realizada a deliberação pela banca examinadora que considerou o trabalho aprovado.

Fabio Luiz Bertotti
Orientador (UTFPR)

Dalcimar Casanova
Coorientador (UTFPR)

Kathya Silvia Collazos Linares
(UTFPR)

Ricardo Bernardi
(UTFPR)

Profa. Beatriz Terezinha Borsoi
Coordenador de TCC

Prof. Pablo Gauterio Cavalcanti
Coordenador do Curso de
Engenharia de Computação

A Folha de Aprovação assinada encontra-se na Coordenação do Curso.

“A coragem não é ausência do medo; é a persistência apesar do medo.”

Autor desconhecido

RESUMO

MOREIRA, Fernanda Gapski. Estudo sobre a estimativa da pressão arterial utilizando dados de fotopleletismografia da base MIMIC e uma rede neural artificial. 2018. 57f. Trabalho de Conclusão de Curso de bacharelado em Engenharia de Computação – Universidade Tecnológica Federal do Paraná. Pato Branco, 2018.

Este trabalho aborda o desenvolvimento de uma rede neural artificial com o propósito de estimar de forma contínua o valor da pressão arterial. São discutidos os tipos de métodos atualmente utilizados para a medição da pressão arterial realizada em clínicas, hospitais e residências. Também são apontados os prós e contras de cada método de medição contínua, considerando que este trabalho propõe a medição contínua da pressão arterial. O presente trabalho propõe o uso de sinais de fotopleletismografia (PPG) para estimar a pressão arterial a partir de uma rede neural artificial (RNA) que utilizará como parâmetro a transformada rápida de Fourier aplicada ao sinal de PPG obtido a partir do banco de dados MIMIC-III junto com a pressão arterial. Foram utilizados 108 ciclos para o treinamento da RNA e 45 para os testes. Os resultados obtidos da rede neural são analisados estatisticamente em conjunto com os valores reais de pressão arterial para avaliar se este método pode ser desenvolvido para uma possível substituição dos métodos atualmente utilizados. O projeto mostra que, com uma melhora na filtragem e separação dos dados de entrada, é possível aferir valores da pressão arterial de uma pessoa utilizando uma RNA.

Palavras-chave: Fotopleletismografia. Transformada Rápida de Fourier. Pressão arterial. Rede Neural Artificial.

ABSTRACT

MOREIRA, Fernanda Gapski. Study about blood pressure estimation using MIMIC's base photoplethysmography data and artificial neural network. 2018. 57f. Trabalho de Conclusão de Curso de bacharelado em Engenharia de Computação – Universidade Tecnológica Federal do Paraná. Pato Branco, 2018.

This paper addresses the development of an artificial neural network with the purpose of estimating continuously blood pressure value. The types of methods currently used for measuring blood pressure in clinics, hospitals and residences are discussed. Afterwards, considering that this paper proposes a continuous measuring method, the pros and cons of each current continuous measuring method is discussed in details. This proposes the use of photoplethysmography (PPG) signals to estimate blood pressure from an artificial neural network (ANN). It will receive the fast Fourier transform of the PPG signal obtained from the MIMIC database -III and give out a value of blood pressure. For ANN's training and testing there were used 108 and 45 blocks, respectively. At the end, the results obtained from the neural network will be analyzed statistically in conjunction with the actual blood pressure values to validate whether this method could be developed for a possible replacement of the currently used methods. The analyses showed that, with an improvement in the filtering and separation of the input data, an ANN can measure a person's blood pressure.

Keywords: Photoplethysmogram. Fast Fourier Transform. Blood pressure. Artificial Neural Network.

LISTA DE FIGURAS

Figura 1 - Sistema circulatório simplificado e a porcentagem da distribuição de sangue.....	14
Figura 2 - Exemplo de válvulas aórticas mecânicas.....	21
Figura 3 - Aparelho de Pressão Digital de Pulso.....	21
Figura 4 - Esfigmomanômetro (1) e estetoscópio (2).....	22
Figura 5 - Técnicas existentes, os tipos de medição e os métodos que as utilizam.....	24
Figura 6 - Nomeação das transformadas para cada tipo de sinal.....	25
Figura 7 - Diferença na quantidade de interações para a DFT e a FFT.....	28
Figura 8 - Modelo não linear de um neurônio.....	31
Figura 9 - Modelo não linear de um neurônio considerando o bias como entrada.....	32
Figura 10 - Funções de ativação: (a) Função limiar, (b) Função linear por partes, (c) Função sigmoide.....	33
Figura 11 - Representação das direções dos fluxos de sinais básicos em um MLP.....	36
Figura 12 - Resumo do funcionamento da retropropagação.....	37
Figura 13 - Diagrama em blocos das etapas do projeto.....	40
Figura 14 - Gráfico de um dos intervalos de PPG utilizados.....	43
Figura 15 - Trecho de código para separação dos dados.....	44
Figura 16 - Sinal PPG após aplicada a FFT, módulos das componentes.....	45
Figura 17 - Trecho do código para a aplicação da FFT no sinal PPG no grupo de treinamento.....	46
Figura 18 - Trecho do código de definição da RNA.....	46
Figura 19 - Trecho do código para o cálculo dos erros entre os resultados obtidos e os valores reais.....	47
Figura 20 - Representação gráfica dos valores reais X aferidos.....	47

LISTA DE SIGLAS E ABREVIATURAS

PPG	Photoplethysmogram (Fotopleletismograma)
RNA	Rede Neural Artificial
ECG	Electrocardiogram Sensor (Sensor de eletrocardiograma)
FFT	Fast Fourier Transform (Transformada Rápida de Fourier)
FT	Fourier Transform (Transformada de Fourier)
DFT	Discrete Fourier Transform (Transformada discreta de Fourier)

SUMÁRIO

1 INTRODUÇÃO.....	8
1.1 OBJETIVOS	10
1.1.1 Objetivo Geral.....	10
1.1.2 Objetivos Específicos.....	10
1.2 JUSTIFICATIVA	11
1.3 ESTRUTURA DO TRABALHO	12
2 REFERENCIAL TEÓRICO.....	13
2.1 SISTEMA CARDIOVASCULAR	13
2.1.1 Coração	14
2.1.2 Circulação Sistêmica	16
2.1.3 Alterações na pressão arterial	17
2.1.4 Monitoramento da Pressão Arterial	18
2.2 ENGENHARIA Biomédica	18
2.2.1 Instrumentação Biomédica	20
2.2.2 Métodos e Instrumentos para Monitoramento da Pressão Arterial	21
2.3 TRANSFORMADA DE FOURIER	25
2.3.1 Transformada Discreta de Fourier	26
2.3.2 Transformada Rápida de Fourier	27
2.4 Inteligencia artificial	28
2.4.1 Redes Neurais Artificiais	29
3 MATERIAIS E MÉTODOS.....	39
3.1 MATERIAIS	40
3.2 MÉTODOS	40
3.2.1 Obtenção de Informações da Base de Dados MIMIC.....	40
3.2.2 Transformada de Fourier do PPG.....	41
3.2.3 Desenvolvimento e treinamento de uma RNA.....	42
4 RESULTADOS.....	43
5 CONCLUSÃO.....	49
REFERÊNCIAS.....	50

1 INTRODUÇÃO

As doenças cardiovasculares são responsáveis por grande parte das mortes no mundo, sendo que a doença isquêmica do coração e o derrame, que tem a hipertensão como uma de suas causas, estão como as que mais matam no mundo. Além disso, segundo a OMS (Organização Mundial da Saúde), das 56,4 milhões de mortes mundiais em 2015, essas duas doenças foram responsáveis por 15 milhões, o equivalente a aproximadamente 26% das mortes mundiais (WORLD HEALTH ORGANIZATION – WHO, 2015).

A hipertensão é uma doença crônica que tem como característica a elevada pressão sanguínea nas artérias ou Pressão Arterial (PA), o que pode levar a consequências graves ao portador, como derrames cerebrais, infartos e insuficiência renal, caso não seja adequadamente tratada. No Brasil, a hipertensão é responsável por cerca de 40% dos infartos, 80% dos derrames e 25% dos casos de insuficiência renal terminal (SOCIEDADE..., 2017). Ainda, segundo a Sociedade Brasileira de Hipertensão (2017), no Brasil, cerca de 25% da população adulta brasileira é hipertensa, chegando a passar de 50% para pessoas com idade acima dos 60 anos.

A hipertensão pode ser chamada de doença “silenciosa” pelo fato de não demonstrar sintomas ao hipertenso. Apesar disso, é importante esclarecer que a hipertensão pode não causar sintomas mas traz consequências complicadas para o paciente. Assim a única maneira de acompanhar a PA de um paciente é através do monitoramento deste parâmetro, pois apenas assim é possível saber qual tratamento deve ser indicado. É necessário ainda que, para pacientes hipertensos, esse acompanhamento não seja realizado apenas em consultas periódicas, mas diariamente em casa.

Para realizar o monitoramento da PA é importante utilizar um método adequado. No passado, essa medição não era prática de fazer, pois os aparelhos eram complexos de usar e não muito precisos, o que tornava o tratamento e o conhecimento de doenças cardiovasculares mais complicados. Com o desenvolvimento da tecnologia, os aparelhos foram ficando mais precisos e práticos de operar. Assim, foi possível aprimorar os conhecimentos da medicina em relação a essas doenças cardiovasculares e melhorar os seus respectivos tratamentos.

Atualmente, o método mais utilizado para aferir a pressão arterial é o oscilométrico usando um dispositivo conhecido como esfigmomanômetro. Este instrumento possui uma bolsa inflável protegida por um tecido inelástico, que está conectada a um manômetro, o qual medirá a pressão de ar dentro da bolsa, e a uma bomba de ar responsável por encher a bolsa. Porém, esse aparelho sozinho não é capaz de medir a pressão, uma vez que o médico que

realizará esta medição deve utilizá-lo junto com um estetoscópio. O médico prenderá o esfigmomanômetro no braço do paciente, que deve estar sentado com o braço apoiado e relaxado, posicionando o estetoscópio sobre a artéria braquial e proceder para encher a bolsa. Com o estetoscópio o médico ouvirá os sons de Korotkoff¹ e, com isso, identificará as pressões sistólica e diastólica (KOHLMANN, 2011).

Hoje em dia não existem muitos métodos que realizem a medição contínua da pressão arterial e os que existem não conseguem realizar esta por um longo período de tempo. Os métodos mais conhecidos são o MAPA (Monitorização Ambulatorial da Pressão Arterial) pelo método oscilométrico e pelo Holter. Os dois métodos possuem um mini-gravador digital preso na cintura do paciente que registrará a pressão durante um período determinado, a diferença é que no oscilométrico a pressão é aferida por uma braçadeira presa no braço e no Holter ela é aferida por meio de eletrodos posicionados no peito (SOUZA, 2016). Ambos os métodos causam um certo desconforto no paciente e não podem ser realizados por períodos longos. Assim pesquisas vem sendo realizadas para a descoberta de novos métodos mais confortáveis e que funcionem por longos períodos de tempo. O método pesquisado para a realização deste projeto utiliza a fotoplestígrafia (PPG). Este parâmetro é adquirido através de sensores, que são compostos de um LED e um fotodiodo, posicionados em um anel no dedo do paciente.

Como foi anteriormente comentado, os métodos atuais para a medição contínua da pressão arterial não são muito confortáveis ou práticos. Por exemplo, o esfigmomanômetro necessita que a pessoa fique com o braço imóvel, apoiado em uma superfície plana, para que não ocorram erros na medição. O MAPA oscilométrico infla em intervalos de 20 a 30 minutos, fazendo com que o paciente interrompa o que está fazendo para não interferir no resultado obtido. Enquanto que a técnica do PPG poderá ser usada por um intervalo mais longo além de não interferir nas atividades do dia a dia do paciente, visto que não é necessária nenhuma alteração nos sensores para a realização da medição, que pode ser feita continuamente. Existem também um método chamado MRPA (Monitorização Residencial da Pressão Arterial), porém este não é um monitoramento contínuo da PA, visto que o paciente irá, utilizando um aparelho preferencialmente do método oscilatório, medir sua PA quatro vezes ao dia.

Já existem aparelhos para a obtenção de sinais PPG que apresentam pequenos erros e desvios no resultado da medição, conforme abordado no trabalho de Chen *et al.* (2013).

¹ Os sons são produzidos pela passagem turbilhonar do sangue através da artéria estenosada pela compressão do manguito (SOCIEDADE BRASILEIRA DE HIPERTENSÃO, 2017)

Apesar da obtenção dos sinais ser adequada, a análise destes sinais ainda não traz um resultado muito preciso, ou seja, com desvios maiores do que o desejado para a pressão arterial estimada. Logo, a implementação de um sistema para a obtenção desses sinais não será o foco deste trabalho. Assim, o projeto em questão tem como proposta implementar uma rede neural artificial (RNA) que estimará a pressão arterial baseado em parâmetros retirados da transformada de Fourier do sinal PPG de forma a diminuir esses desvios. Essa minimização dos desvios ocorre devido a RNA conseguir analisar o relacionamento não linear entre a PA e o sinal PPG, ela possui uma fase de treinamento utilizando dados reais para se calibrar de forma a encontrar o melhor resultado que sua implementação permite.

O sinal PPG utilizado é um sinal periódico que acompanha o ciclo cardíaco, sendo que o sistema a ser implementado analisará esse sinal período a período. Essa análise será feita por uma RNA, a qual será inicialmente treinada. O sistema irá, primeiramente, aplicar a transformada rápida de Fourier em um período do sinal PPG, que será obtido do banco de dados público *Multiparameter Intelligent Monitoring in Intensive Clinical* (MIMIC), a qual retornará parâmetros que serão usados pela RNA para estimar a pressão arterial. Como o propósito do trabalho é diminuir os desvios encontrados nos sistemas atuais de medição da pressão arterial pelo método do PPG, ao fim da implementação e testes do sistema, uma análise estatística será realizada, comparando-se com os valores reais da PA. A partir disso, estes resultados serão comparados com outros apresentados na literatura que empregam o mesmo método.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Desenvolver uma rede neural para estimar a pressão arterial, utilizando como dados de entrada os descritores de Fourier para analisar fotoplestimogramas (PPG), provenientes do banco de dados MIMIC.

1.1.2 Objetivos Específicos

- Estudo e treinamento para o uso do banco de dados MIMIC;
- Aplicar a transformada rápida de Fourier utilizando a linguagem Python;

- Elaborar um algoritmo para identificar e extrair a forma de onda do sinal de fotopleletismografia do banco de dados MIMIC;
- Configurar e treinar uma rede neural artificial, utilizando a função da biblioteca *sklearn* do Python, para aferir a pressão arterial.
- Fazer uma análise estatística entre as pressões estimadas pela RNA e a extraída do banco de dados MIMIC.

