



Universidade Federal de Campina Grande - UFCG
Centro de Engenharia Elétrica e Informática - CEEI
Departamento de Engenharia Elétrica - DEE

Luis Alberto Souto Maior Neto

**Desenvolvimento de Sistema para Detecção de Arritmias
Cardíacas para Auxílio ao Diagnóstico Médico à Distância**

Campina Grande, Paraíba

Abril de 2017

Luis Alberto Souto Maior Neto

Desenvolvimento de Sistema para Detecção de Arritmias Cardíacas para Auxílio ao Diagnóstico Médico à Distância

Relatório do Estágio Supervisionado realizado no NUTES - UEPB, apresentado à Coordenação do Curso de Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande como parte dos requisitos necessários para a obtenção do grau de Bacharel em Engenharia Elétrica.

Universidade Federal de Campina Grande - UFCG
Centro de Engenharia Elétrica e Informática - CEEI
Departamento de Engenharia Elétrica - DEE

Orientador: Prof. Dra. Luciana Ribeiro Veloso (UFCG)

Campina Grande, Paraíba
Abril de 2017

Luis Alberto Souto Maior Neto

Desenvolvimento de Sistema para Detecção de Arritmias Cardíacas para Auxílio ao Diagnóstico Médico à Distância/ Luis Alberto Souto Maior Neto. – Campina Grande, Paraíba, Abril de 2017

35 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Dra. Luciana Ribeiro Veloso (UFCG)

Relatório de Estágio Supervisionado
, Abril de 2017.

1. Redes Neurais. 2. Eletrocardiografia. 2. Processamento de Sinais. I. Universidade Federal de Campina Grande. II. Departamento de Engenharia Elétrica. III. Desenvolvimento de Sistema para Detecção de Arritmias Cardíacas para Auxílio ao Diagnóstico Médico à Distância

Luis Alberto Souto Maior Neto

Desenvolvimento de Sistema para Detecção de Arritmias Cardíacas para Auxílio ao Diagnóstico Médico à Distância

Relatório do Estágio Supervisionado realizado no NUTES - UEPB, apresentado à Coordenação do Curso de Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande como parte dos requisitos necessários para a obtenção do grau de Bacharel em Engenharia Elétrica.

Trabalho aprovado em ____/____/_____

Prof. Dra. Luciana Ribeiro Veloso
Universidade Federal de Campina Grande

Prof. Dr. Edmar Candeia Gurjão
Universidade Federal de Campina Grande

Campina Grande, Paraíba
Abril de 2017

Agradecimentos

À minha família, meu pai Roberto, minha mãe Maria Esther (*in memoriam*), e minha irmã Marília, por sempre terem me apoiado e dado educação em toda a minha vida, dádivas imensuráveis.

À minha namorada Ingrid, por ter sempre ficado ao meu lado e me dado forças para ficar em pé em todos os momentos de fraqueza.

Aos meus amigos Luiz Neto, Matheus Augusto, Arthur, Fábio, Germano e Danilo pela ajuda em abrir minha mente para a vida, o universo e tudo mais.

Aos professores que tive durante minha vida, por me darem a oportunidade de aprender.

Aos funcionários Tchaikowsky e Adail que, sem eles, teria uma família a menos.

À música, por ser capaz de me compreender.

E à oportunidade de ser e de existir.

*“ We live together, we act on, and react to, one another; but always and in all circumstances we are by ourselves. The martyrs go hand in hand into the arena; they are crucified alone. Embraced, the lovers desperately try to fuse their insulated ecstasies into a single self-transcendence; in vain. By its very nature every embodied spirit is doomed to suffer and enjoy in solitude. Sensations, feelings, insights, fancies - all these are private and, except through symbols and at second hand, incommunicable. We can pool information about experiences, but never the experiences themselves.
(Aldous Huxley, "The Doors of Perception")*

Resumo

Eletrocardiografia (ECG) é um exame médico que faz uso de sinais elétricos captados na pele de um paciente. O diagnóstico de doenças cardíacas é mais comumente realizado pelo ECG, porém este exame é consistentemente demorado e requer grande expertise médica para ser realizado. Em cidades do interior do nordeste, existe uma falta de profissionais capazes de realizar diagnósticos em ECG. Em situações de emergência, a insuficiência destes profissionais acarreta em atrasos na diagnose, o que pode gerar um risco à vida dos pacientes. Para resolver este problema, este trabalho, realizado durante o estágio no NUTES - UEPB, propõe um sistema móvel para auxiliar o diagnóstico médico de ECG, chamado de IDAH-ECG. O IDAH-ECG consiste de um sistema de aquisição a partir de um dispositivo de ECG portátil, de um sistema de servidor na nuvem para registro dos dados do exame e de um sistema de detecção de arritmias nos sinais cardíacos. Este trabalho foca no sistema detector de arritmias, que faz uso de técnicas de processamento de sinais como transformadas wavelet discretas (DWT), filtro de resposta finita (FIR), análise de componentes principais (PCA) e redes neurais artificiais para segmentação e classificação dos batimentos dos exames entre normais e arrítmicos. Após o treinamento da rede usando o banco de dados MIT-BIH Arrhythmia Database e um processo de validação cruzada ten-fold e Monte Carlo, obteve-se resultados de acurácia de 96,48% e sensibilidade de 98,7%, próximos aos do estado da arte.

Palavras-chave: processamento digital de sinais. engenharia biomédica. aprendizado de máquina. eletrocardiografia. redes neurais artificiais

Abstract

Electrocardiography (ECG) is a kind of medical exam that makes use of electric signals captures from a patient's skin. Physicians diagnose cardiac diseases most often using ECG, although ECG diagnosis is known to be time consuming and to require strong medical expertise. At northeastern Brazil, in inland cities, there is a lack of medical professionals to supply the healthcare demand on ECG examinations. In emergency situations, the lack of medical specialists can lead to delay in proper clinical examination and, thus, proper diagnosis and treatment, putting patient lives in risk. In order to solve this issue, in this work accomplished at NUTES - UEPB as part of a mandatory undergraduate internship, we propose a tool named Intelligent Detection of Arrhythmic Heartbeats on ECG, or IDAH-ECG, which consists of a system comprised of modules for portable ECG exam acquisition, server monitoring, cloud-based signal processing, and short message service (SMS) notification. The system makes use of a portable ECG device to capture the ECG signal during an examination, uploads the exams to a server, which proceeds to process the signals and to distinguish arrhythmic heartbeats from healthy, or normal ones. Upon detection of any abnormalities, a SMS is sent to available medical professionals in the area, which then can use the message to access the cloud-based database of examinations, evaluate the acquired examination and then promptly decide how to proceed with the patient. This document focuses on the signal processing aspect of the system which makes use of Finite Impulse Response and Discrete Wavelet Filtering, Principal Component Analysis and Artificial Neural Networks to accomplish arrhythmia detection with accuracy of 96.48%, sensitivity of 98.7%, using ten-fold cross-validation and Monte Carlo testing over the MIT-BIH Arrhythmia Database.

Keywords: digital signal processing. biomedical engineering. machine learning. electrocardiography. artificial neural networks.

Lista de ilustrações

Figura 1 – A arquitetura do sistema IDAH-ECG	15
Figura 2 – Dispositivo TEB ECG PC	16
Figura 3 – Visão geral dos caminhos de processamento tomados para as várias arquiteturas de pré-processamento usadas neste trabalho	17
Figura 4 – Exemplo de sinal ECG	19
Figura 5 – Processo de segmentar um batimento	20
Figura 6 – Exemplo de sinal sendo filtrado pelo filtro FIR: Sinal original (cima) e sinal filtrado (baixo)	20
Figura 7 – Exemplo de sinal sendo filtrado pela DWT proposta	22
Figura 8 – Esquema do processo de transformada DWT.	23
Figura 9 – Exemplo do resultado da PCA para um subconjunto dos dados	25
Figura 10 – Estrutura de uma Rede Neural	25
Figura 11 – Visão geral do processo de validação cruzada <i>10-fold</i> com teste de Monte Carlo	28
Figura 12 – Esquema do Submódulo em funcionamento	31
Figura 13 – Interface gráfica do protótipo	32

Lista de tabelas

Tabela 1 – Matriz Eliminadora	23
Tabela 2 – Sumário dos nomes dos Arranjos	29
Tabela 3 – Resultados de cada Arranjo	29
Tabela 4 – Comparação entre os resultados obtidos e os encontrados na literatura	29