1.2 JUSTIFICATIVA

O método auscultatório depende da escuta dos sons de Korotkoff. Desta forma, é possível que os sistemas automatizados que usam este método possam ter resultados errôneos caso tenha muito som ambiente no local onde a pessoa está medindo sua pressão e também pelos sons emitidos caso a pessoa movimente o braço enquanto o aparelho esteja trabalhando (SOLTANE et al, 2004). Desta forma, um método que não dependesse do silêncio do ambiente e da imobilidade do paciente seria preferível, tal método poderia ser o da fotopleletismografia, que foi o pesquisado para a realização deste projeto. Esse método não exige que o paciente fique numa posição determinada, não sofre interferências por sons do ambiente e, mesmo utilizando uma técnica luminosa, não possui seus resultados alterados pela mudança da iluminação do ambiente, visto que o sensor está protegido da claridade externa.

Entretando, pelas pesquisas realizadas, ainda não foi implementado um aparelho que consiga medir a pressão continuamente utilizando o método da fotopleletismografia em conjunto com uma rede neural, pela dificuldade em aferir resultados com erros aceitáveis pelos padrões americanos da Associação para o Avanço da Instrumentação Médica (*Association for the Advancement of Medical Instrumentation*²). Esses padrões definem o que é ou não aceitável para os equipamentos médicos serem liberados para a venda no mercado. Nos artigos pesquisados foram encontrados alguns métodos diferentes que utilizam o sinal PPG para estimar a pressão arterial, sendo eles o de McCombie *et al.* (2006), que utiliza o PWV (pulse wave velocity) para estimar a pressão arterial, o de Teng e Zhang (2003), que utiliza um modelo linear baseado em características temporais retiradas do sinal PPG e os que utilizam uma rede neural para analisar parâmetros retirados do sinal, como o de Kurylyak e Lamomaca (2013) que alimentam a rede neural com 21 parâmetros retiradas da forma de onda do sinal PPG, e o de Xing e Sun (2016) que alimentam sua rede com parâmetros retirados da

²O programa de padrões da AAMI é composto por mais de 100 comitês técnicos e grupos de trabalho que produzem padrões, práticas recomendadas e relatórios de informações técnicas para dispositivos médicos.

Transformada de Fourier do sinal.

Esses métodos foram estudados para tentar melhorar a medição contínua da pressão arterial, porém possuem erros nos resultados, os quais foram calculados através do módulo da diferença entre os valores obtido pelo método e o valor de referência retirado do banco de dados ou do paciente em questão, fora do padrão aceito, sendo este padrão $5 \text{ mmHg} \pm 8 \text{ mmHg}$ (ASSOCIATION FOR THE ADVANCEMENT OF MEDICAL INSTRUMENTATION – AAMI, 1987). No Quadro 1 observa-se os erros obtidos em cada um dos trabalhos citados anteriormente. Como foi possível observar o método com menores desvios foi o utilizado por Xing e Sun (2016). Desta forma, este será o utilizado como base deste projeto. No artigo de Kurylyak e Lamonaca (2013) também é comentado sobre o método de regressão linear para a estimação da pressão, só que os erros obtidos neste método são ainda maiores que os dos outros métodos, visto que são $9,80 \pm 8,09 \text{ mmHg}$ para a pressão sistólica e $5,88 \pm 5,11 \text{ mmHg}$ para a pressão diastólica.

Pressão Arterial	Métodos pesquisados		
	Teng e Zhang (2003)	Kurylyak e Lamonaca (2013)	Xing e Sun (2016)
Sistólica	$0,21 \pm 7,52 \text{ mmHg}$	$3,80 \pm 3,46 \text{ mmHg}$	$-1,67 \pm 2,46 \text{ mmHg}$
Diastólica	$0,02 \pm 4,39 \text{ mmHg}$	$2,21 \pm 2,09 \text{ mmHg}$	$-1,29 \pm 1,71 \text{ mmHg}$

Quadro 1 - Comparação dos erros obtidos em cada um dos métodos

Fonte: Autoria própria.

1.3 ESTRUTURA DO TRABALHO

O Capítulo 2 apresenta a fundamentação teórica para a melhor compreensão do projeto a ser implementado. Será apresentado o funcionamento do sistema circulatório e do coração, as consequências de um aumento na pressão sanguínea para o organismo e porque se deve monitorá-la. Em seguida será mostrada a situação em que a engenharia biomédica se encontra em relação aos dispositivos para monitoramento da pressão sanguínea. Então será indicada uma explicação básica da Transformada de Fourier que será utilizada no projeto, assim como os dois tipos desta. Por fim, serão expostos os tipos de classificação utilizados nas redes neurais e como realizar o treinamento desta rede. O Capítulo 3 exibirá quais técnicas e programas serão utilizados na implementação do projeto.

2 REFERENCIAL TEÓRICO

Esta seção vai apresentar uma explicação breve sobre o sistema cardiovascular, como funciona, porque ocorrem as variações na pressão arterial e um histórico das técnicas e dispositivos utilizados no monitoramento dela. Também será comentado sobre os métodos que servirão como base para a implementação e elaboração do sistema deste projeto, assim como exemplificar e justificar o uso de RNA em outros artigos que servem como base para o desenvolvimento deste trabalho.

2.1 SISTEMA CARDIOVASCULAR

O sistema cardiovascular tem como função transportar o sangue pelo organismo, realizando a circulação sanguínea. A função desta circulação é assistir nas necessidades dos tecidos corporais, isto é, transportar nutrientes e oxigênio para os órgãos, realizar a retirada de resíduos, transportar hormônios de uma parte à outra do corpo e manter um ambiente adequado nos fluidos dos tecidos para uma funcionalidade ótima e a sobrevivência das células. O sistema é formado pelo coração, pelos vasos sanguíneos, as veias e artérias, e pelo sangue. A Figura 1 mostra uma versão simplificada da organização do sistema cardiovascular e a distribuição, em porcentagem, do sangue no sistema. A circulação sistêmica é composta pela circulação das artérias, arteríolas e capilares e das veias, vênulas e seios venosos.

O sangue é quem transporta os nutrientes, oxigênio, resíduos e hormônios pelos vasos sanguíneos. Este fluido é formado por glóbulos vermelhos, que são os responsáveis por levar oxigênio e retirar o gás carbônico das células, glóbulos brancos, que defendem o organismo de ameaças, como vírus e bactérias, plaquetas, que são encarregadas por coagular o sangue em regiões de corte, e o líquido extracelular, que é onde essas células estão localizadas. Os vasos sanguíneos são as vias por onde o sangue circula no corpo, sendo que as veias transportam o sangue em direção ao coração, enquanto que as artérias conduzem o sangue para fora do coração, ou seja, em direção aos órgãos. Por último, o coração é responsável, basicamente, por bombear o sangue através desses vasos (HALL e GUYTON, 2016).

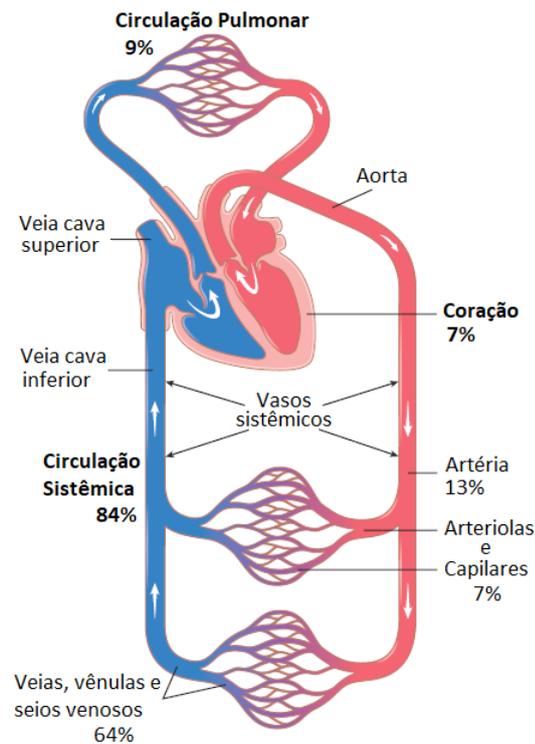


Figura 1 - Sistema circulatório simplificado e a porcentagem da distribuição de sangue
Fonte: Adaptado de Hall e Guyton, 2016

Na seção seguinte será abordado o funcionamento do coração, assim como indicar a definição de pressão arterial e explicar como os movimentos cardíacos afetam essa pressão.

2.1.1 Coração

O coração pode ser considerado como duas bombas, sendo que cada uma é composta de um átrio e de um ventrículo, responsáveis por duas circulações distintas, conhecidas como circulação pulmonar e sistêmica. O lado direito do coração é incumbido da circulação pulmonar, enquanto que o esquerdo da circulação sistêmica. Posteriormente, será comentado sobre cada tipo de circulação. Independente dos lados o átrio é uma bomba mais fraca, que recebe o sangue através das veias, responsável por movê-lo para o ventrículo, que, por sua vez, expelle o sangue através das artérias, e, conseqüentemente, deve possuir uma força maior. A diferença nas forças de contração do átrio e do ventrículo se deve ao fato de que o coração não é formado apenas por um único músculo cardíaco, mas por três tipos distintos: o músculo atrial, o músculo ventricular e fibras musculares condutivas e excitatórias (HALL e GUYTON, 2016).

Os músculos cardíacos contraem de maneira parecida com os músculos esqueléticos, porém suas contrações são muito mais longas. Já as fibras do coração contraem pouco, uma vez que são responsáveis por fornecer um sistema excitatório que controla os batimentos rítmicos do coração. O músculo cardíaco é um sincício³ de muitas células cardíacas tão interconectadas que, quando uma célula é excitada, o potencial de ação se espalha rapidamente entre elas. É possível afirmar que o coração é formado por dois sincícios, o atrial e o ventricular, que constituem, respectivamente, as paredes dos dois átrios e dos dois ventrículos. Essa divisão no músculo do coração permite que o átrio contraia um curto período de tempo antes do ventrículo, cuja ação é muito importante para a eficiência do bombeamento do coração (HALL e GUYTON, 2016).

Além dos músculos cardíacos o coração possui válvulas, chamadas de atrioventriculares, que impedem que o sangue siga pelo caminho errado, ou seja, que o sangue volte para o átrio em vez de seguir para as artérias. Essas válvulas permanecem abertas durante a diástole, permitindo o enchimento dos ventrículos, para então, durante a sístole, se fecharem impedindo que o sangue seja bombeado novamente para os átrios. Também existem válvulas no início das artérias pulmonar e aorta que funcionam no mesmo princípio das atrioventriculares mas impedindo o caminho inverso, ou seja, impedem que o sangue volte das artérias para os ventrículos (HALL e GUYTON, 2016).

São denominados de ciclo cardíaco os eventos ocorrentes entre o início de um batimento até o início do próximo. O ciclo é formado por uma fase de relaxamento, ou diástole, onde o coração enche de sangue, e uma fase de contração, ou sístole, em que o coração empurra o sangue para o resto do corpo. A duração total deste ciclo é recíproca à frequência cardíaca, ou seja, com uma frequência de 80 batimentos/min a duração do ciclo cardíaco é de 1/80 min/batimento. Quando a frequência cardíaca aumenta, o ciclo cardíaco diminui, mas a diástole e a sístole não diminuem proporcionalmente. A porcentagem de perda do tempo da diástole é maior do que a da sístole, para uma frequência cardíaca próxima de 72 bpm a sístole utiliza em torno de 40% do ciclo, enquanto que para uma frequência três vezes maior ela utiliza 65% do ciclo total. Isto demonstra que para frequências maiores, o coração acaba lançando menos sangue para o corpo em cada ciclo, pois o coração não permanece relaxado por tempo suficiente para o total enchimento das câmaras cardíacas (HALL e GUYTON, 2016).

³Conjunto de células que se fundem, perdendo parte de sua membrana, e formando uma única massa citoplasmática multinucleada (HALL e GUYTON, 2016).

2.1.2 Circulação Sistêmica

Como foi anteriormente comentado existem duas circulações ocorrendo no corpo: a circulação pulmonar e a circulação sistêmica. A primeira leva o sangue do coração até os pulmões e de volta ao coração. O sangue sai do ventrículo esquerdo para as artérias pulmonares, percorre o caminho até os pulmões e volta pelas veias pulmonares para o átrio esquerdo. Apesar desta ser muito importante para o funcionamento do corpo humano, a circulação pulmonar não é utilizada para verificar a pressão sanguínea de uma pessoa, e, portanto, não é relevante para este projeto. Já a circulação sistêmica, também conhecida como grande circulação, representa o conjunto de veias e artérias que percorrem todo o corpo, alimentando todos os órgãos com o sangue (HALL e GUYTON, 2016). Para entender o que causa a pressão sanguínea é necessário primeiramente assimilar o conceito de fluxo sanguíneo.

O fluxo sanguíneo não é igual para todos os órgãos do corpo, visto que a necessidade de oxigênio e nutrientes de cada órgão é variável e dependente da atividade deste. O corpo consegue controlar o fluxo que manda para cada órgão, mas neste projeto não é importante saber de que maneira o corpo realiza este controle, o que importa são as alterações que ocorrem no sistema circulatório, mais precisamente nos vasos sanguíneos, para o controle deste fluxo. O coração não consegue aumentar o débito cardíaco⁴ mais do que quatro à sete vezes dos seus níveis normais, assim, para ajudar no ajuste do fluxo local, os vasos podem dilatar e contrair (HALL e GUYTON, 2016).

Existe também um controle da pressão arterial, que é independente dos controles do fluxo e do débito cardíacos. O sistema circulatório é provido de um sistema extensivo para o controle da pressão arterial. Por exemplo, se a pressão cair significativamente abaixo do nível normal uma série de mudanças circulatórias elevam a pressão de volta ao normal. Os sinais nervosos responsáveis por isso causam um aumento na força do bombeamento cardíaco, uma contração dos grandes reservatórios venosos, fornecendo mais sangue ao coração, e uma vasoconstrição generalizada das arteríolas de muitos tecidos, aumentando assim o volume de sangue nas grandes artérias (HALL e GUYTON, 2016).

⁴O volume de sangue sendo bombeado pelo coração em um minuto.