Lista de abreviaturas e siglas

ECG	Eletrocardiografia
IDAH-ECG	Detector inteligente de batimentos arrítmicos em ECGs <i>Intelligent Detection of Arrhythmic Heartbeats on Electrocardiograms</i>
ABNT	Associação Brasileira de Normas Técnicas
MLP	Perceptron de Múltiplas Camadas
FIR	Filtro a Resposta de Impulso Finita
DWT	Transformada Discreta de Wavelet
PCA	Análise de Componentes Principais
PSF	Programa Saúde da Família
SAMU	Serviço de Atendimento Móvel de Urgência
NUTES	Núcleo de Tecnologias Estratégicas em Saúde
UEPB	Universidade Estadual da Paraíba
USB	<i>Universal Serial Bus</i>
SMS	<i>Short Message Service</i>
WAV	Decomposição DWT
MITDB	<i>MIT-BIH Arrhythmia Database</i>
FFT	<i>Fast Fourier Transform</i>
MSE	Erro médio quadrático (<i>Média squared error</i>)
Acc	Acurácia
Sen	Sensitividade
Spe	Especificidade
Ppr	Valor preditivo positivo

Sumário

1	INTRODUÇÃO	13
2	DESCRIÇÃO DO SISTEMA	15
3	SUBMÓDULO DE ASSISTÊNCIA MÉDICA	17
3.1	Banco de Dados	17
3.2	Pré-processamento	18
3.2.1	Redução de Ruídos	18
3.2.1.1	Filtro FIR	19
3.2.1.2	Filtragem DWT	21
3.2.2	Extração de Características	22
3.2.2.1	Decimação utilizando a DWT (WAV)	23
3.2.2.2	Análise de Componentes Principais (PCA)	24
3.3	Rede Neural Artificial (RNA)	25
3.4	Procedimento Experimental	26
3.4.1	Métricas	26
3.4.2	Validação Cruzada <i>10-fold</i> e teste Monte Carlo	28
4	RESULTADOS	29
5	DISCUSSÃO DO EXPERIMENTO	30
6	PROTÓTIPO DO SUBMÓDULO COM INTERFACE GRÁFICA	31
7	CONCLUSÃO	33
	REFERÊNCIAS	34

1 Introdução

Doenças cardiovasculares são a causa do maior número de mortes naturais no mundo, de acordo com a Organização Mundial de Saúde (OMS, 2016). A doença cardiovascular mais comum é a desritmia cardíaca, também conhecida como arritmia. Arritmias são doenças nas quais os batimentos cardíacos de uma pessoa acontecem de forma não-natural ou não saudável. A forma mais comum de detectar e analisar arritmias é através do uso de eletrocardiografia.

Eletrocardiogramas ou eletrocardiografias (ECGs) são um tipo de exame médico indolor e não-invasivo que consiste na captura dos sinais elétricos gerados na pele de um indivíduo graças aos gradientes elétricos provocados pelos batimentos cardíacos. A partir de uma análise visual do sinal de ECG é possível identificar alguns problemas cardíacos. Este procedimento, no entanto, deve ser realizado por um especialista médico ou por um enfermeiro treinado, e, por ser a norma em exames clínicos e emergenciais, acaba se tornando demorado pois os especialistas tem de observar um número grande de sinais de vários eletrodos ao mesmo tempo diariamente, fato que aumenta o risco de erros na diagnose.

Além disso, nas cidades do interior do Brasil, a falta de especialistas médicos capazes de realizar estes exames e de suprir esta demanda é um problema real. Programas populares como o Programa Saúde da Família (PSF) e o Serviço de Atendimento Móvel de Urgência (SAMU) que oferecem serviços de tratamento ambulatorio e emergencial, respectivamente, estão espalhados pelas cidades interioranas, porém seu contingente de profissionais médicos não é o suficiente para suprir esta demanda. Por isso, é necessário a criação de sistemas que diminuam a necessidade de se precisar de especialistas ativamente realizando estes exames que são de extrema importância, para todo caso de urgência e emergência da cidade. O maior problema, no entanto, é a necessidade de que exista, em prontidão, um especialista capaz de diagnosticar os pacientes em tempo.

No estágio realizado no NUTES - Núcleo de Tecnologias Estratégicas em Saúde, supervisionado pelo professor Dr. Robson Pequeno e em conjunto com o grupo do Laboratório de Análise de Imagens e Sinais (LAIS), foi desenvolvido um sistema portátil e conectado na nuvem para aquisição, armazenamento, detecção e notificação de sinais e arritmias cardíacas. Neste trabalho, este projeto será apresentado e discutido. O sistema envolve as etapas de aquisição a partir de um módulo de ECG portátil, uma histórico médico eletrônico na nuvem, um detector de arritmias cardíacas baseado em redes neurais artificiais (um dos tipos de classificadores de batimentos cardíacos e arritmias mais utilizados na literatura (JAMBUKIA; DABHI; PRAJAPATI, 2015)), e um sistema de

notificação aos profissionais e especialistas médicos através de serviço de mensagem SMS.

Após a aquisição dos dados, o sistema os analisa os dados e notifica um especialista acessível através de mensagens SMS, que contém um link para uma página na qual ele pode acessar os dados do paciente bem como os sinais do exame de ECG para, enfim, diagnosticar remotamente o paciente. Caso o sistema de detecção de arritmias detecte positivamente uma anormalidade no exame, o médico é devidamente informado no ato da mensagem, com a intenção de diminuir os riscos existentes no diagnóstico atrasado e também de reduzir a necessidade de especialistas estarem sempre em prontidão e de se locomoverem até o local do exame para realizar o diagnóstico.

Este relatório focará no desenvolvimento do sistema de detecção de arritmias cardíacas, denominado de *Intelligent Detection of Arrhythmic Heartbeats on Electrocardiograms* (IDAH-ECG), especificamente nos aspectos de processamento de sinal e de classificação, visto que restante do sistema desenvolvido foi abordado em uma publicação anterior (PEQUENO et al., 2015). O sistema de classificação de batimentos ou detecção arritmias usa uma rede neural do tipo perceptron de múltiplas camadas (MLP), que classifica os batimentos cardíacos individuais em normais ou anormais. Técnicas como o uso de filtro de resposta ao impulso finita (FIR), transformada discreta de Wavelet (DWT) foram usadas para redução de ruídos. A DWT também foi usada para extração de características e redução de dimensionalidade, em adição à análise de componentes principais (PCA). O banco de dados utilizado nestes estudos foi o MIT-BIH Arrhythmia Database (MITDB), e o sistema IDAH-ECG foi testado e validado usando um sistema de validação cruzada do tipo 10-fold, com teste de Monte Carlo.

Estrutura do Documento

Este documento está organizado da seguinte forma. O capítulo 2 descreve o sistema geral e os módulos individuais. No capítulo 3, o submódulo de assistência médica que realiza o processamento e classificação é descrito, incluindo a descrição: do banco de dados; dos sistemas de pré-processamento para redução de ruídos usando FIR, DWT e SWT; das técnicas de redução de dimensionalidade e extração de características que usam DWT e PCA; do classificador de batimentos cardíacos propriamente dito usando redes neurais artificiais; e do processo de treinamento, teste e validação cruzada. No capítulo 4 e 5 são mostrados, respectivamente, os resultados dos experimentos e a discussão dos mesmos. No capítulo 6, um protótipo do software projetado para visualização e demonstração é apresentado. Finalmente, no capítulo 6 é dada a conclusão que pode ser obtida com este trabalho.