2.1.3 Alterações na pressão arterial

É importante notar que se não existisse a PA o sangue não percorreria os vasos, visto que esse movimento ocorre devido à diferença de pressão entre pontos dos vasos. O problema ocorre no momento em que a PA está fora da normalidade, seja na hipotensão ou na hipertensão. Existem diversos fatores que influenciam a PA, seja de modo a aumentá-la ou diminuí-la. Alguns destes fatores podem vir de alguma anomalia interna no sistema circulatório, enquanto que outros podem ser causados por alguma situação de estresse que ocorreu com a pessoa. Mesmo o foco deste projeto ser a hipertensão, existem situações em que é importante identificar que uma pessoa está hipotensa, pois a hipotensão também pode causar consequências no organismo da pessoa. Quando se fala da alteração na pressão arterial é importante lembrar que a hipertensão e a hipotensão estão sendo consideradas.

Alguns dos fatores internos que causam o aumento da pressão são a retenção de água e sódio, aumento na demanda de sangue, vasoconstrição, aumento na viscosidade do sangue e o enrijecimento das artérias. A condição de hipotensão pode ser provocada por uma hemorragia, aqui sendo considerada uma hemorragia interna causada por um rompimento de algum vaso, uma falha na bomba cardíaca e a vasodilatação (SOCIEDADE BRASILEIRA DE HIPERTENSÃO – SBH, 2017). É possível que o controle que o corpo realiza sobre a PA cause alguns desses fatores, mas também existem doenças que alteram o funcionamento do sistema circulatório, como as cardiopatias⁵. Existem diversos tipos de cardiopatias, entre elas as agudas, as crônicas e as terminais, que definem o mal funcionamento do coração. Existe uma cardiopatia que é consequência da hipertensão, conhecida como cardiopatia hipertensiva, que sobrecarrega o coração e os vasos sanguíneos (DUTRA, 2006).

Também é importante ressaltar os fatores externos que podem causar alterações na PA. Por exemplo, existe um termo chamado “pressão do avental branco” que se deve a possibilidade de existir uma diferença entre a PA de uma pessoa em sua residência e a medida no consultório médico. Graças a isso, foi possível identificar a hipertensão do avental branco, que seria uma pessoa que ao medir sua pressão no consultório médico possui pressão alta enquanto que em seu dia a dia a pressão está dentro dos padrões normais. Também existe a hipertensão mascarada que é o oposto da hipertensão do avental branco, em que a pessoa possui pressão normal no consultório e hipertensão no dia a dia (SBH, 2017).

⁵Cardiopatia é qualquer doença que acomete o coração (DUTRA, 2006).

2.1.4 Monitoramento da Pressão Arterial

Muitos médicos incentivam o monitoramento casual, exterior ao consultório, da pressão arterial, visto que sem este procedimento não é possível avaliar adequadamente a PA (SOUSA *et al.*, 2011). O monitoramento de rotina no consultório médico é indispensável para verificar a PA, mas, ainda assim, é muito recomendado que as pessoas realizem um acompanhamento diário para poder monitorar o tratamento, melhorar a adesão e o controle da PA. Segundo a VI Diretrizes Brasileiras de Hipertensão (2010), é recomendada a medida da pressão fora do consultório, sempre que possível, para fins de esclarecimento de diagnóstico.

Como comentado anteriormente, a hipertensão do avental branco e a hipertensão mascarada são problemas para quem realiza a medida casual da PA apenas em consultórios. Desta forma, é orientado que deve ser considerada a utilização de métodos de medição intermitente e casuais fora do consultório para investigar se um paciente possui um desses dois tipos de hipertensão citados (SOUSA *et al.*, 2011). Pelos métodos atuais para medir a PA um problema é encontrado, os aparelhos podem estar descalibrados e os pacientes podem não ter sido bem informados das regras para realizar uma medição correta pelo equipamento, levando a medições errôneas da PA. Na seção 2.2.2 será comentado a respeito dos métodos atuais e uma solução para este problema encontrado.

2.2 ENGENHARIA BIOMÉDICA

A engenharia é uma profissão onde são aplicados conhecimentos de matemática, física e ciências naturais para desenvolver maneiras de utilizar, economicamente, materiais e forças da natureza para o ganho da humanidade. A engenharia biomédica, sendo uma subárea, aplicará esses conhecimentos para resolver problemas específicos da medicina e biologia. No sistema de saúde moderno, a engenharia é necessária para solucionar problemas na proteção da saúde, na prevenção de doenças e no tratamento e reabilitação de pacientes com a introdução de tecnologias de uso diário e hospitalar (BADNJEVIC e GURBETA, 2016).

É inegável que a engenharia biomédica contribuiu significativamente com a melhora no cuidado diário da saúde em hospitais, clínicas e em residências, além de colaborar ativamente para o conhecimento fundamental nas áreas de medicina e biologia, com o desenvolvimento de aparelhos e equipamentos que facilitam e auxiliam pesquisas realizadas na área. Apesar de o campo parecer relativamente recente, pode-se afirmar que a ideia básica surgiu muito antes, no ano 2000 arqueologistas alemães encontraram uma múmia em Tebes

com uma prótese de madeira no lugar do dedão do pé, podendo ser a mais antiga prótese conhecida (BADNJEVIC e GURBETA, 2016). A primeira aparição de dispositivos médicos foi no Egito, onde eram utilizados cana oca para visualizar e escutar os acontecimentos internos da anatomia humana. Mesmo tendo surgido há muito tempo, foi após a invenção do transistor de silício que começou o desenvolvimento e crescimento da engenharia biomédica (MAGJAREVIC e DIAZ, 2014).

Recentemente, devido ao grande desenvolvimento da engenharia biomédica, foi possível observar uma necessidade de especialização na área, o que acabou criando alguns perfis para os profissionais, sendo eles: engenheiro biomédico, bioengenheiro e engenheiro clínico (MAGJAREVIC e DIAZ, 2014). Um bioengenheiro foca mais na biologia molecular, que resolvem problemas utilizando células vivas, assim sendo, utiliza os princípios da engenharia a nível celular e molecular. Um engenheiro clínico utiliza esses princípios para resolver problemas com sistemas tecnológicos e humanos complexos, do tipo encontrados em instalações de cuidados de saúde, também podendo trabalhar com enfermeiros e outros profissionais de saúde na criação de novos produtos e conceitos, assim como em testes clínicos. De acordo com a Organização Mundial de Saúde (World Health Organization - WHO) o trabalho de um engenheiro biomédico é descrito da seguinte maneira.

“São necessários engenheiros biomédicos treinados e qualificados para a concepção, avaliação, regulação, manutenção e gerenciamento de dispositivos médicos presentes em sistemas de saúde em todo o mundo. Os conhecimentos e os níveis de habilidade dos engenheiros biomédicos variam do design e avaliação de dispositivos médicos em níveis mais elevados, até o trabalho muito técnico em níveis mais baixos, como serviço regular e manutenção.” (WHO,).

Os engenheiros biomédicos podem ser vistos, então, como os responsáveis pela criação e desenvolvimento de novas tecnologias nas áreas médica e biológica, de forma a possibilitar aos profissionais dessas áreas novas maneiras e técnicas para melhor entender o funcionamento biológico do ser humano, prevenir, identificar e tratar doenças, permitir e facilitar a reabilitação de pacientes, desenvolver instrumentos e máquinas para auxiliar em cirurgias mais avançadas. Em seguida será comentado sobre os instrumentos utilizados por médicos para o diagnóstico e tratamento de doenças.

2.2.1 Instrumentação Biomédica

De acordo com o estatuto dos Estados Unidos da América, um dispositivo médico é tido como um instrumento, aparelho, máquina, dispositivo, implante ou similares que seja destinado ao diagnóstico, cura ou tratamento de doenças ou destinado a afetar a estrutura ou função do corpo humano, sem realizar ações químicas (MONSEIN, 1997). Neste projeto será utilizado o termo instrumento quando se for considerar um dispositivo médico. Dessa forma se pode declarar como um instrumento médico tudo aquilo que é usado a favor da saúde e bem-estar de um paciente. No Brasil, a classificação dos instrumentos médicos é feita baseada no risco para o paciente, operador e médico, sendo esta dividida em 4 classes, Classe I-IV (EMERGO, 2018).

Muitos instrumentos médicos atuais tiveram origem em instrumentos utilizados muito antigamente, como ataduras, muletas, entre outros simples. Mas com o avanço das tecnologias e entendimento do corpo humano, foi possível o desenvolvimento de instrumentos mais aperfeiçoados. Tais com utilidades mais complexas, como aferição de pressão arterial, raio-X, mamografia, entre outros, que permitiram ainda mais a compreensão do corpo e das fisiologias humanas. Atualmente existem muitos exemplos de dispositivos, como os exemplificados nas figuras 2 e 3.



Figura 2 - Exemplo de válvulas aórticas mecânicas
Fonte: Adaptado de Lugones (2017).

A Figura 2 mostra uma válvula aórtica mecânica, utilizada em pacientes que tem algum problema em seu coração que tenha danificado ou inutilizado a sua válvula aórtica original, ou seja, é utilizado como tratamento de um problema do paciente. Também existem aqueles instrumentos que são utilizados na cura de alguma doença, ou no seu diagnóstico total ou parcial, como o instrumento da Figura 3, um medidor de pressão arterial de pulso. Devido a este projeto lidar com uma maneira de aferir a pressão arterial, os instrumentos utilizados com esse propósito serão previamente comentados a seguir, de forma a visualizar a evolução que já tiveram e que ainda podem ter.



Figura 3 - Aparelho de Pressão Digital de Pulso
Fonte: Fibra Cirúrgica, G-TECH (2017)

2.2.2 Métodos e Instrumentos para Monitoramento da Pressão Arterial

A primeira tentativa de medir a pressão arterial foi realizada em 1733 pelo reverendo Stephen Hales em uma égua. Hales inseriu um tubo de vidro na carótida do animal, verificando que a coluna de sangue no tubo subia 2,9 m e oscilava conforme os batimentos cardíacos da jumenta. Mesmo após ter ganho honrarias na Europa pela descoberta da pressão arterial, os estudos de Hales caíram no esquecimento (KOHLMANN, 2011). Por muito tempo apenas métodos invasivos foram experimentados. Apenas em 1834 que o médico J. Hérisson e o engenheiro P. Gernier criaram um instrumento não invasivo. Mas como este só tinha como função transformar uma sensação tátil em uma impressão visível acabou sendo abandonado.

A primeira medição mais exata da pressão em um ser humano foi realizada em 1856, durante um ato cirúrgico realizado por Fraive. Na artéria femoral foi detectada uma pressão de 120 mmHg, enquanto que na artéria branquial esses valores variaram entre 115 e 120 mmHg, começando a busca por valores de normalidade. Em 1896, Scipione Riva-Rocci criou um esfigmomanômetro mais portátil, que consistia de um manguito, que cobria o braço por toda

sua circunferência, que era inflado até o total desaparecimento do pulso radial e, em seguida, desinflado até o reaparecimento deste, medindo então a pressão arterial. Riva-Rocci marcou o fim da era das pesquisas de um método clínico simples para a avaliação da PA. A partir daí modificações foram feitas a esse esfigmomanômetro e outras evoluções que levaram ao surgimento dos métodos auscultatório e oscilométrico, os quais são automáticos e não invasivos (KOHLMANN e KOHLMANN JUNIOR, 2011).

O método mais comumente utilizada em consultórios médicos é o auscultatório. Os instrumentos que utilizam essa técnica determinam a pressão arterial pelo monitoramento dos sons de Korotkoff. Esta técnica é realizada se utilizando de um manômetro acoplado a uma bolsa inflável (manguito) e um estetoscópio. O objetivo é interromper a passagem do fluxo sanguíneo, na artéria braquial, insuflando o manguito para, então, liberar lentamente o ar da bolsa e, utilizando o estetoscópio, perceber o ruído produzido no retorno do fluxo. Quando o sangue começa a fluir pela artéria, seu fluxo cria uma pulsação sincrônica do pulso (primeiro som de Korotkoff). A pressão arterial sistólica é associada com a primeira detecção deste som, visto que a pressão do fluxo conseguiu vencer a pressão imposta pelo manguito, sendo assim a pressão máxima. Quando o silêncio volta a ocorrer, indicasse que não há nenhuma força se opondo à passagem do sangue, logo é aferida a pressão arterial diastólica (SBH, 2017). Alguns dos instrumentos que utilizam essa técnica são o esfigmomanômetro de mercúrio e um esfigmomanômetro em conjunto com um estetoscópio, como o visto na Figura 4.



Figura 4 - Esfigmomanômetro (1) e estetoscópio (2)
Fonte: Glicomed, 2017

Com o avanço na tecnologia, foi possível o desenvolvimento de novas técnicas que envolvem um processamento digital de sinais para aferir a pressão arterial, tais como a oscilometria e a fotopletismografia. A técnica da oscilometria também utiliza a mesma ideia de ocluir o fluxo para determinar a PA. O equipamento pressuriza o manguito para detectar os pulsos oscilométricos⁶. Para determinar a PA, essa técnica identifica, quantifica e analisa esses pulsos. A PA média é definida no ponto onde as oscilações são maiores, enquanto que a sistólica e a diastólica requerem uma normalização na amplitude da onda, o que ocorre por meio de cálculos matemáticos (SBH, 2017). Alguns instrumentos que utilizam desta técnica são os tensiômetros automáticos e os tensiômetros semiautomáticos, sendo que a diferença entre eles está apenas no método de inflar a braçadeira. Nos semiautomáticos isso é feito à mão.

Atualmente, os métodos para o controle contínuo da pressão arterial são bem escassos e não possuem um tempo de atuação muito longo. O mais utilizado é o M.A.P.A., mas existe também um que utiliza a técnica de fotopletismografia, o primeiro é um exame realizado em períodos de 24 horas, e procura auxiliar os médicos na avaliação de sintomas, assim como palpitações, arritmias, episódios de desmaios e também para acompanhamento pós-cirurgias. O M.A.P.A. (Monitoração Ambulatorial da Pressão Arterial) é um exame cardiológico que pode ser realizado por dois métodos, sendo estes o oscilométrico ou o Holter, para a obtenção das pressões arteriais continuamente. Este exame permite o estudo do padrão da pressão arterial e a realização da análise da eficácia das drogas anti-hipertensivas. O M.A.P.A. Holter é realizado através de eletrodos colados no peito do paciente que são conectados a um monitor. Devido ao uso desses eletrodos a técnica utilizada aqui é parecida com a do eletrocardiograma.

A fotopletismografia realiza a medição da PA batimento a batimento, porém este método ainda envolve a utilização de um manguito preso ao dedo do paciente. Aqui, um feixe de luz infravermelha identifica a Pressão Transmural⁷, e o equipamento infla o manguito até que sua pressão anule a transmural, obtendo assim a PA, visto que a pressão transmural é a PA menos a pressão exercida pelo manguito (SBH, 2017). Na Figura 5 é possível observar as três técnicas existentes de monitoramento da pressão arterial, em quais contextos cada uma é usada e por quais métodos. Por exemplo, o método oscilométrico é usado para realizar medidas casuais ou intermitentes, sendo considerado casual a realização da medida em algum momento do dia por um indivíduo.

⁶Ondas de oscilação geradas pela passagem do sangue na luz da artéria após a oclusão.

⁷Pressão nas paredes das artérias do dedo.

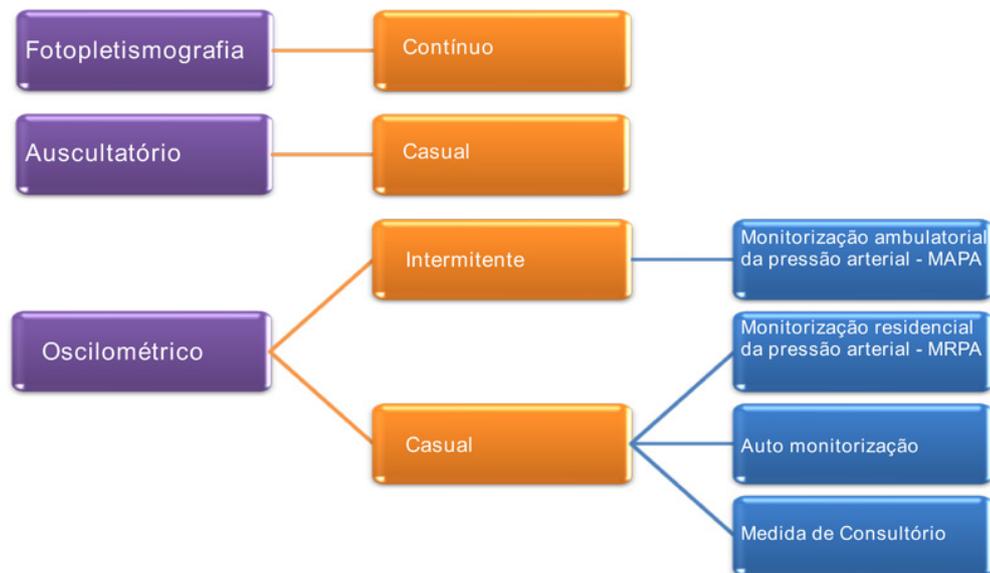


Figura 5 - Técnicas existentes, os tipos de medição e os métodos que as utilizam
Fonte: Retirado da Sociedade Brasileira de Hipertensão (2015)

Apesar dos métodos descritos não serem muito funcionais para uma utilização diária, foram realizadas comparações entre eles de forma a escolher aquele que possui a melhor capacidade de ser aperfeiçoado e aproveitado para um controle melhor da pressão diária do paciente. O M.A.P.A. pelo método oscilométrico, devido a precisar de um manguito inflando no braço do paciente, pois realiza a medida pelos sons de Korotkoff, não tem como remover o desconforto sem afetar o método. O Holter precisa utilizar cargas elétricas para aferir a pressão, dificultando a evolução desse método de forma mais prática e contínua. A fotopletismografia utilizada da maneira atual é muito cara, mas a maneira de obter o dado para análise é relativamente fácil. Assim, se for possível diminuir os custos com a análise dos dados poderia se tornar um método viável para a medição da PA diariamente.

Após pesquisas, foi possível identificar apenas um aparelho existente que utiliza essa técnica, mesmo assim este aparelho não é comercializado dentro do país e possui um custo elevado. Porém essa técnica é muito utilizada em aparelhos com a técnica da oximetria, para verificar a saturação de oxigênio e pulso do paciente. Para realizar a medição da PA estudos estão sendo realizados, como foi indicado na justificativa. No Brasil, esses aparelhos ainda não são muito comercializados por não atingirem os padrões necessários para isso. Outra inibição é que o único que é comercializado utiliza um manguito para aferir a pressão, não

sendo utilizando completamente da técnica desejada. O processamento do sinal ainda precisa ser aprimorado para a possível comercialização do produto dentro dos padrões necessários, que é o propósito deste projeto.

2.3 TRANSFORMADA DE FOURIER

A Transformada de Fourier ou FT (do inglês *Fourier Transform*) é muito utilizada em diversos campos como uma ferramenta de análise comum. Em muitos sinais é considerado mais natural o estudo com informações de frequência e não de tempo, que é, essencialmente, o que a FT consegue proporcionar. Essa transformada possui quatro categorias, pois como os sinais podem ser contínuos ou discretos e também periódicos ou aperiódicos, fazendo uma combinação dessas duas características tem-se as seguintes categorias: Sinais aperiódicos e contínuos, periódicos e contínuos, aperiódicos e discretos e periódicos e discretos. A transformada recebe um nome diferente para cada uma dessas categorias sendo eles, respectivamente, transformada de Fourier, séries de Fourier, transformada de Fourier de tempo discreto e a Transformada Discreta de Fourier ou DFT (do inglês *Discrete Fourier Transform*), como é possível observar na Figura 6.

Tipo de Transformada	Exemplo de Sinal
Transformada de Fourier <i>sinais que são contínuos e aperiódicos</i>	
Série de Fourier <i>sinais que são contínuos e periódicos</i>	
Transformada de Fourier de Tempo Discreto <i>sinais que são contínuos e aperiódicos</i>	
Transformada Discreta de Fourier <i>sinais que são contínuos e aperiódicos</i>	

Figura 6 - Nomeação das transformadas para cada tipo de sinal

Fonte: Adaptado de Smith (2003)

Considerando que o escopo deste projeto envolve sinais periódicos e discretos não serão abordadas as transformadas para os outros tipos de sinal. Mas para poder entender a

DFT é necessário compreender o princípio da FT. Basicamente a FT decompõe um sinal em senoides, ou seja, um sinal pode ser representado por uma soma de senos e cossenos. Para os sinais de tempo discreto, não é possível identificar uma diferença entre o sinal original e a sua representação, devido a ambos já serem representados de maneira discreta, ponto a ponto. As senoides são utilizadas no lugar de ondas quadradas ou triangulares devido ao fato que são mais simples de lidar por serem a única forma de onda à possuírem a fidelidade senoidal⁸ como característica (SMITH, 2003).

Para representar sinais aperiódicos é necessário um número infinito de senoides, fazendo com que seja impossível um algoritmo de computador realizar a transformada de Fourier de tempo discreto. Desta maneira, para o processamento digital de sinais, o único tipo que pode ser usado é o DFT, o que se torna um problema quando se deve lidar com sinais que se repetem parcialmente em determinados períodos, ou seja, se repetem mas mudam minimamente entre cada período. A solução para este problema é discutida no tópico de materiais e métodos deste projeto.

2.3.1 Transformada Discreta de Fourier

Considerando que o tipo mais comum de sinal que entra na DFT é composto de amostras tiradas em intervalos de tempo regulares, é dito que este está no domínio do tempo. Enquanto que o termo domínio da frequência é usado para descrever as amplitudes dos senos e cossenos resultantes da decomposição do sinal. A DFT muda um sinal de entrada com N pontos para dois sinais de saída com $N/2 + 1$ pontos. Esses pontos dos sinais de saída representam as amplitudes dos senos e cossenos. A DFT pode ser representada por (SMITH, 2003):

$$X[m] = \sum_{n=0}^{N-1} x[n] \left(\cos\left(\frac{2\pi nm}{N}\right) - j \sin\left(\frac{2\pi nm}{N}\right) \right), \quad (1)$$

em que m representa o número da amostra do sinal e vai de $m=0, \dots, N-1$, esta é conhecida como a forma retangular da DFT, e N representa o número total de amostras (SMITH, 2003). Porém, quando se trata de um algoritmo implementado num sistema é mais importante saber

⁸Para um sistema linear, se a entrada for uma senoide a saída é garantidamente uma senoide. Apenas a amplitude e a fase do sinal podem mudar, enquanto que a forma de onda e a frequência devem permanecer as mesmas.

os vetores das amplitudes das senoides do que os valores obtidos por (1). Utilizando a mesma notação esses vetores podem ser definidos como (SMITH, 2003):

$$c_k[m] = \cos\left(\frac{2\pi km}{N}\right) , \quad (2)$$

$$s_k[m] = \sin\left(\frac{2\pi km}{N}\right) , \quad (3)$$

Como a transformada retorna dois vetores com $N/2 + 1$ pontos agora m vai de $m=0, \dots, N/2$. É importante ressaltar que o parâmetro de frequência k é igual ao número de ciclos completos que ocorrem no decorrer dos N pontos do sinal de entrada. As Equações 2 e 3 são conhecidas como as funções básicas da DFT. A Equação 1 poderia também ser reescrita utilizando as Equações 2 e 3 para realizar a DFT inversa, ou seja, a reconstrução do sinal no domínio do tempo utilizando os sinais no domínio da frequência, resultando em (SMITH, 2003):

$$X[m] = \sum_{k=0}^{N/2} (c[k] \cos\left(\frac{2\pi km}{N}\right) + s[k] \sin\left(\frac{2\pi km}{N}\right)) , \quad (4)$$

Neste projeto não é necessária a reconstrução do sinal de entrada, apenas a realização da DFT. Logo, não será aprofundado o funcionamento da DFT inversa. Como foi possível observar, as frequências resultantes da DFT são dependentes do número de amostras do sinal de entrada, porém estarão sempre espaçadas igualmente entre as frequências inicial $k=0$ e a final $k=N/2$. Visto que os sinais de saída possuem $N/2 + 1$ amostras cada, percebe-se que o número de amostras que sai é maior que o número que entra na DFT, porém não foi adicionada nenhuma informação por causa disso já que os valores de $s[0]$ e $s[N/2]$ são nulos. Isso ocorre devido a $\sin(0)$ e $\sin(\pi m)$ serem sempre nulos, visto que se ao substituir $k=0$ e $k=N/2$ em (3) se obtêm os valores comentados.

2.3.2 Transformada Rápida de Fourier

A FFT nada mais é que um algoritmo inteligente de implementação da DFT (WEEKS, 2012). Como é de se esperar os resultados obtidos são iguais aos da DFT, porém de maneira muito mais rápida, devido à eficiência do algoritmo. O algoritmo da FFT levou a um

grande avanço, visto que permitiu a pesquisadores calcular a transformada de Fourier de maneira muito mais rápida. A DFT realiza operações N^2 para obter seu resultado, ou seja, para uma entrada com cem bilhões de amostras ela levaria em torno de dois meses para obter seus resultados. Já a FFT, possuindo operações $N \cdot \log(N)$, levaria apenas 1.33 segundos para trazer o resultado com essa mesma quantidade de dados. É possível ver essa diferença no tempo de execução da Figura 7. Os asteriscos representam a função N^2 e a linha representa a função $N \cdot \log(N)$.

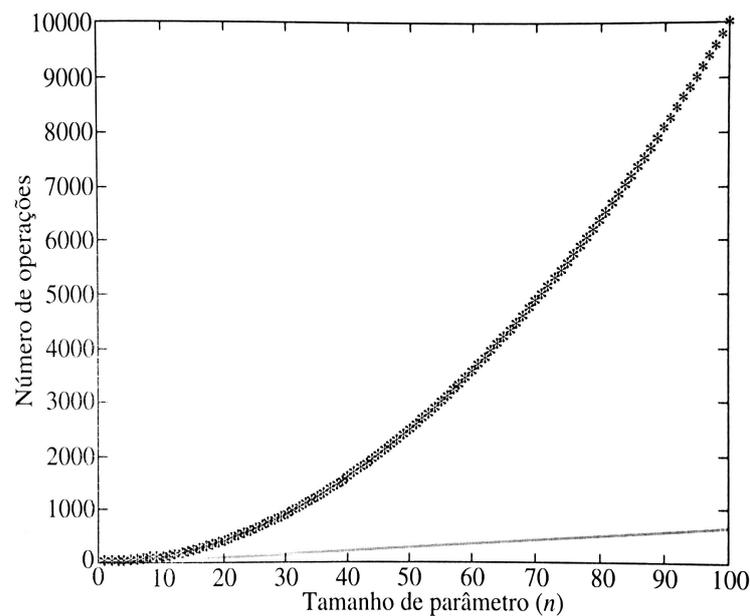


Figura 7 - Diferença na quantidade de interações para a DFT e a FFT
Fonte: Retirado de Weeks (2012).

2.4 INTELIGENCIA ARTIFICIAL

A classificação de dados é utilizada antes mesmo do surgimento dos computadores. Por exemplo, um gerente deve saber qual é a melhor organização da loja, a disposição dos produtos, para ter o maior número de vendas e um médico deve observar os exames de um paciente para saber se ele possui alguma doença. Antigamente essas ações eram realizadas exclusivamente por pessoas, pois existia uma escassez de dispositivos que pudessem ajudar nesta classificação.

O cérebro humano é capaz de reconhecer padrões de forma muito mais rápida do que os atuais computadores digitais convencionais, devido a ele ser capaz de organizar seus neurônios para realizar um processamento não linear e paralelo de todos os estímulos que

recebe a cada segundo. Pode-se citar a visão como um ótimo exemplo desta velocidade, pois o cérebro humano é capaz de reconhecer um rosto familiar em meio a uma cena não familiar em questão de segundos, enquanto que tarefas menos complexas podem levar dias para serem processadas por um computador (HAYKIN, 2001).

Apesar de o computador ter uma velocidade de processamento mais rápida que a do ser humano, ele só consegue realizar ações previamente definidas por um código instalado dentro dele. Assim, ele é mais rápido para realizar operações matemáticas, mas muito mais lento para encontrar um rosto em uma multidão, visto que isso requer um processamento de imagem. Atualmente, a quantidade de tarefas complexas e o volume de dados exigidos por essas tarefas está tornando a sua realização por seres humanos muito mais difícil e as vezes até impossível, visto que um humano gasta muito tempo para processar o volume de dados (FACELLI et al, 2011). Sendo assim, a necessidade em encontrar uma maneira de tornar o computador capaz de realizar ditas tarefas está ficando cada vez maior. Graças a isso, a quantidade de pesquisas realizadas na implementação de um sistema capaz de realizar tais tarefas é muito elevada, e levou ao surgimento das ditas redes neurais artificiais, as quais serão melhor explicadas a seguir.