2 Descrição do Sistema

O sistema IDAH-ECG consiste de quatro módulos principais: o módulo especialista, o módulo portátil, o módulo do servidor e o submódulo de assistência médica (incorporado no módulo do servidor), conforme é ilustrado na Figura 1. O módulo portátil é um software que foi desenvolvido e é capaz de ser instalado em computadores notebooks ou tablets Windows e é responsável pela aquisição dos dados de ECG através da compatibilidade com dispositivos ECG com comunicação USB, como o TEB ECG PC (Figura 2) que será utilizado para realizar o exame. Os dados coletados são enviados para o módulo do servidor, localizado "na nuvem" em um servidor no NUTES ou no hospital no qual sistema será integrado. Estes dados são devidamente armazenados no histórico do paciente, que são cadastrados previamente ou após o exame. Os dados são acessíveis através do módulo especialista, que consiste em uma interface web acessível por qualquer dispositivo portátil, como um smartphone ou um computador. Os dados do paciente são imediatamente acessíveis e são apresentados em uma interface bem estruturada e intuitiva para o médico especialista. (PEQUENO et al., 2015)

Figura 1 – A arquitetura do sistema IDAH-ECG

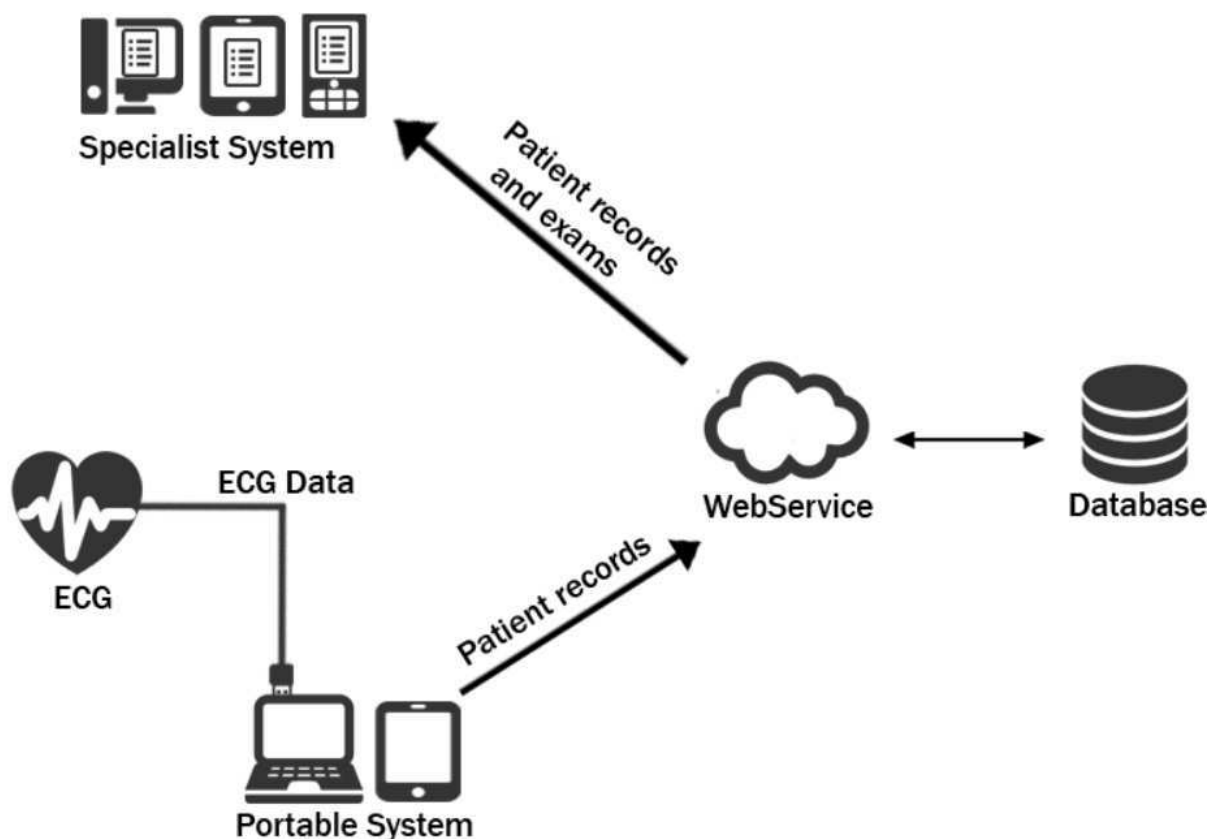


Figura 2 – Dispositivo TEB ECG PC



3 Submódulo de Assistência Médica

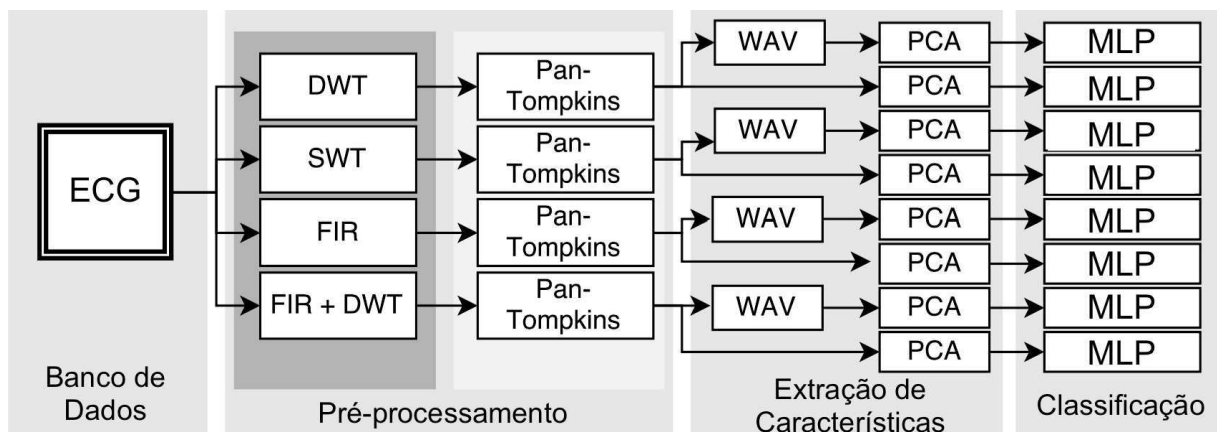
O submódulo de assistência médica está presente no módulo do servidor e é o responsável por pré-diagnosticar os exames de forma a notificar o médico assim que qualquer anormalidade ou indício de arritmia for detectado. É importante salientar que este sistema não foi criado com a intenção de substituir o diagnóstico final, apenas de auxiliá-lo fazendo com que os exames denotados como suspeitos ou anormais sejam imediatamente verificados, porém garantindo ainda que todos os exames, notificados ou não, serão diagnosticados manualmente pelo especialista. Este tipo de processo é chamado de telemedicina e torna todo o processo de diagnose comprovadamente mais rápido, como denotado por (HSIEH; LO, 2009). Neste capítulo, todo o processo usado no desenvolvimento deste submódulo é apresentado.

3.1 Banco de Dados

O treinamento supervisionado de redes neurais artificiais requer um banco de dados robusto e compatível com a aplicação. Neste projeto, após a pesquisa literária, foi selecionado o banco de dados MITDB (GOLDBERGER et al., 2000) por ser um banco de dados confiável e amplamente utilizado, fato que facilita a comparação do algoritmo implementado com o existente no estado da arte. O MITDB possui informações detalhadas sobre cada exame realizado, sobre cada paciente e também sobre cada batimento individual, oferecendo uma ferramenta de alto valor para procedimentos de classificação supervisionada como o desenvolvido neste trabalho.

O MITDB consiste em 48 pares de sinais de ECG gravados em exames de 30 minutos de duração, amostrados a uma taxa de 360 Hz. Cada um destes pares de sinais

Figura 3 – Visão geral dos caminhos de processamento tomados para as várias arquiteturas de pré-processamento usadas neste trabalho



foi obtido a partir de exames individuais realizados em pacientes distintos, sendo que cada componente do par de sinais representa um sinal obtido por um eletrodo diferente. Dos 48 pares de sinais, 8 continham informações de eletrodos não consistentes com o resto dos sinais, portanto estes foram eliminados neste estudo. Apenas os pares contendo dados dos eletrodos MLII e V1 foram usados, que representa um total 40 pares de sinais dentre todos os pares do MITDB.

3.2 Pré-processamento

A figura 3 representa uma visão geral do procedimento realizado para treinar a rede neural, sendo que cada ramo representa um caminho de pré-processamento distinto. O procedimento pode ser resumido da seguinte forma:

1. Os sinais são obtidos do MITDB e armazenados;
2. Os sinais filtrados para redução de ruído, utilizando 2 métodos diferentes (DWT, FIR) em paralelo;
3. Cada saída de cada método de redução de ruído passa por uma etapa de detecção de picos, para separar os batimentos individuais e formar um conjunto de batimentos cardíacos;
4. O conjunto de batimentos individuais passa por um processo de extração de características e redução de dimensionalidade; e
5. Cada conjunto de dados resultante é separado em conjunto de treino, testes e validação para o treinamento de rede neural. A saída da rede neural é 0 para batimentos normais ou 1 para batimentos arrítmicos.

3.2.1 Redução de Ruídos

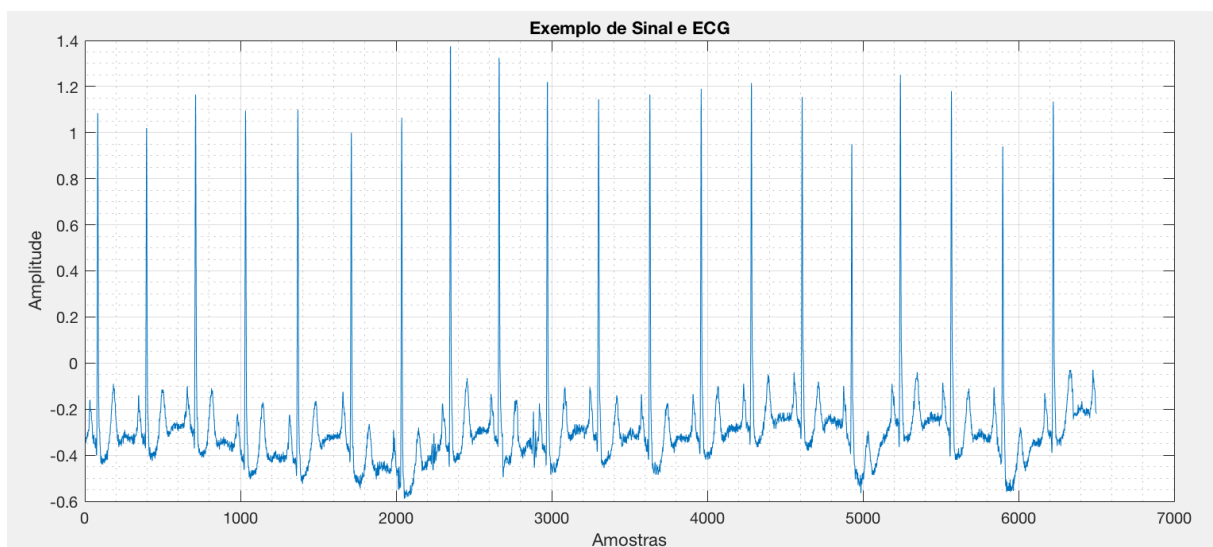
Os exames de ECG possuem um problema fundamental que é a necessidade de eliminar ou reduzir ruídos não-desejáveis ou anormalidades que podem comprometer a integridade dos sinais a serem analisados. Nos sinais de ECG, estes ruídos e suas fontes são bem conhecidas e a sua não eliminação pode interferir no processo de classificação destes sinais. Os tipos de ruídos mais importantes nos exames de ECG são os ruídos de baixa frequência graças ao movimento do eletrodo no paciente (respiração, movimentos musculares, etc), que acarretam em mudanças na impedância dos eletrodos. Estes ruídos são chamados de '*baseline wandering*' ou 'devaneios de base', por serem de muito baixa frequência, acarretando no que aparenta ser um nível DC variando pouco com o tempo. Outros ruídos comuns são os provenientes da interferência da rede (60 Hz) e ruídos estáticos

e de ambiente. O processo de reduzir ruídos pode ser abordado com o uso de filtragem espectral ou filtragem no domínio da frequência.

Neste projeto, cada um dos 40 pares de sinais (totalizando $2 \times 40 = 80$ sinais no final) foram processados usando diferentes filtros, explicados nas seções seguintes. Após a filtragem, os sinais passam por um algoritmo de detecção de picos de batimentos, chamado de algoritmo Pan-Tompkins (PAN; TOMPKINS, 1985). Este algoritmo permite a detecção dos picos QRS dos sinais de ECG, que são as características mais evidentes e centrais de um batimento. Após se obter os dados dos picos QRS, uma janela arbitrária de 200 amostras (99 antes e 100 depois do pico) foi utilizada para segmentar cada batimento individual, formando, no final, um banco de batimentos em pares (um para cada eletrodo). Além disso, como o MITDB provê uma lista de informações para cada batimento já pré-segmentado, estas informações foram referenciadas aos batimentos segmentados usando o algoritmo implementado, de forma a se obter um conjunto de dados Batimentos x Classes dos batimentos, como requisitado em qualquer algoritmo de classificação supervisionada.

Um exemplo de sinal do MITDB é ilustrado na Figura 4. Uma ilustração de um processo de segmentação é mostrado na Figura 5.

Figura 4 – Exemplo de sinal ECG



3.2.1.1 Filtro FIR

Um filtro de resposta finita ao impulso, ou *Finite Impulse Response* (FIR), foi desenvolvido graças à sua facilidade de implementação, além do seu uso amplo na literatura. O sinal foi filtrado por um filtro FIR passa-faixa de ordem 90, com frequências de corte de 5 Hz e 15 Hz. O atraso de resposta linear foi contabilizado como sendo de 90 amostras. Este procedimento foi capaz de eliminar boa parte do *baseline wandering* e também de suavizar o sinal. A Figura 6 mostra um exemplo deste processo.

Figura 5 – Processo de segmentar um batimento





Figura 6 – Exemplo de sinal sendo filtrado pelo filtro FIR: Sinal original (cima) e sinal filtrado (baixo)