2.4.1 Redes Neurais Artificiais

Uma rede neural artificial (RNA) é uma tentativa de copiar a maneira como o cérebro realiza uma tarefa particular ou uma função de interesse (HAYKIN, 2001). Da maneira como as redes neurais são desenvolvidas atualmente não é possível criar uma RNA que seja capaz de realizar múltiplas tarefas diferentes, só é possível desenvolver uma RNA para realizar uma tarefa complexa por vez, devido a como é implementado o seu funcionamento. Para melhor entender o funcionamento de uma RNA a definição de Haykin (2001) será utilizada:

“Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.” (HAYKIN, 2001, p.28).

Como é possível observar, uma RNA é desenvolvida com base no funcionamento do cérebro humano, e, por isso, possui duas características semelhantes a ele. Essas

características são: seu conhecimento é adquirido através de um processo de aprendizagem. A partir de seu ambiente e esse conhecimento é armazenado utilizando-se de forças de conexão entre neurônios, conhecidas como pesos sinápticos. É necessário então discutir qual a definição de um neurônio para uma RNA, qual é seu ambiente e o que é um processo de aprendizagem. Um ambiente de aprendizagem é, basicamente, o conjunto de dados que a RNA utiliza para treinar, e seu ambiente de atuação é o conjunto que ela processará, em seguida ao seu treinamento (HAYKIN, 2001). Os tipos de dados utilizados em ambos os ambientes devem ser iguais. Em seguida, será explicado em detalhes os neurônios e os processos de aprendizagem possíveis.

2.4.1.1 Neurônios artificiais

Um neurônio é uma unidade de processamento de informações, o qual é fundamental para o funcionamento de uma rede neural (HAYKIN, 2001). Um neurônio é composto por um conjunto de conexões, por um somador e por uma função de ativação, como é possível ver na Figura 8. Cada uma das partes do neurônio possui um propósito para no fim causar o bom funcionamento deste. O conjunto de elos de conexão, sendo que cada um possui um peso sináptico próprio, são responsáveis por multiplicar os sinais de entrada de cada elo pelo seu peso. Também é importante notar que os pesos sinápticos de um neurônio artificial podem assumir valores tanto negativos quanto positivos, o que não ocorre em uma sinapse no cérebro. O somador, como o próprio nome já indica, é responsável por realizar o somatório do sinal de cada um dos elos, ponderados pelos respectivos pesos sinápticos do neurônio. E por fim, a função de ativação está encarregada de restringir a amplitude do sinal de saída do neurônio. Esta função também é conhecida como função restritiva, visto que limita o intervalo permitido das amplitudes do sinal de saída.

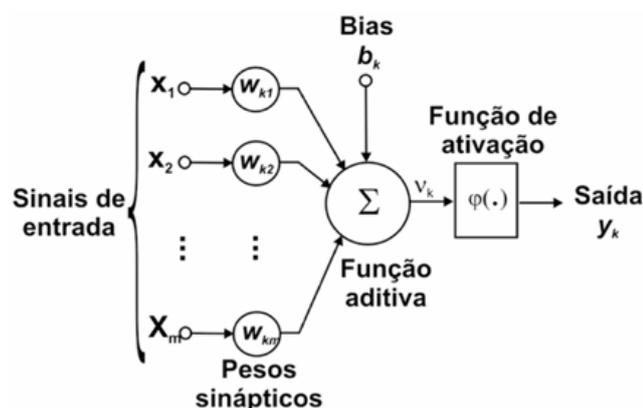


Figura 8 - Modelo não linear de um neurônio
Fonte: Retirado de Haykin (2001)

É possível visualizar que o modelo da Figura 9 possui um sinal extra na entrada, nomeado de bias. Este sinal possui o intuito de aumentar ou diminuir a entrada líquida da função de ativação, visto que pode assumir valores positivos ou negativos (HAYKIN, 2001). Os neurônios artificiais podem ser representados matematicamente da seguinte forma:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad , \quad (5)$$

$$y_k = \varphi(u_k + b_k) \quad , \quad (6)$$

sendo que x_j representam os sinais de entrada, w_{kj} são os pesos sinápticos do neurônio k , u_k é a saída do combinador linear, b_k representa o bias, $\varphi(\cdot)$ é a função de ativação e y_k é a saída do neurônio k (HAYKIN, 2001). O propósito do bias é realizar uma transformada afim para modificar o campo local induzido do neurônio, de forma que este não passe mais pela origem. Pode-se, então, redefinir (5) e (6), considerando o bias como uma entrada $x_0=1$ cujo peso w_{k0} equivale ao valor do b_k . Desta forma, as novas equações ficariam da seguinte forma (HAYKIN, 2001):

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad , \quad (7)$$

$$y_k = \varphi(v_k) \quad , \quad (8)$$

Considerando as entradas da maneira que estão em (7) é possível redesenhar o modelo do neurônio anteriormente visto na Figura 8. Assim o novo modelo do neurônio pode ser visualizado na Figura 9.

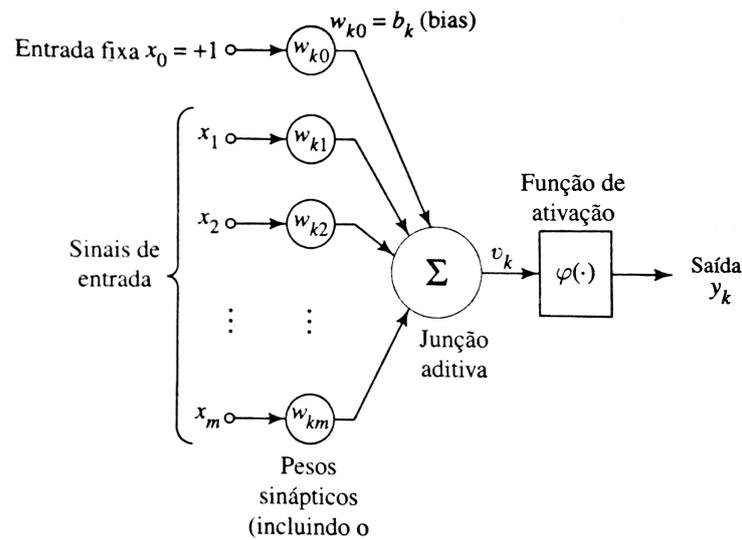


Figura 9 - Modelo não linear de um neurônio considerando o bias como entrada
Fonte: Retirado de Haykin (2001)

As funções de ativação podem ser de três tipos básico: função de limiar, função linear por partes e função sigmoide. Uma função de limiar possui apenas duas saídas possíveis, 1, se o campo local induzido é não negativo, ou 0 caso contrário. Essa função é descrita da seguinte forma (HAYKIN, 2001):

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (9)$$

Uma função linear por partes é uma função que dentro de um intervalo possui saída igual à entrada e fora deste intervalo assume valores pré definidos. Um exemplo desse tipo de função pode ser expresso por (HAYKIN, 2001):

$$\varphi(v) = \begin{cases} 1, & v \geq 0,5 \\ v, & 0,5 > v > -0,5 \\ 0, & v \leq -0,5 \end{cases} \quad (10)$$

Já uma função sigmoide é uma função estritamente crescente que exibe um balanceamento entre comportamentos linear e não-linear. Esse tipo de função é o mais comumente utilizado na construção de RNAs (HAYKIN, 2001). Um exemplo de função sigmoide é a função logística, definida por

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad , \quad (11)$$

onde a é o parâmetro de inclinação da função. Variando-se este parâmetro é possível obter funções com diferentes equações. Caso esse parâmetro se aproxime de infinito, esta função pode ser considerada simplesmente uma função limiar. Na Figura 10 é possível visualizar um exemplo de cada um desses tipos de funções.

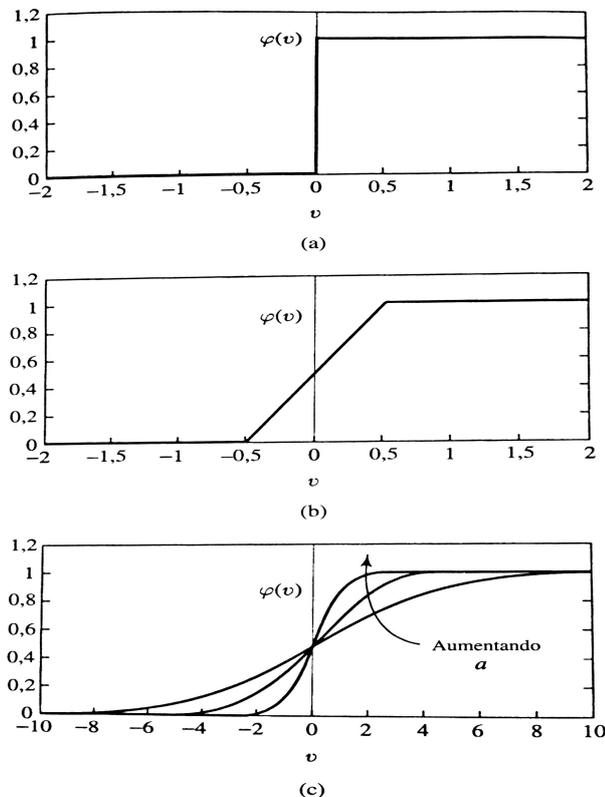


Figura 10 - Funções de ativação: (a) Função limiar, (b) Função linear por partes, (c) Função sigmoide
Fonte: Retirado de Haykin (2001)

2.4.1.2 Processo de aprendizagem

Uma rede neural tem como propriedade de primordial importância a habilidade de aprender e melhorar seu desempenho a partir de seu ambiente. Desta forma, um processo de aprendizagem nada mais é do que um processo iterativo de ajustes que são aplicados aos pesos sinápticos e níveis de bias da rede neural. É desejado que a rede, a cada iteração do processo de aprendizagem, se torne mais instruída em relação ao seu ambiente. Para uma RNA é possível definir aprendizagem da seguinte maneira:

“Aprendizagem é um processo pela qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede esta inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação ocorre.” (HAYKIN, 2001, p.75).

Esta definição foi adaptada de Mendel e McClaren (1970) por Haykin (2001). É possível verificar que essa definição do processo de aprendizagem implica uma determinada sequência de eventos. Esta sequência sendo a seguinte, uma RNA é estimulada por seu ambiente, sofrendo, então, alterações nos seus parâmetros livres, para, por fim, responder de uma maneira nova ao seu ambiente. Pode-se considerar que existem cinco regras básicas de aprendizagem: aprendizagem por correção de erro, aprendizagem baseada em memória, aprendizagem hebbiana, aprendizagem competitiva e aprendizagem de Boltzmann. Cada uma dessas regras possui um método de atuação. É importante saber que a aprendizagem por correção de erro foi fundamentada na filtragem ótima, a aprendizagem baseada em memória opera memorizando os dados de treinamento, a aprendizagem de Boltzmann é baseada em ideias da mecânica estatística, e a aprendizagem hebbiana e a aprendizagem competitiva são inspiradas em considerações neurobiológicas (HAYKIN, 2001).

Visto que o método para treinar a RNA que será utilizado neste projeto emprega um algoritmo que se baseia na regra de aprendizagem por correção do erro, apenas esta regra será explicada em mais detalhes. Quando se inicia o treinamento de uma rede neural não se sabe ao certo quais serão seus pesos sinápticos, sendo assim eles são iniciados em algum valor. Costuma-se, então, ocorrer um erro na saída desta rede em relação ao resultado esperado. Esse erro é então processado e os valores dos pesos sinápticos corrigidos. Esse processo costuma ocorrer um determinado número de vezes, podendo ser definido inicialmente pelo desenvolvedor da rede ou até que o erro esteja menor do que um valor, também definido pelo desenvolvedor (HAYKIN, 2001).

Os processos de aprendizagem também podem ser definidos em supervisionados e não supervisionados. Processo não supervisionados são aqueles onde não é informado um valor esperado para a saída da RNA. Normalmente, esse tipo de processo é utilizado em redes que se quer descobrir um padrão para os dados informados. Já nos processos supervisionados se sabe o valor esperado na saída e algum modo de comparar o valor obtido com o valor esperado. A regra de aprendizagem por correção do erro requer um processo supervisionado, visto que é necessário saber o resultado esperado para poder obter o erro.

2.4.1.3 Tipos de redes neurais artificiais

Existem muitas tarefas diferentes que podem ser resolvidas utilizando-se RNAs. Dessa forma, é de se esperar que existam tipos diferentes de redes. Problemas mais complexos requererão uma RNA mais complexa para a sua execução, enquanto que problemas mais simples podem utilizar uma RNA menos desenvolvidas. No escopo deste trabalho é importante comentar sobre dois tipos de redes neurais: a perceptron de camada única e a perceptron de múltiplas camadas. Será explicada superficialmente a perceptron de camada única, visto que o tipo de RNA que será utilizado neste projeto é o perceptron de múltiplas camadas.

Um perceptron de camada única é a forma mais simples que uma rede neural pode assumir e costuma ser utilizado para o reconhecimento de padrões ditos linearmente separáveis⁹. Esse tipo de rede consiste em, basicamente, um único neurônio com pesos sinápticos ajustáveis e bias (HAYKIN, 2001). Deve-se considerar que, apesar de ser dito que possui apenas uma camada, o perceptron possui a camada de entrada e a de saída. Como possui apenas um único neurônio na saída, o perceptron é capaz de identificar apenas duas classes. Adicionando-se mais neurônios na saída ele passa a poder classificar mais tipos. Porém, para que funcione corretamente, essas classes ainda devem ser linearmente separáveis (HAYKIN, 2001).

Como o funcionamento do perceptron de camada única não é muito importante para este projeto ele não será comentado em detalhes. Já o perceptron de múltiplas camadas ou MLP(do inglês *multilayer perceptron*) será o utilizado para a implementação da RNA deste projeto. Este possui um conjunto de nós de fonte como entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída de nós computacionais. O MLP tem sido muito utilizado na resolução de problemas difíceis por meio de seu treinamento supervisionado com algoritmos baseados na regra de aprendizagem por correção de erro. Um dos algoritmos utilizados é o de retropropagação de erro, o qual será comentado mais profundamente na próxima sessão, mas pode-se dizer que de forma simplificada o erro encontrado retornará no sentido contrário as sinapses para realizar a atualização dos valores dos pesos sinápticos. O MLP possui três características distintas: a função de ativação dos neurônios é não-linear, sendo a função logística comumente utilizada, a RNA possui uma ou mais camadas de neurônios ocultos, ou seja, não fazem parte nem da entrada ou saída, e por fim, a rede possui um alto grau de conectividade determinado por suas sinapses (HAYKIN, 2001).