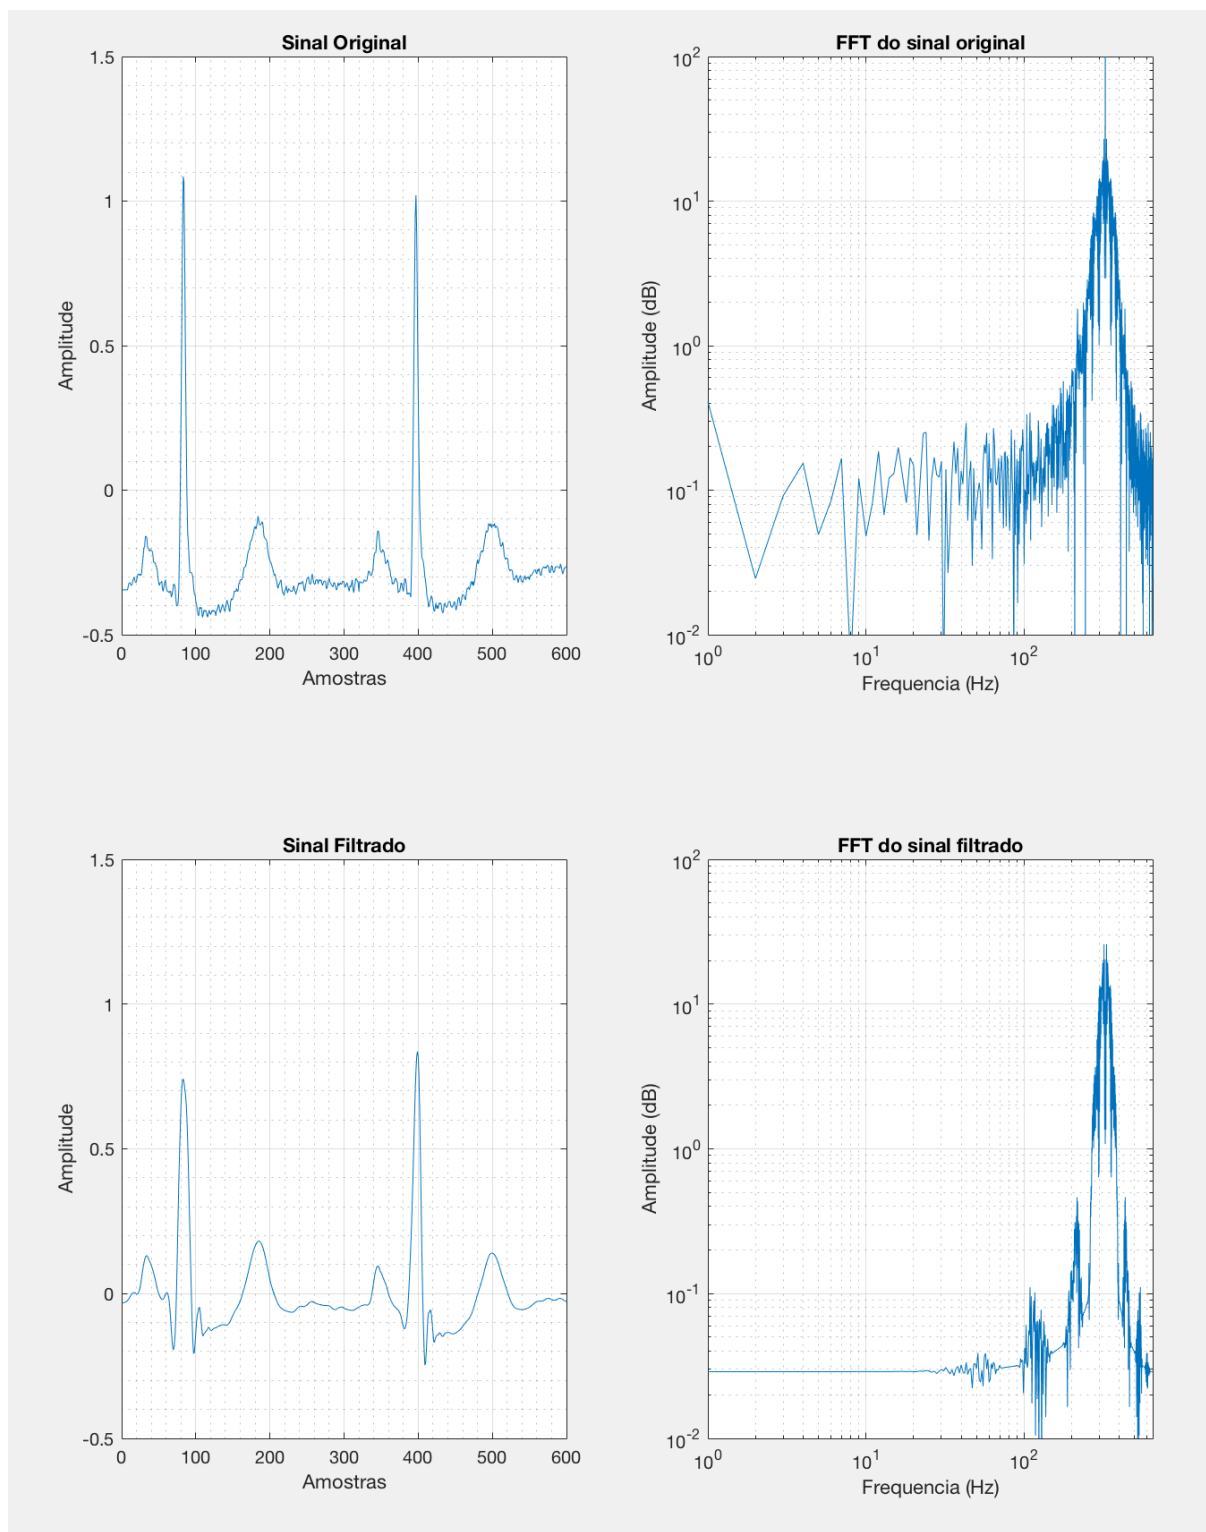
3.2.1.2 Filtragem DWT

A filtragem usando a transformada Discreta de Wavelet, ou *Discrete Wavelet Transform* (DWT), é amplamente utilizada na literatura, e seu esquema está ilustrado na figura 3. A transformada DWT é uma ferramenta de análise multiresolucional que provê informação do sinal temporal e em frequência ao mesmo tempo, sem necessitar de grandes recursos de processamento computacional. A DWT consiste em aplicar uma sequência de filtros meia-banda passa-baixas e passa-altas e depois subamostrar o sinal em um fator de 2, resultando em um par de sinais filtrados, um contendo informações de baixas e outro de altas frequências, cada um com metade da faixa de frequências do sinal original. As saídas dos ramos de passa altas são chamadas de detalhes e as saídas dos ramos de passa baixas são chamadas de aproximações. A ordem da DWT corresponde ao número de vezes ou iterações que processo que é realizado, sempre tomando como entrada atual a saída (coeficientes de aproximação ou detalhe) da iteração anterior. É possível reconstruir um sinal no domínio do DWT a partir da transformada inversa de DWT. Ao se eliminar as componentes de determinados níveis da DWT, é possível efetivamente filtrar aquelas componentes de alta ou baixa frequência, ao reconstruir o sinal aplicando a transformada inversa sucessivamente. Este processo é chamado de filtragem DWT e é muito utilizado na literatura para eliminar ruídos de sinais de ECG, graças à sua boa especificidade nas gamas de frequência a serem eliminadas. A Figura 8 mostra como a decomposição funciona de forma mais visual e intuitiva.

Um filtro DWT do tipo Daubechies 6 (db6) de ordem 9 foi implementado. O sinal original do MITDB, amostrado em uma frequência de 360 Hz foi transformado, portanto, 9 vezes pela DWT. Os coeficientes de detalhes de ordem 9 e de aproximação de ordem 2 e 3 no processo de reconstrução foram eliminados. Assim, as frequências às de 360-359,639 Hz (detalhes de ordem 9) e as frequências de 0-360 Hz, 90-180 Hz e 45-90 Hz, correspondendo a, respectivamente, os detalhes de ordem 1, 2 e 3, podem ser eliminados do sinal. Este processo se dá, no código, através de uma "matriz eliminadora", que contém elementos 1 ou 0 a serem multiplicados pelos coeficientes. Ou seja, por exemplo, caso os coeficientes de detalhe de primeira ordem devam ser eliminados, o elemento da posição da linha 1 e coluna 2 da matriz deve ser 0, pois este será multiplicado pelo vetor de coeficientes de detalhe da primeira ordem do sinal processado.

A [Figura 7](#) mostra uma passagem de filtragem wavelet com estas exatas especificações. A matriz de eliminação é mostrada na tabela [Tabela 1](#).

Figura 7 – Exemplo de sinal sendo filtrado pela DWT proposta



3.2.2 Extração de Características

Em posse de um banco limpo e robusto de batimentos cardíacos, com cada batimento sendo representado por um array de 400 elementos (200 para cada sinal de eletrodo), o

Figura 8 – Esquema do processo de transformada DWT.

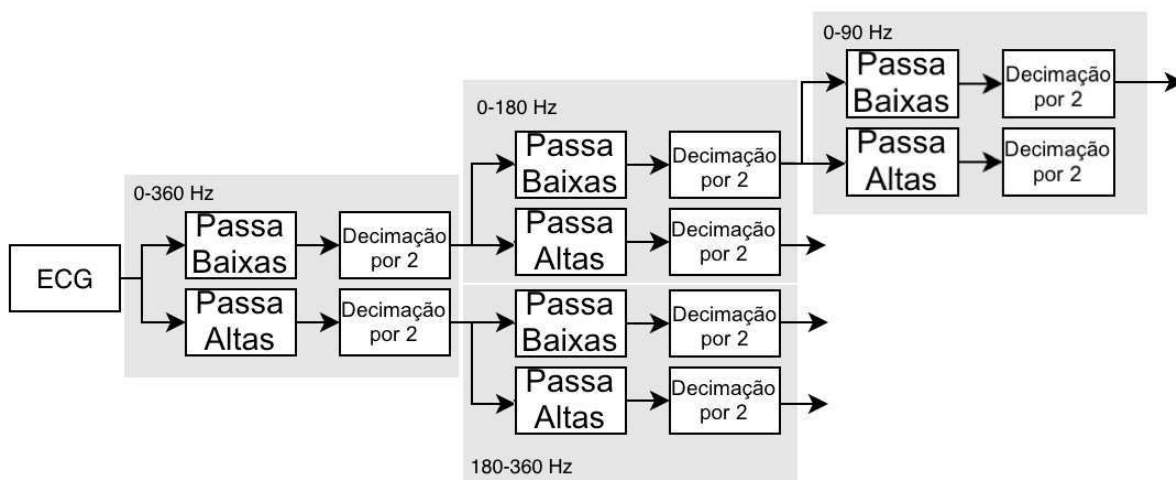


Tabela 1 – Matriz Eliminadora

Aproximação	Detalhe
1	0
1	0
1	0
1	1
1	1
1	1
1	1
1	1
0	1

próximo passo é a extração de características. Esse passo é necessário para reduzir o tempo de treinamento do classificador ao reduzir redundâncias nos atributos das entradas da rede neural. Nas subseções a seguir, as técnicas de decimação DWT e análise de componentes principais (PCA) usadas neste trabalho serão abordadas.

3.2.2.1 Decimação utilizando a DWT (WAV)

A decimação DWT (WAV) faz uso da transformada DWT, porém difere da técnica de filtragem previamente discutida pois, ao invés de remover as componentes de aproximação e detalhe e depois reconstruir o sinal resultante, a decimação DWT mantém o sinal sem reconstruí-lo. Isto permite que o sinal resultante no domínio DWT seja menor, pois cada eliminação dos parâmetros reduzirá drasticamente a quantidade de amostras do sinal e, desde que a informação importante seja retida, a quantidade de dados será reduzida sem que haja impacto negativo na convergência do treino da rede neural.

Uma transformada wavelet DWT do tipo Mayer's foi aplicada no sinal e seus coeficientes de aproximação e detalhes de quarto grau foram retidos, eliminando todos

os outros coeficientes. Isto se deu pois as componentes que estes coeficientes representam estão entre 0 e 22.5 Hz, e foi comprovado na literatura ([MARTIS; ACHARYA; MIN, 2013](#)) que estas frequências retêm a maior parte da variância nos sinais de ECG. As saídas foram reduzidas de 400 elementos para 56 com este processo.