⁹Padrões que se encontram em lados opostos de um hiperplano.

Uma rede MLP possui dois tipos de sinais identificados, os sinais funcionais e os sinais de erro. Os sinais funcionais são os sinais de entrada que incidem nos terminais de entrada, se propagam pela rede e acabam nos terminais de saída como um sinal de saída. Já os sinais de erro se originam nos neurônios de saída da rede e se propagam para trás, em direção ao início da rede. É possível visualizar esses sinais na Figura 11. Cada neurônio das camadas ocultas é responsável por duas funções, a realização do cálculo do sinal funcional, expressado como uma função não linear do campo local induzido, e do cálculo de uma estimativa do vetor gradiente, necessário para a retropropagação do erro através da rede (HAYKIN, 2001).

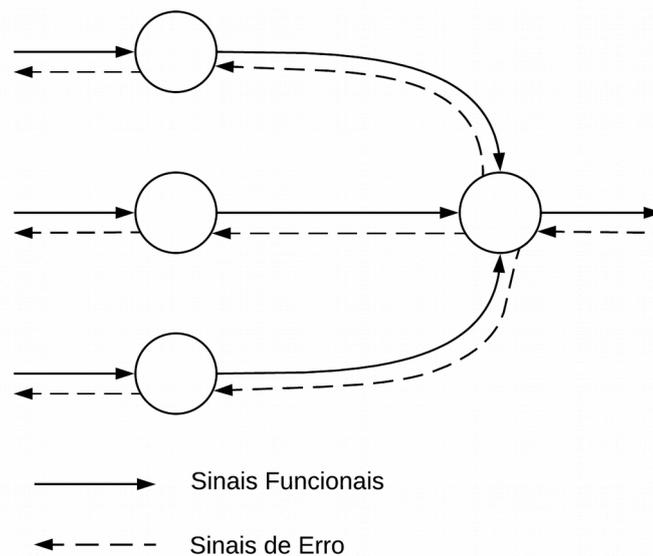


Figura 11 - Representação das direções dos fluxos de sinais básicos em um MLP
Fonte: Adaptado de Haykin (2001)

2.4.1.4 Método de Retropropagação

O algoritmo de retropropagação (do inglês *backpropagation algorithm*) pode ser visto como uma abordagem computacionalmente eficiente para calcular as derivadas parciais de uma função de custo complexa em redes neurais de múltiplas camadas. Apesar de ter sido redescoberto e popularizado em 1985, este algoritmo ainda é o mais utilizado na área de inteligências artificiais como forma de treinamento de redes neurais (RASCHKA e MIRJALINI, 2017). Esse método permite a rede aprender seus coeficientes de peso de forma a obter os melhores resultados possíveis dado um conjunto de treinamento.

Esse método é um tipo de treinamento supervisionado de RNA, ou seja, é necessário possuir os valores reais que deveriam ser atingidos ao alimentar a RNA com os dados do

conjunto de entrada. Desta forma é possível calcular o erro, obtido pela comparação dos dados aferidos pela RNA com o conjunto dos valores esperados. Então, este erro é utilizado na retropropagação de forma a atualizar os pesos dos neurônios para o aprimoramento do resultado obtido. O erro é calculado a partir da última camada de neurônios, a camada de saída, até a primeira camada de neurônios, a camada de entrada, percorrendo as camadas ocultas de forma a atualizar o peso de cada neurônio, como é possível visualizar graficamente na Figura 12.

De maneira simplificada, a retropropagação é uma aplicação da regra de cadeia para o cálculo da derivada de uma função aninhada complexa, que é uma função que pode ser definida como $f(g(x))$, ou seja a entrada para a função f é a saída obtida pela função g . Uma rede neural pode ser vista como uma composição de função arbitrariamente longa, devido aos resultados das funções de ativação da camada inicial serem os valores de entrada para a primeira camada oculta e assim por diante. Esse método auxilia na obtenção da derivada desta para o recálculo dos pesos de cada neurônio até o afinamento do resultado final obtido (RASCHKA e MIRJALINI, 2017).

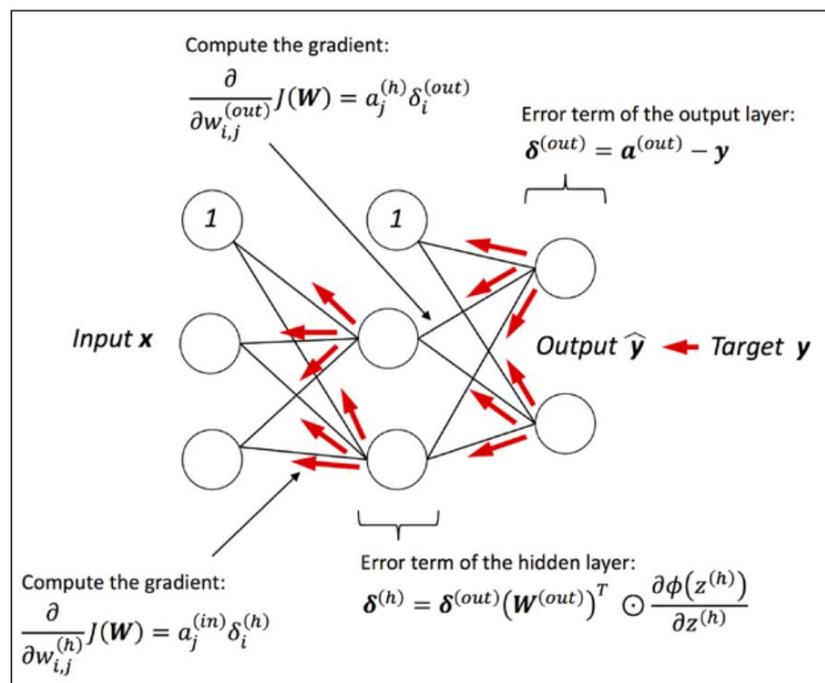


Figura 12 - Representação do funcionamento da retro propagação
Fonte: Retirado de Raschka e Mirjalini (2017)

A retro propagação ajuda no cálculo do erro e no aprimoramento dos pesos de cada neurônio da rede. Porém, sem a utilização de outra técnica, é possível que a rede tenha um problema chamado *overfitting*, que é o fenômeno onde a rede consegue uma exatidão muito boa no resultado dos dados utilizados para seu treinamento, mas quando são alimentadas

entradas nunca vistas, suas predições ficam muito fracas. Para impedir que esse fenômeno ocorra é utilizado um processo conhecido como validação.

2.4.1.5 Validação Cruzada

Seria possível utilizar todos os dados disponíveis para realizar o treinamento de uma RNA, porém, dessa forma, existe uma grande chance de ocorrer o fenômeno de *overfitting* citado anteriormente (McCaffrey, 2013). A validação tenta diminuir a ocorrência desse fenômeno ao separar o conjunto de dados em dois ou mais subconjuntos que são utilizados no aprimoramento dos resultados da RNA. Existem diversos métodos diferentes de validação, mas o mais comumente utilizado é o de separar o conjunto de dados original em três subconjuntos, os quais serão utilizados para o treinamento, validação e teste da rede neural (RELVAS, 2015).

De forma simplificada, o conjunto de treinamento é o que será utilizado para treinar a RNA, enquanto o de teste é utilizado para verificar quão bem a rede lida com valores nunca vistos, ou seja, sua eficiência para novos dados (RELVAS, 2015). Ao contrário dos primeiros citados, o subconjunto de validação pode não existir em algumas técnicas de treino, visto que ele é utilizado para um afinamento dos pesos e *bias* obtidos nos neurônios. O método mais simples de realizar uma validação é conhecido como *hold-out*. Neste método são os dados separados em apenas dois subconjuntos, escolhidos aleatoriamente e mutualmente exclusivos, os quais serão utilizados para treinamento e teste da RNA. Porém dessa maneira, se ocorrer uma má divisão dos dados é possível que a rede neural não alcance um bom resultado.

Uma versão mais robusta desse método seria realizar a separação dos dados e o treinamento diversas vezes, porém, visto que a separação é aleatória, ainda assim é possível que alguns dados sejam usados apenas para treino e nunca para teste, assim como o contrário. Um outro método é a validação cruzada, aqui os dados são separados em n partes, onde, em cada ciclo da validação, todas menos uma serão utilizadas para o treinamento da rede neural enquanto a última será utilizada para a validação. Esse treinamento ocorre repetidamente, através de um loop, de forma que todas as n partes tenham sido utilizadas apenas uma vez como base de teste (McCaffrey, 2013).

3 MATERIAIS E MÉTODOS

No referencial teórico foram apresentados os artigos onde foram desenvolvidos alguns métodos para análise do sinal PPG, e, também, foi justificado porque o método que utiliza uma RNA, que tem como entrada os parâmetros obtidos com a FFT, foi o escolhido para o desenvolvimento deste projeto. Assim, neste será realizado o desenvolvimento de um sistema que aferirá a pressão arterial, pressão sistólica e diastólica, utilizando um sinal PPG como entrada. Esse sistema é composto de duas partes principais: a FFT e a RNA. A FFT é aplicada aos sinais de PPG, que possuem duração de um segundo cada, e estes servem de entrada para a RNA. Visto que o sinal precisa estar separado quando é alimentado ao código que treinará e testará a RNA, será necessário realizar uma filtragem e separação dos dados previamente ao treinamento da rede.

O desenvolvimento e a verificação dos resultados do projeto é dividido em 5 etapas, como mostra a Figura 13. A primeira etapa, que foi realizada junto com o desenvolvimento do referencial teórico, era o estudo de como estão os dados na base de dados para entender como utilizá-los. Foi necessário, também, realizar um curso sobre pesquisas utilizando recursos humanos. Esse treinamento foi pedido pelo criador do banco de dados para seu uso ser liberado. A segunda etapa foi a extração dos sinais utilizados do banco de dados. Essa etapa consistiu em obter os dados, em seguida realizar uma escolha manual dos sinais que tinham menos ruídos e interferências. Após essa primeira escolha, os sinais foram separados por segundo e relacionados com os valores de pressão arterial. As próximas duas etapas foram realizadas em conjunto, devido a aplicação da FFT suceder ao treinamento e teste da RNA. Por fim, foi realizada uma análise estatística entre os valores obtidos pela RNA e os dados reais retirados do banco de dados. Essa análise permite verificar se a rede possui resultados satisfatórios.

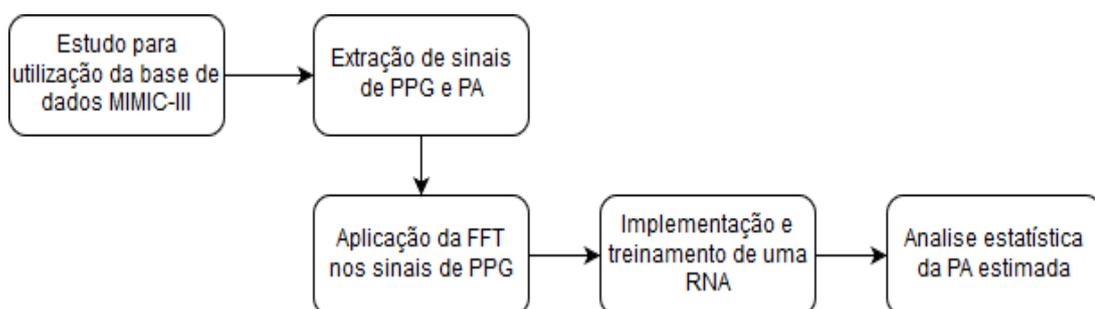


Figura 13 - Diagrama em blocos das etapas do projeto
Fonte: Autoria própria

3.1 MATERIAIS

O principal foco deste projeto foi o desenvolvimento de uma rede neural que utiliza sinais de PPG para aferir a pressão arterial de uma pessoa, assim a aquisição deste sinal foi utilizando o banco de dados MIMIC-II . Este banco de dados foi preenchido com informações desidentificadas de pacientes que estavam internados em unidades de cuidados intensivos do *Beth International Israel Deaconess Medical Center* entre 2001 e 2012. Os dados utilizados neste projeto foram salvos sem uma relação direta entre a pressão e o PPG, apenas contendo um valor de tempo atrelado a cada um. Dessa forma foi necessário fazer essa relação no decorrer do desenvolvimento do projeto. Os sinais PPG contidos no banco de dados MIMIC-II foram obtidos através de oxímetros de pulso comerciais, os quais foram filtrados e amplamente amplificados (Xing e Sun, 2016).

Foram desenvolvidos dois arquivos que realizaram as tarefas necessárias para a execução do projeto. Esses arquivos contêm os códigos na linguagem Python que foram responsáveis pela separação dos sinais, aplicação da FFT no sinal e a implementação da RNA. Essa linguagem foi escolhida devido a possuir bibliotecas de funções que facilitaram nas tarefas de aplicar a FFT em um determinado sinal e desenvolver e treinar a RNA. O projeto foi realizado no ambiente de desenvolvimento Spyder, desenvolvido pela empresa Anaconda Inc., utilizando a versão 2.7 da linguagem Python.

3.2 MÉTODOS

Uma vez que este projeto utiliza como base o trabalho realizado por Xing e Sun (2016), os métodos aqui empregados também usam como base os métodos do trabalho. Porém, algumas alterações foram feitas, visto que o propósito deste projeto é a aplicação dos conhecimentos obtidos durante a graduação e não o desenvolvimento de uma nova tecnologia que pode ser posteriormente comercializada. Por isso, muitas etapas foram realizadas manualmente, como a escolha dos dados e a “filtragem” destes.

3.2.1 Obtenção de Informações da Base de Dados MIMIC

Foram utilizados dados de apenas 16 pacientes que foram escolhidos manualmente através da ferramenta *PhysioBank* oferecida pela *Physionet*, que é a plataforma onde se encontram os dados do banco MIMIC. Com essa ferramenta é possível observar uma

representação gráfica dos sinais desejados de cada paciente e, portanto, escolher com mais precisão o conjunto de dados que melhor treinará a rede neural. Isso é necessário devido a dados imprecisos e incorretos não permitirem a rede neural a convergir durante seu treinamento. Em seguida, os dados foram salvos em arquivos separados por paciente para a realização de uma análise minuciosa de forma a remover dados errôneos, como valores aleatórios originados na movimentação do paciente, no sinal que foi obtido inicialmente pela MIMIC. Após essa análise, foram obtidos os intervalos de tempo, por paciente, que serão utilizados pelo primeiro código para separar e correlacionar a PA e o sinal PPG. É importante lembrar que o PPG é uma onda enquanto que a PA é uma dupla de valores para cada segundo, as pressões sistólica e diastólica, logo isto deve ser levado em consideração para a correta correlação entre os dados.