3.2.2.2 Análise de Componentes Principais (PCA)


Análise de componentes principais é uma técnica de redução de dimensionalidade que faz uso da auto-decomposição da matriz de covariância de um conjunto de dados. Ao ordenar a matriz dos autovalores da matriz de covariância em ordem decendente, guarda-se os números das linhas e colunas da matriz de covariância original e se obtém uma matriz diagonal. Esta matriz pode ser utilizada para se calcular a distribuição de energia de cada componente dos sinais, ao somar as primeiras N componentes da matriz e dividir o resultado por N. A técnica PCA usa um valor limiar, no caso deste trabalho de 99%, para determinar quais componentes retêm a maior parte da variância no banco de dados original. Utilizando um algoritmo simples, pôde-se determinar quais componentes do sinal original retêm 99% da variância, tornando possível eliminar todas as outras componentes de menor importância. A matriz dos autovalores pode ser truncada para este propósito, de forma a se obter uma matriz de projeção a ser multiplicada pela matriz do banco de dados original. Esta multiplicação resulta em um banco significativamente menor, porém que retém 99% da variância do banco original. O processo é melhor descrito em ([MARTIS et al., 2012](#)).

No caso dos conjunto de batimentos cardíacos aqui trabalhado, este processo foi realizado e a PCA resultou em uma redução de 400 amostra para 26 amostras quando aplicada sobre o conjunto que não passou por decimação DWT mas passou por filtro FIR, e para 33 amostras quando passou pelo filtro DWT. O mesmo processo foi aplicado no conjunto que passou por decimação DWT, resultando em uma redução de 56 amostras para de 17 e 21 amostras, respectivamente para filtragem FIR e DWT.

A [subseção 3.2.2.2](#) mostra como o processo de PCA foi capaz de separar os dados. Esta figura representa as três primeiras componentes de cada batimento plotadas uma com relação às outras. Desta forma, é possível visualizar, ao pintar cada ponto da cor da classe que se sabe de cada batimento, como é o arranjo das classes perante suas dimensões internas. Para uma rede neural ser treinável com um banco de dados, é preciso que o banco seja separável nas dimensões de seus vetores por um hiperplano, de forma que as classes sejam separadas uma em cada lado do plano. Pode-se observar na imagem que claramente existe dois conjuntos de classes, cada um agrupado em uma região do espaço aqui plotado. Os pontos azuis correspondem aos batimentos normais e os pontos verdes e vermelhos, a batimentos arrítmicos e anômalos. Este passo de visualização é importante para determinar se o PCA está realmente funcionando, se foi devidamente implementado,

e se terá uso prático para a situação.


Figura 9 – Exemplo do resultado da PCA para um subconjunto dos dados



3.3 Rede Neural Artificial (RNA)

Redes Neurais Artificiais (RNA) são algoritmos computacionais baseados em algoritmos de otimização. A rede neural mais simples é a do tipo perceptron (ROSENBLATT, 1961), composta por apenas um neurônio. O neurônio é um elemento composto por uma soma ponderada aplicada a uma função qualquer $f(x)$, chamada de função de ativação. Uma rede neural pode ser simplificada por $Y = f(W * X)$, onde Y é o vetor de saída, W é a matriz de pesos e X é o vetor de entradas. O objetivo fundamental de uma rede

Figura 10 – Estrutura de uma Rede Neural



neural é minimizar uma função de erro $E(W, X, T)$, onde T é o vetor de saídas desejadas (alvos), procedimento comumente chamado de treinamento da rede neural. A função de erro pode ser definida, por exemplo, pelo erro médio quadrático $E = MSE = \frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2$, onde t_i e y_i são as i -ésimas amostras dos vetores alvo T e saídas Y . Para minimizar esta função, é necessário alterar os valores dos pesos W da soma ponderada. O algoritmo mais utilizado para alterar os pesos é chamado de retro-propagação do erro através do método da gradiente descendente. Este método consiste em calcular o vetor gradiente da função erro com relação a todos os pesos da rede, de forma a achar a direção no espaço de pesos na qual a função aumentará. Assim, ao subtrair este vetor, multiplicado por uma constante (constante de treinamento), do vetor de pesos original, traz-se o vetor de pesos para uma posição no espaço multidimensional na qual a função de erro é reduzida.

O perceptron de múltiplas camadas (MLP) funciona da mesma forma, porém várias camadas de redes neurais são sobrepostas, considerando a saída da primeira igual à entrada da próxima e assim por diante. A configuração mais comum é um trio de camadas, denominadas camada de entrada, camada escondida e camada de saída. O número de neurônios nas camadas de entrada e de saída dependem do número de entradas e saídas desejadas para a aplicação. Redes neurais de múltiplas camadas são comumente utilizadas em tarefas de segmentação, classificação, detecção, extração de características, reconhecimento de padrões, dentre outros. Na Figura 10, é ilustrada uma rede neural de forma genérica (BISHOP, 2006).

Uma rede MLP com 25 neurônios na camada escondida e 1 na camada de entrada foi implementada em MATLAB. O número de neurônios na camada escondida foi determinado empiricamente e não foi alterado desde o começo dos testes, com a finalidade de comparar cada filtro e extrator de características. A rede foi treinada usando o algoritmo de retropropagação com o método do gradiente descendente (coeficiente μ igual a 0.001), com as entradas sendo as saídas do extrator de características descrito acima, ou seja, com um número entre 17 e 33 entradas no total. A saída da rede neural foi treinada para ser 0 quando o batimento é normal e 1 quando ele é anormal.

3.4 Procedimento Experimental

3.4.1 Métricas

Como o MITDB contém informação do tempo e da classe do batimento, estas informações foram usadas para medir a performance do classificador. Uma saída 0 é chamada de saída negativa, e significa um batimento normal. Uma saída 1 é chamada de positiva e corresponde a um batimento anormal. Um bom resultado de classificação seria tal que, para cada batimento classificado como anormal (positivo), quando procurado no banco do MITDB, sua classe também seja anormal (positiva). Esta possibilidade se

chama de resultado verdadeiro positivo, e a contagem de verdadeiros positivos é chamada da variável TP . De forma similar, se o batimento é classificado como normal (negativo), e o batimento no MITDB também for normal, isso seria um verdadeiro negativo, e sua contagem seria dada pela variável TN . Por outro lado, quando cada situação destas resulta em um erro em comparação ao MITDB, os resultados são chamados de falso positivo e falso negativo, e a sua soma é dada pelas variáveis equivalentes (FP) e (FN).

No Brasil, a norma ABNT NBR IEC 60601-1-51:2005 (ABNT, 2005) prevê o uso destas variáveis aliadas a outros parâmetros para determinar a qualidade do algoritmo de classificação de arritmias. Os parâmetros são:

- Acurácia (Acc)
- Sensitividade (Sen)
- Especificidade (Spe)
- Valor preditivo positivo (Ppr)

Estes parâmetros são definidos da seguinte forma:

$$N = TP + TN + FP + FN \quad (3.1)$$

$$Ne = FP + FN \quad (3.2)$$

$$Acc = \frac{N - Ne}{N} \quad (3.3)$$

$$Sen = \frac{TP}{TP + FN} \quad (3.4)$$

$$Spe = \frac{TN}{TN + FP} \quad (3.5)$$

$$Ppr = \frac{TP}{TP + FP} \quad (3.6)$$

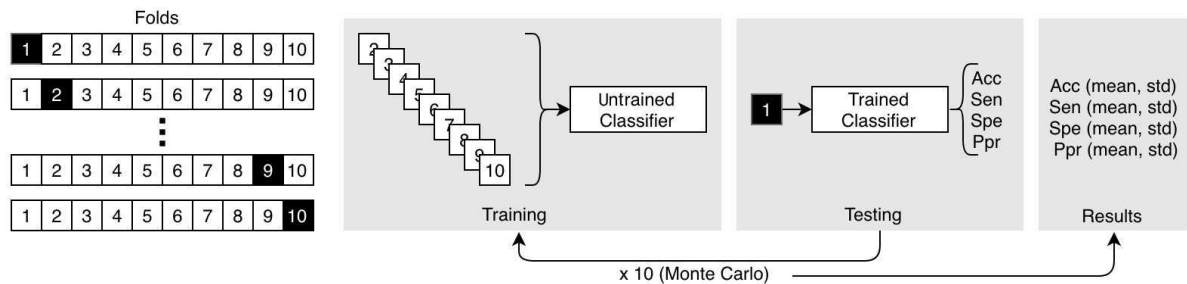
onde N é o número total de batimentos no teste e Ne , o número de erros de classificação. É importante notar que o parâmetro mais importante para a aplicação deste projeto é a sensitividade, pois ela representa a precisão na detecção de sinais anormais quando eles são, de fato, anormais. Ou seja, ela medirá a capacidade do algoritmo de prover uma pré-diagnose e detectar anormalidades nos exames.

3.4.2 Validação Cruzada *10-fold* e teste Monte Carlo

Para treinar a rede neural, um esquema de validação cruzada *10-fold* e teste Monte Carlo foi implementado. O esquema consiste em usar um número (arbitrado como 20000) de batimentos de cada classe (anormal e normal) do banco de dados completo, depois separar estes batimentos em 10 partes iguais. Um algoritmo recursivo opera treinando a rede com 9 destas partes e testando-a com a parte restante. A recursividade acontece de forma que este processo repete-se 10 vezes, cada vez treinando com 9 partes e testando com a parte que sobra, até que todas as partes tenham sido usadas para teste. Isto foi feito garantindo que o algoritmo nunca usasse como conjunto de treino o mesmo que o usado para teste, evitando, assim, *overfitting* no treinamento da rede. a Figura 11 abaixo mostra uma iteração deste processo.

Um teste Monte Carlo foi realizado, de forma que este processo de validação cruzada foi efetuado 10 vezes. As médias e desvios padrões de cada parâmetro Acc, Sen, Spe, Ppr, foram calculados e armazenados.

Figura 11 – Visão geral do processo de validação cruzada *10-fold* com teste de Monte Carlo



4 Resultados

Tabela 2 – Sumário dos nomes dos Arranjos

Nome	Técnica de Redução de Ruídos	Extrator de Características
FIRPCA	Filtro FIR	Apenas PCA
FIRWAV	Filtro FIR	DWT + PCA
DWTPCA	Filtro DWT	Apenas PCA
DWTWAV	Filtro DWT	DWT + PCA

Tabela 3 – Resultados de cada Arranjo

Nome	Acc (%)		Sen (%)		Spe (%)		Ppr (%)	
	<i>Média</i>	<i>Erro Padrão</i>	<i>Média</i>	<i>Erro Padrão</i>	<i>Média</i>	<i>Erro Padrão</i>	<i>Média</i>	<i>Erro Padrão</i>
FIRPCA	96.48	00.64	98.70	00.56	94.45	00.84	94.19	00.91
FIRWAV	96.34	00.79	98.61	00.74	94.28	00.92	94.01	00.98
DWTPCA	95.94	01.18	98.17	01.26	93.92	01.16	93.65	01.20
DWTWAV	95.78	01.01	98.21	01.04	93.58	01.04	93.26	01.10

A Tabela 2 mostra um sumário de todos os esquemas de pre-processamento usados neste trabalho, onde todas as siglas são definidas, totalizando 4 esquemas diferentes. Os resultados dos experimentos são apresentados na Tabela 3.

Os resultados do experimento indicam que o melhor arranjo foi o FIRPCA, obtendo uma acurácia média de 96,48% e sensibilidade média de 98,7%. Os métodos que fazem uso de redução de dimensionalidade PCA tiveram performance superior aos demais, porém obtiveram no geral um maior desvio padrão da média.

A Tabela 4 mostra uma comparação entre os resultados do estudo feito aqui com resultados do estado da arte (ASL; SETAREHDAN; MOHEBBI, 2016), (YE; COIMBRA; KUMAR, 2010), (GÜLER; ÜBEYLİ, 2005), (YU; CHEN, 2007).

Tabela 4 – Comparação entre os resultados obtidos e os encontrados na literatura

Método	Acc Média	Sen Média
Song et al.	98.7%	99.5%
Ye et al.	96.5%	98.7%
FIRPCA (autor)	96.5%	98.7%
Yu and Chou	95.4%	96.9%
Guler and Ubeyli	89.1%	93.2%
Yu and Chen	81.1%	85.2%

5 Discussão do Experimento

Este trabalho focou na comparação dos diferentes métodos de processamento de sinais de ECG para se obter um detector de arritmia confiável. Como o objetivo do projeto é usar um algoritmo que seja capaz de detectar problemas ou anormalidades para que um médico seja imediatamente notificado, o parâmetro mais importante para a determinação da qualidade do algoritmo é a sensibilidade (Sen), pois esta determina a porcentagem dos acertos de batimentos anormais perante todos os erros e acertos de batimentos anormais. Resultados mostraram que o algoritmo treinado obteve performance próxima ao estado da arte. Os resultados mostraram também que o esquema que fez uso do filtro FIR foram os que obtiveram maiores sensibilidades, portanto este deverá ser utilizado na aplicação. Os algoritmos que fizeram uso de redução de dimensionalidade com PCA obtiveram melhor performance possivelmente por conta da redução nas redundâncias dos conjuntos de dados, o que fez com que a rede neural fosse treinada com dados mais separáveis.

6 Protótipo do Submódulo com Interface Gráfica

Nesta seção, será apresentada uma interface que foi desenvolvida para testar a rede neural e o sistema de pré-processamento em tempo real. Um diagrama simplificado do funcionamento do software é mostrado na [Figura 12](#).

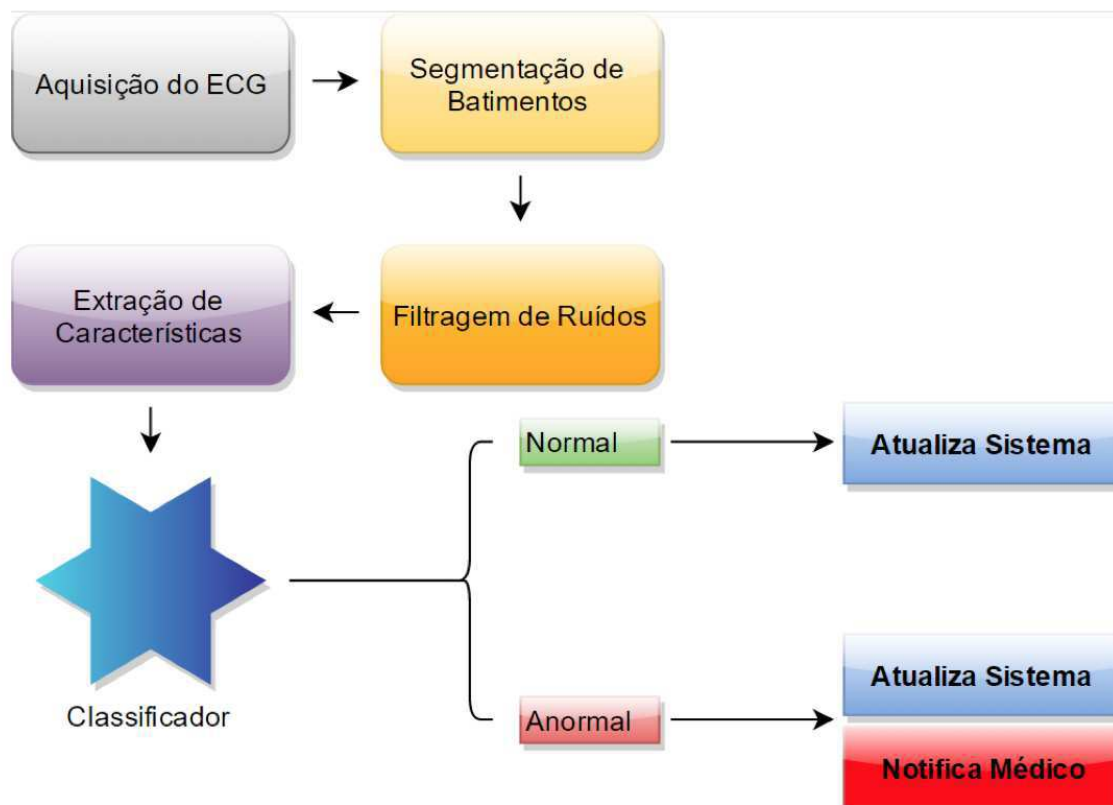


Figura 12 – Esquema do Submódulo em funcionamento

O software foi implementado em MATLAB e uma interface gráfica foi criada para fácil visualização do mesmo ([Figura 13](#)). O software consiste na captura de sinais crus aleatórios provenientes do banco MITDB. A cada 3600 amostras (10 segundos de aquisição), o número de batimentos classificados é contado e, caso haja um batimento classificado como anormal, o programa emite um aviso, a ser utilizado pelo sistema do IDAH-ECG para notificação do médico ou enfermeiro especialista.