Após essa primeira etapa de escolha, os intervalos de tempo e os dados de cada paciente foram alimentados ao primeiro código que realizou o alinhamento entre a PA e o PPG, a separação em blocos de um segundo e a separação entre os conjuntos de treino e teste para a RNA. Essas informações foram salvas para em seguida serem alimentadas ao segundo código, responsável pela aplicação da FFT, o treinamento da RNA e a análise dos resultados obtidos. A separação levou em consideração três grupos de PA, pressão baixa, pressão normal e pressão alta, para que os conjuntos de treino e teste contivessem valores de todos os grupos. Estes conjuntos foram separados de forma que o treino ficou com 70% dos dados e o teste com os 30% restantes, sendo que esse agrupamento se deu seguindo a ordem que os dados foram obtidos na primeira parte da separação.

3.2.2 Transformada de Fourier do PPG

O sinal PPG possui um período variável em conjunto com a frequência dos batimentos cardíacos e uma rede neural precisa que seu número de pontos de entrada seja constante. Devido a isso, foi necessário encontrar uma maneira de separar o sinal PPG de forma a manter a duração de cada pedaço constante, sendo escolhida a separação do sinal em partes com duração de um segundo, porém isso causou o desalinhamento dos inícios e fins dos ciclos do PPG. Uma maneira encontrada de resolver esse novo problema foi de aplicar a FFT no sinal, visto que esta extrai as informações de frequência e amplitude do sinal. Assim, antes de informar os dados à rede, a FFT é aplicada em cada uma das porções de um segundo do PPG e, então, essa nova informação é utilizada para treinar e, posteriormente, testar a acurácia da rede.

Para a aplicação da FFT no sinal foi utilizada uma função auxiliar da biblioteca *numpy* do *python*, uma das bibliotecas disponíveis que visam facilitar o desenvolvimento de algoritmos em *python*. A função auxiliar escolhida foi no pacote *Discrete Fourier Transform*, que recebe como entrada o sinal ao qual desejasse aplicar a FFT e retorna os valores de frequência e amplitude referentes a entrada.

3.2.3 Desenvolvimento e treinamento de uma RNA

No artigo de Xing e Sun (2016) é implementada uma RNA do tipo MLP (*Multi-layer perceptron*), que é uma rede que possui camadas ocultas de neurônios, neste caso com apenas uma camada. Devido a isso, foram iniciados os testes com uma rede similar. Entretanto, neste contexto foi identificado que uma rede que possui duas camadas ocultas retornava resultados melhores. Esta rede será alimentada com as componentes da aplicação da FFT no sinal PPG e retornará os valores de pressão diastólica e sistólica equivalentes. Visto que a rede não servirá para classificar as informações em certos grupos, mas sim retornará os valores das pressões é necessária a utilização de uma MLP de regressão.

Devido à complexidade do desenvolvimento de uma RNA, aqui também foi utilizada uma biblioteca auxiliar, neste caso a biblioteca foi *sklearn* e o pacote *Neural network*. A MLP de regressão deste pacote foi desenvolvida utilizando um modelo que visa otimizar o erro ao quadrado aplicando um algoritmo de escolha entre o LBFGS (do inglês *Limited-memory BFGS*) e *stochastic gradient descent*. Testes mostraram que os melhores resultados foram obtidos utilizando o LBFGS, um otimizador da família dos métodos quase Newtonianos que visa realizar uma aproximação do algoritmo Broyden–Fletcher–Goldfarb–Shanno (BFGS) com uma quantidade limitada de memória computacional. O treinamento desta rede é realizado utilizando a retropropagação do erro com o algoritmo citado. A rede já possui no seu treinamento uma validação cruzada que foi utilizada separando 10% dos dados que serviram de treino para realizar a validação.

4 RESULTADOS

Durante o desenvolvimento do projeto foi possível notar que seriam necessárias alterações nas técnicas utilizadas por Xing e Sun (2016), visto que o conhecimento e materiais necessários para certas aplicações ainda não são foram obtidos. Desta maneira não foi possível realizar uma filtragem automatizada dos sinais puros retirados da base MIMIC, visto que o grande volume dos sinais requereria um computador potente e um longo período para a realização desta filtragem. Logo, os dados foram analisados manualmente utilizando a ferramenta disponível da Physionet, com a visualização gráfica, foi possível escolher os dados que possuíam menos distúrbios e interferências. Visto que esses dois interferem muito no resultado final obtido pela RNA, devido a serem dados que saem do padrão do sinal original.

A Figura 14 mostra como foram visualizados os gráficos que permitiram a escolha dos intervalos de cada paciente para um melhor treinamento da RNA. Com esses intervalos em mãos, foi iniciado o código que realizou a separação dos dados crus obtidos pelo Physiobank em dados filtrados para serem utilizados pela RNA. Como comentado, uma RNA precisa ter uma mesma quantidade de pontos de entrada para seu correto funcionamento, assim, é necessário uma segmentação do sinal PPG original em partes menores com um número fixo de pontos. Devido a variação na forma de onda e na duração do período dos sinais obtidos não foi possível fazer uma divisão utilizando o tal período como parâmetro. Apesar disso, uma outra solução encontrada foi de separar esse sinal em porções de um segundo de duração, o que equivalia a 125 pontos.

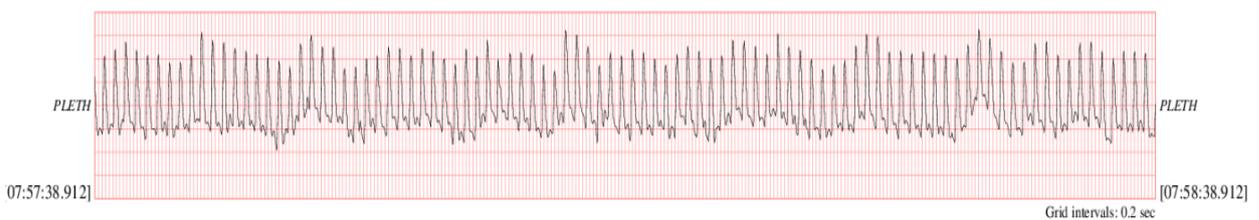


Figura 14 - Gráfico de um dos intervalos de PPG utilizados
Fonte: PhysioBank ATM

O código de separação realiza a leitura do dado cru e remove valores NaN (do inglês Not a Number) enquanto separa os intervalos de um segundo para cada paciente. Essa segmentação foi realizada pelo código visto na Figura 15, que percorria cada um dos

intervalos informados e verificava se o valor instantâneo era um número. Em caso afirmativo, esse valor era adicionado a um vetor auxiliar, enquanto não completasse um segundo, e quando completasse, era adicionado a matriz de PPG. Em caso negativo, era pulado o valor.

```

while y < yfim and z < zfim:
    if ('-' in dadosBP['ABP Sys'][z]) or ('-' in dadosBP['BP Dias'][z]):
        z = z + 1
        if z == zfim:
            break
        while float(dadosPLETH['Elapsed time'][y]) < float(dadosBP['    Elapsed
time'][z]):
            y = y + 1
            if y == yfim:
                break
            elif '-' in dadosPLETH['PLETH'][y]:
                aux = []
                y = y+1
            else:
                if float(dadosPLETH['Elapsed time'][y]) < (float(dadosBP['    Elapsed
time'][z])+1):
                    aux.append(float(dadosPLETH['PLETH'][y]))
                    y = y+1
                else:
                    if len(aux) > 100:
                        dadosP.append(aux)
                        dadosBS.append(float(dadosBP['ABP Sys'][z]))
                        dadosBD.append(float(dadosBP['BP Dias'][z]))
                    z = z + 1
                    aux = []

```

Figura 15 - Trecho de código para separação dos dados

Fonte: Autoria própria

Esse método de segmentação apresenta um problema, visto que o sinal não se encaixa perfeitamente nesse segundo, acabou que o início do bloco não equivale necessariamente ao início do período do sinal e é possível que existam mais de um ciclo por bloco. Apesar disso, ao aplicar a FFT essa variação acaba não interferindo tanto no resultado, visto que os valores de frequência e amplitude das componentes do sinal não dependem da parte em que o sinal é analisado. Assim foi possível ter um número finito de pontos enquanto tem-se valores consistentes para a entrada da RNA.

Outro possível problema que pode ocorrer nas RNAs é o fenômeno de over-fitting, o que levam elas a terem resultados excelentes quando lidam com suas bases de treino, mas que oferecem resultados medíocres quando entram em contato com dados nunca antes visto. Para verificar isso, neste projeto foi realizada a validação cruzada dos dados, com a técnica de separar o conjunto total em dois subconjuntos, um que é utilizado para o treinamento e outro

que é utilizado para a verificação da acurácia da rede. Além disso, devido a maneira que foi desenvolvida a rede neural utilizada, o subconjunto de treino é separado uma segunda vez para realizar a validação interna da rede. Esta segunda separação pega 10% dos valores de treino para realizar a validação.

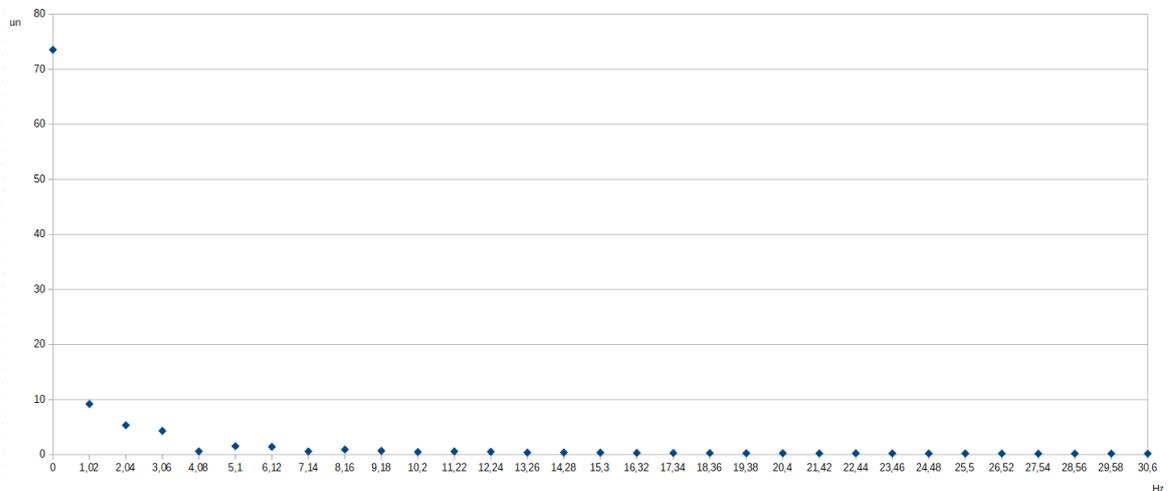


Figura 16 - Sinal PPG após aplicada a FFT, módulos das componentes

Fonte: Autoria própria

Essa separação dos dados entre grupos de treino e teste precisou que, primeiramente, as pressões fossem classificadas em altas, baixas e normais. A classificação levou em conta que uma pressão alta equivale à sua pressão sistólica ser maior que 130 mmHg e a diastólica, maior que 85 mmHg. Na pressão baixa esses valores são menores que 100 mmHg e 60mmHg, respectivamente, e a pressão normal são os valores no meio (HALL e GUYTON, 2016). Em seguida, são selecionados 70% de cada grupo para fazer parte do conjunto de treino, enquanto os outros 30% vão para o conjunto de teste. Tendo esses dados separados em seus respectivos conjuntos, o código da rede neural lerá cada um dos arquivos, aplicará a FFT para cada bloco e pegará o módulo de cada valor, visto que a rede neural do projeto precisa de valores reais para seu correto funcionamento, juntando essas informações em 4 matrizes, 2 de entrada, as porções do sinal PPG, e 2 de saída, os valores de PA referentes as entradas.

Um exemplo dos sinais obtidos pode ser observado na Figura 16. As matrizes de entrada recebem os módulos da FFT para cada bloco e as matrizes de saída recebem os valores de pressões sistólica e diastólica equivalentes para cada entrada. A aplicação da FFT foi realizada como se pode ver no código da Figura 17. Durante os testes do projeto, foi possível identificar que as componentes iniciais da FFT eram as que melhor treinavam a

RNA. Assim, o trecho de código que aplicava a FFT nos dados inseria apenas as 25 primeiras componentes na matriz de entrada. Porém, antes de alimentar a rede com os valores obtidos foi realizada uma normalização dos valores de entrada desses primeiras componentes.

```
for x in np.arange(0, len(entradaTreino)):
    dt = np.fft.fft(entradaTreino.iloc[[x]][cols])
    blood.append([int(saidaTreino['D'][x]), int(saidaTreino['S'][x])])
    aux=[]
    for i in dt[0][0:25]:
        y = round(abs(i), 2)
        aux.append(y)
    pleth.append(aux)
```

Figura 17 - Trecho do código para a aplicação da FFT no sinal PPG no grupo de treinamento

Fonte: Autoria própria

Tendo as matrizes prontas, foi realizado o treinamento da rede e em seguida a análise dos resultados com o conjunto de teste. Para a RNA, como comentado anteriormente, foi utilizada a função pronta *MLPRegressor* da biblioteca *sklearn*. Os hiperparâmetros, que podem ser vistos na Figura 18, definem como ela vai funcionar. Para este projeto, os melhores resultados foram obtidos utilizando uma RNA com duas camadas ocultas de neurônios, sendo a primeira com 40 neurônios e a segunda com 20, uma validação cruzada que separava 10% dos dados de treino para realizar a validação, uma função de ativação do tipo logística e o otimizador de erro LBFGS.

```
from sklearn.neural_network import MLPRegressor

rede = MLPRegressor(hidden_layer_sizes = (40,20), activation='logistic',
                    solver='lbfgs', alpha=0.0001, early_stopping=True,
                    validation_fraction=0.1)
```