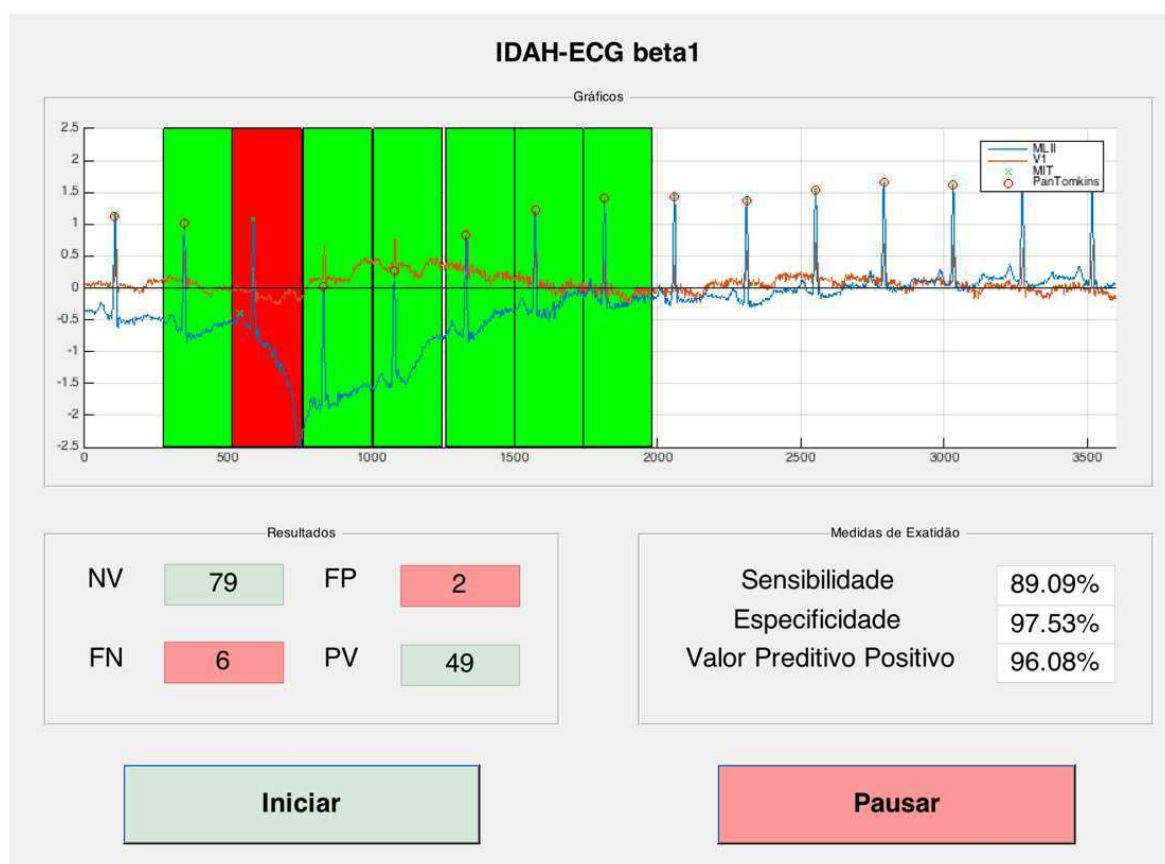


Figura 13 – Interface gráfica do protótipo

7 Conclusão

Neste trabalho, o trabalho realizado durante o estágio no Núcleo de Tecnologias Estratégicas em Saúde - NUTES foi apresentado, consistindo em um sistema de auxílio ao diagnóstico médico emergencial na detecção de arritmias cardíacas. Foi mostrada uma visão geral do sistema, chamado de *Intelligent Detection of Arrhythmic Heartbeats* (IDAH-ECG), que foca em solucionar o problema da escassez de profissionais capazes de realizar a função de diagnosticar problemas cardíacos através do exame de ECG em cidades do interior do Brasil.

O foco do trabalho foi no submódulo de assistência médica, o que representa o processamento dos sinais de ECG e classificação e segmentação dos batimentos cardíacos. Através do uso do banco de dados MIT-BIH Arrhythmia Database, foi possível quantizar a performance do submódulo e se obteve um coeficiente de sensibilidade de 98,7%, próximo ao do estado da arte. No entanto, a acurácia do classificador ainda pode ser melhorada com o uso de análise multi-patologias, por exemplo, pois o classificador aqui estudado foi treinado apenas para classificar batimentos normais de batimentos anormais, e não entre as múltiplas patologias cardíacas conhecidas na medicina moderna.

Referências

- ABNT. *Norma Técnica ABNT NBR IEC 60601-2-51:2005*. 2005. Disponível em: <<http://www.abntcatalogo.com.br/norma.aspx?ID=1613>>. Acesso em: 21 mar 2017. Citado na página 27.
- ASL, B. M.; SETAREHDAN, S. K.; MOHEBBI, M. Support vector machine-based arrhythmia classification using reduced features of heart rate variability signal. *Artificial Intelligence in Medicine*, Elsevier, v. 44, n. 1, p. 51–64, 04 2016. ISSN 0933-3657. Disponível em: <<http://dx.doi.org/10.1016/j.artmed.2008.04.007>>. Citado na página 29.
- BISHOP, C. M. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN 0387310738. Citado na página 26.
- GOLDBERGER, A. L. et al. Physiobank, physiotoolkit, and physionet: Components of a new research resource for complex physiologic signals. *Circulation*, v. 101, n. 23, p. e215–e220, 2000. Disponível em: <<http://circ.ahajournals.org/content/101/23/e215.abstract>>. Citado na página 17.
- GÜLER İnan; ÜBEYLİ, E. D. ECG beat classifier designed by combined neural network model. *Pattern Recognition*, v. 38, n. 2, p. 199 – 208, 2005. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320304002766>>. Citado na página 29.
- HSIEH, J.-C.; LO, H.-C. The clinical application of a pacs-dependent 12-lead ECG and image information system in e-medicine and telemedicine. *Journal of Digital Imaging*, v. 23, n. 4, p. 501–513, 2009. ISSN 1618-727X. Disponível em: <<http://dx.doi.org/10.1007/s10278-009-9231-7>>. Citado na página 17.
- JAMBUKIA, S. H.; DABHI, V. K.; PRAJAPATI, H. B. Classification of ECG signals using machine learning techniques: A survey. In: *2015 International Conference on Advances in Computer Engineering and Applications*. [S.l.: s.n.], 2015. p. 714–721. Citado na página 13.
- MARTIS, R. J. et al. Application of principal component analysis to ECG signals for automated diagnosis of cardiac health. *Expert Systems with Applications*, v. 39, n. 14, p. 11792 – 11800, 2012. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417412006690>>. Citado na página 24.
- MARTIS, R. J.; ACHARYA, U. R.; MIN, L. C. ECG beat classification using PCA, LDA, ICA and discrete wavelet transform. *Biomedical Signal Processing and Control*, v. 8, n. 5, p. 437 – 448, 2013. ISSN 1746-8094. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1746809413000062>>. Citado na página 24.
- OMS. *Cardiovascular diseases (CVDs)*. 2016. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs317/en/>>. Acesso em: 27 mar 2017. Citado na página 13.

- PAN, J.; TOMPKINS, W. J. A real-time QRS detection algorithm. *Biomedical Engineering, IEEE Transactions on*, BME-32, n. 3, p. 230–236, March 1985. ISSN 0018-9294. Citado na página 19.
- PEQUENO, R. et al. A portable system to support electrocardiography in emergency care. In: *Computer-Based Medical Systems (CBMS), 2015 IEEE 28th International Symposium on*. [S.l.: s.n.], 2015. p. 256–257. Citado 2 vezes nas páginas 14 e 15.
- ROSENBLATT, F. *Principles of neurodynamics. perceptrons and the theory of brain mechanisms*. [S.l.], 1961. Citado na página 25.
- YE, C.; COIMBRA, M. T.; KUMAR, B. V. K. V. Arrhythmia detection and classification using morphological and dynamic features of ECG signals. In: *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*. [S.l.: s.n.], 2010. p. 1918–1921. ISSN 1094-687X. Citado na página 29.
- YU, S.-N.; CHEN, Y.-H. Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network. *Pattern Recognition Letters*, v. 28, n. 10, p. 1142 – 1150, 2007. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S016786550700013X>>. Citado na página 29.