Figura 18 - Trecho do código de definição da RNA

Fonte: Autoria própria

Após o treinamento, o cálculo dos erros foi realizado comparando os resultados previstos pela RNA com os valores reais retirados da base de dados. Como visto na Figura 19, foi calculado o erro percentual entre cada dupla (valor real x valor estimado), sendo feito individualmente o erro para a pressão sistólica e para a diastólica. Por fim, é realizada a média desses erros e seus desvios padrões, que destinaram-se a um melhor entendimento da capacidade de aferir uma correta pressão arterial da RNA. Na Figura 20 é possível visualizar a comparação entre os valores estimados e reais que permitiu o cálculo dos erros individuais

para cada uma das entradas do conjunto de teste, o que sinaliza que, apesar de terem casos onde o erro é elevado, na sua maioria os resultados aferidos pela rede foram precisos.

```

pred = rede.predict(inDataTeste)
for x in np.arange(0, len(pred)):
    predD.append(round(pred[x][0], 2))
    predS.append(round(pred[x][1], 2))
    erroD = 100 * ((outDataTeste[x][0] - round(pred[x][0], 2)) / outDataTeste[x][0])
    erroS = 100 * ((outDataTeste[x][1] - round(pred[x][1], 2)) / outDataTeste[x][1])
    MAED.append(abs(erroD))
    MAES.append(abs(erroS))

maed = round(np.mean(MAED), 2)
maes = round(np.mean(MAES), 2)
for x in np.arange(0, len(MAED)):
    erroD = MAED[x] - maed
    RMSED.append((erroD * erroD))
    erroS = MAES[x] - maes
    RMSES.append((erroS * erroS))

rmsed = round(math.sqrt(np.mean(RMSED)), 2)
rmseS = round(math.sqrt(np.mean(RMSES)), 2)

```

Figura 19 - Trecho do código para o cálculo dos erros entre os resultados obtidos e os valores reais

Fonte: Autoria própria

Os erros obtidos pelos cálculos foram de $4,06\% \pm 2,24\%$ para a pressão diastólica e $3,79\% \pm 1,98\%$ para a sistólica, sendo estes valores a média e o desvio padrão dos erros de cada pressão. Esses valores representam a porcentagem de erro em relação ao valor real da

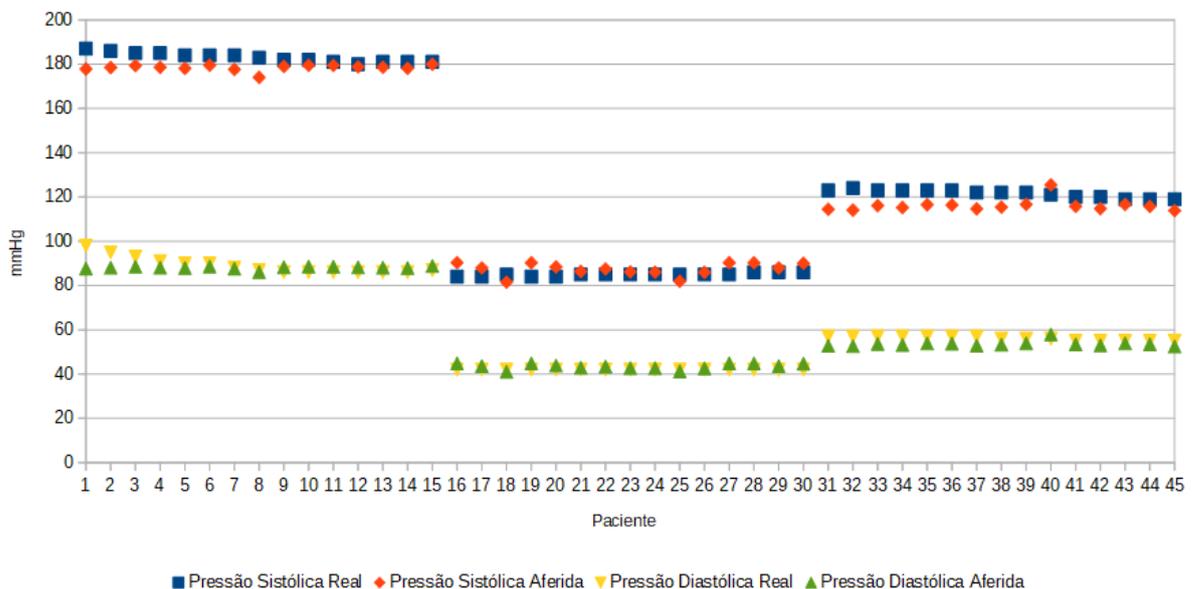


Figura 20 - Representação gráfica dos valores reais X aferidos

Fonte: Autoria própria

pressão arterial. Os valores baixos dos desvios padrões obtidos indicam que a rede está sendo mais precisa ao aferir os resultados. E com a média baixa verifica-se que a maioria dos resultados obtidos foram próximos aos valores esperados.

5 CONCLUSÃO

Após a análise dos dados foi possível verificar que realizar a aferição da pressão arterial através de uma rede neural alimentada pelos descritivos de Fourier é uma tarefa plausível. Porém alguns objetivos não foram alcançados, como o desenvolvimento de um algoritmo para a extração dos dados do banco de dados, visto que a comunicação com o banco se dá apenas pela internet, já que o volume de dados disponível no banco é muito grande para obter uma cópia local. Devido a isso, o conhecimento para desenvolver um código que realize a comunicação *online* com o banco ainda não havia sido adquirido. Além disto, o grande número de dados com distúrbios levou a não ser possível a realização de uma filtragem automatizada, devido a serem dados sem padrão algum para serem removidos através de código.

Como a análise dos erros mostrou que existem casos que o resultado ainda é distante do esperado, seria interessante, em estudos futuros, realizar uma análise mais aprofundada do sinal de PPG e suas componentes, como o valor RMS, valor médio e pico a pico, para tentar obter resultados mais precisos. Além disso, também seria válido realizar uma filtragem automatizada anterior a segmentação dos dados de forma que distúrbios e interferências não sejam inclusos no treinamento da RNA.

REFERÊNCIAS

AMERICAN COLLEGE OF CLINICAL ENGINEERS. **About ACCE**. 2015. Disponível em: < <http://accenet.org/about/Pages/ClinicalEngineer.aspx> >. Acesso em: 16 mai. 2017.

ASSOCIATION FOR THE ADVANCEMENT OF MEDICAL INSTRUMENTATION. **American National Standard For Electronic or Automated Sphygmomanometers Washington**, 1987.

BADNJEVIC, Almir; GURBETA, Lejla. **Development and Perspectives of Biomedical Engineering in South East European Countries**. In: Information and Communication Technology, Electronics and Microelectronics (MIPRO), 39th International Convention, p.457-460, 2016.

CARDIAC SCIENCES PROGRAM. **Holter Monitoring**, 2016. Disponível em: <http://www.umanitoba.ca/medicine/units/cardiac_sciences/holterinfo.htm>. Acesso em: 09 jun. 2017.

CHEN, Zhihao; YANG, Xiufeng; TEO, Ju Teng; HUAT, Soon. **Noninvasive Monitoring of Blood Pressure Using Optical Ballistocardiography and Photoplethysmograph Approaches**. In: 35th Annual International Conference of the IEEE EMBS, p.2425-2428, 2013.

CHEN, Chen-Huan; NEVO, Erez; FETICS, Barry; PAK, Peter H.; YIN, Frank CP; MAUGHAN, W. Lowell; KASS, David A. **Estimation of central aortic pressure waveform by mathematical transformation of radial tonometry pressure**. *Circulação* 95, n.7, p.1827-1836, abr. 1997.

CHUA, Eric Chern-Pin; REDMOND, Stephen J.; MCDARBY, Gary; HENEGHAN, Conor. Towards using photo-plethysmogram amplitude to measure blood pressure during sleep. **Annals of biomedical engineering**, v.38, n.3, p.945-954, 2010.

DUTT, D. Narayana; SHRUTHI, S. **Digital processing of ECG and PPG signals for study of arterial parameters for cardiovascular risk assessment**. In: International Conference on Communication and Signal Processing (ICCSP), p.1506-1510, 2015.

DUTRA, Oscar P. **II Diretriz Brasileira De Cardiopatia Grave**, v.87, n.2, agosto 2006.

EMERGO. **Brazil ANVISA Medical Device Classification Consulting**, 2018. Disponível em: <<https://www.emergogroup.com/services/brazil/anvisa-classification>> Acesso em: 23 mar. 2018.

GAURAV, Aman; MAHEEDHAR, Maram; TIWARI, Vijay N.; NARAYANAN, Rangavittal. **Cuff-Less PPG based Continuous Blood Pressure Monitoring – A Smartphone based Approach**. In: Annual International Conference of the Engineering in Medicine and Biology Society (EMBC), p.607-610, 2016.

GLICOMED. **Aparelho de pressão Arterial Esfigmomanômetro Fecho em Velcro com Estetoscópio**. 2017. Disponível em: <<http://www.telediu.com.br/produto/37/aparelho-de-pressao-arterial-esfigmomanometro-fecho-em-velcro-com-estetoscopio>> Acesso em: 31 mai. 2017.

G-TECH. **Aparelho de Pressão Digital de Pulso G-Tech Master BP3AF1-3**. 2017. Disponível em: <<http://www.fibracirurgica.com.br/aparelho-de-pressao-digital-de-pulso-master-bp3af1-3/p>> Acesso em: 30 mai. 2017.

HALL, John E.; GUYTON, Arthur C. **Textbook of Medical Physiology**. 13 ed. Philadelphia: Elsevier, 2016.

HAYKIN, SIMON S. **Redes Neurais**. 2 ed. Bookman Companhia Ed. 2001.

INTROCASO, Luiz. História da medida da pressão arterial. **HiperAtivo**, v.5, n.2, abril/junho 1998, p.79-82.

JOHNSON, A. E. W.; POLLARD, T. J.; SHEN, L; LEHMAN, L; FENG, M; GHASSEMI, M; MOODY, B; SZOLOVITS, P; CELI, LA; MARK, RG. MIMIC-III, a freely accessible critical care database. **Scientific Data**. 2016. Disponível em: <<http://www.nature.com/articles/sdata201635>> Acesso em: 20 mar. 2017.

KOHLMANN, Nárcia Elisa Bellucci; KOHLMANN JUNIOR, Osvaldo. Histórico e perspectivas da medida da pressão arterial. **Revista Hipertensão**, v.14, n.2, setembro/outubro 2011, p.5-13.

KURYLYAK, Yuriy; LAMONACA, Francesco; GRIMALDI, Domenico. **A neural network-based method for continuous blood pressure estimation from a PPG signal**. In: IEEE International Instrumentation and Measurement Technology Conference (I2MTC), p. 280-283, 2013.

LUGONES, Ignacio. **Estenosis Valvular Aórtica**. 2017. Disponível em: <<http://cardiocongenitas.com.ar/cardiopatias-congenitas/estenosis-valvular-aortica.php>> Acesso em: 30 mai. 2017.

MAGJAREVIC, Ratko; DIAZ, Martha L. Zequera. **Biomedical engineering education – Status and perspectives**. In: Engineering in Medicine and Biology Society (EMBC), 36th Annual International Conference of the IEEE, p.5149-5152, 2014.

McCaffrey, James. **Understanding and Using K-Fold Cross-Validation for Neural Networks**. In: Visual Studio magazine, neural network lab, 2013.

McCombie, Devin B.; REISNER, Andrew T.; ASADA, H. Harry. **Adaptive blood pressure estimation from wearable PPG sensors using peripheral artery pulse wave velocity measurements and multi-channel blind identification of local arterial dynamics**. In: Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE, p.3521-3524, 2006.

MONSEIN, Lee H. **Primer on Medical Device Regulation, Part I. History and Background**. Radiology, e. 205, p.1-9, 1997.

RASCHKA, Sebastian; MIRJALINI, Vahid. **Python Machine Learning**. 2 ed. Birmingham: Packt Publishing Ltd., 2017.

RELVAS, Carlos. **Validação Cruzada (Cross Validation)**, 2015. Disponível em: <<http://dsdoportuga.blogspot.com/2015/06/validacao-cruzada-cross-validation.html>>. Acesso em: 12 jun. 2018.

SAHOO, Ashima; MANIMEGALAI, P; THANUSHKODI, K. **Wavelet based pulse rate and blood pressure estimation system from ECG and PPG signals.** In: International Conference on Computer, Communication and Electrical Technology (ICCET2011), p.285-289, 2011.

SMITH, Steven W. **Digital Signal Processing.** Burlington: Elsevier, 2003.

SOCIEDADE BRASILEIRA DE HIPERTENSÃO. **O que é hipertensão.** Disponível em: <<http://www.sbh.org.br/geral/oque-e-hipertensao.asp>>. Acesso em: 20 mar. 2017.

SOCIEDADE BRASILEIRA DE HIPERTENSÃO. **Curso de medida da pressão arterial.** Disponível em: <<http://www.sbh.org.br/curso2015/2-2-2.php>>. Acesso em: 09 jun. 2017.

SOLTANE, Mohamed; ISMAIL, Mahamod; RASHID, Zainol Abidin Abdul. Artificial Neural Networks (ANN) Approach to PPG Signal Classification. **International Journal of Computing & Information Sciences**, v.2, n.1, p.58-65, 2004.

SOUSA, Ana Luiza Lima; JARDIM, Paulo César Brandão Veiga; MENDONÇA, Brunella Chinem; JARDIM, Thiago de Souza Veiga; BARROSO, Weimar K.S.; RODRIGES, Rafaela Bernardes; CARNEIRO, Sergio Baiocchi. Medida Casual da pressão arterial: vantagens e desvantagens no diagnóstico e tratamento da hipertensão arterial. **Revista Hipertensão**, v.14, n.2, setembro/outubro 2011, p.5-13.

SOUZA, Rodrigo. **MAPA e HOLTER, para que servem?** Disponível em: <<http://www.drrodrigossouza.com.br/mapa-e-holter-para-que-servem/>>. Acesso em: 25 mai. 2017.

SUN, J. X.; REISNER, A. T.; Mark, R. G. A signal abnormality index for arterial blood pressure waveforms. **Proceedings of IEEE Conference on Computers in Cardiology**, 2006, p.13–16.

TEB. **O que é um bom eletrocardiógrafo?** 2017. Disponível em: <<http://www.teb.com.br/o-que-e-um-bom-eletrocardiografo/>>. Acesso em: 16 mai. 2017.

Teng, X. F., and Y. T. Zhang. Continuous and noninvasive estimation of arterial blood pressure using a photoplethysmographic approach. **Proceedings of the 25th Annual International Conference of the IEEE**, v.4, p.3153-3156, 2003.

WEEKS, Michael. **Processamento Digital de Sinais utilizando Matlab e Wavelets**, 2 ed. Rio de Janeiro: LTC.

WORLD HEALTH ORGANIZATION. **Top 10 causes of death**. Boletim Informativo, Jan. 2017. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs310/en/>>. Acesso em: 27 abr. 2017.

XING, Xiaoman; SUN, Mingshan. Optical blood pressure estimation with photoplethysmography and FFT-based neural networks. **Biomedical Optics Express**, v.7, n.8, p.3007-3020, 2016.