

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

RENAN DOS SANTOS FAGUNDES

**DETECÇÃO E REMOÇÃO DE
ARTEFATOS EM BIOSINAIS**

Porto Alegre
2018

RENAN DOS SANTOS FAGUNDES

**DETECÇÃO E REMOÇÃO DE
ARTEFATOS EM BIOSINAIS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Engenharia de Computação
- Processamento de Sinais

ORIENTADOR: Prof. Dr. Valner João Brusamarello

Porto Alegre
2018

RENAN DOS SANTOS FAGUNDES

**DETECÇÃO E REMOÇÃO DE
ARTEFATOS EM BIOSINAIS**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: _____

Prof. Dr. Valner João Brusamarello, UFRGS

Doutor pela UFSC – Florianópolis, Brasil

Banca Examinadora:

Prof. Dr. Cristiano Bonato Both, Depto. Ensino e Pesquisa - UFCSPA
Doutor pela UFRGS – Porto Alegre, Brasil

Prof. Dr. Alexandre Balbinot, PPGEE - UFRGS
Doutor pela UFRGS – Porto Alegre, Brasil

Prof. Dr. Altamiro Amadeu Susin, PPGEE - UFRGS
Doutor pela Institut National Polytechnique de Grenoble – Grenoble, França

Coordenador do Curso: _____

Prof. Dr. João Manoel Gomes da Silva Jr.

Porto Alegre, novembro de 2018.

AGRADECIMENTOS

À minha família e amigos pela compreensão nas minhas ausências, e pelo apoio e incentivo que recebi de todos.

Ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, pela oportunidade de realização de trabalhos em minha área de pesquisa.

Aos amigos que fiz durante toda essa trajetória dentro do DELET e dentro da UFRGS. E a todos que me acompanharam nesse processo.

Aos colegas do PPGEE pelo seu auxílio nas tarefas desenvolvidas durante o curso e apoio na revisão deste trabalho.

À CAPES pela provisão da bolsa de mestrado.

Muito Obrigado!

RESUMO

O monitoramento de biosinais é usado em hospitais, ambulatórios e dispositivos vestíveis, para diversos fins. Um dos problemas recorrentes em todas elas são os artefatos de movimentos. Os artefatos de movimentos estão entre as principais causas de alarmes falsos nos hospitais e ambulatórios. Neste trabalho são explorados dois aspectos do uso de biosinais, a detecção de sinais contaminados com artefato, e a remoção de artefatos dos biosinais. O desafio na detecção de artefatos é utilizar apenas medidas estatísticas, para caracterizar o artefato, para que o sistema possa futuramente ser generalizado para outros biosinais. Assim foi proposta uma Máquina de Vetores de Suporte para classificar os sinais em "*com artefato*" ou "*sem artefato*", este classificador atingiu acurácia de 97%. Na remoção de artefatos os desafios são maiores, para tanto foram propostas duas soluções a primeira baseada em decomposição *Ensemble Empirical Mode Decompositions* - (EEMD), que melhorou a qualidade do sinal principalmente nos sinais mais degradados, e a segunda solução baseada em separação cega de fontes que melhorou a qualidade do sinal em todos os casos.

Palavras-chave: *Decomposição de Sinais, Ensemble Empirical Mode Decomposition, Máquina de Vetores de Suporte, Machine Learning, Joint Blind Source Separation, Mult-set Canonical Correlation Analysis.*

ABSTRACT

The monitoring of biosigns is used in hospitals, ambulatory and wearable equipment. A recurring problem in all of them is movement artifacts. In hospitals and clinics these are the main causes of false alarms. In this work, we explore two faces of the use of biosignals, detection of signals contaminated with artifact, and a removal of artifacts from biosignals. The challenge in detecting artifacts is to use only statistical measures to characterize the artifact so that the system can be generalized to other biosignals in the future. Thus, a Support Vector Machine was proposed to classify the signals in *with artifact* or *without artifact*, this classifier reached an accuracy of 97%. The challenge of artifact removal is greater than detection, so two solutions were proposed, the first one based on *Ensemble Empirical Mode Decompositions* - EEMD, which improved the quality of the signal mainly in the most degraded signals and the second solution based on blind source separation has improved signal quality in all cases.

Keywords: Machine Learning, Support Vector Machine, Signal Decomposition, Ensemble Empirical Mode Decomposition, Joint Blind Sources Separation, Mult-set Canonical Correlation Analysis.

SUMÁRIO

| | |
|--|----|
| LISTA DE ILUSTRAÇÕES | 8 |
| LISTA DE TABELAS | 10 |
| LISTA DE ABREVIATURAS | 11 |
| LISTA DE SÍMBOLOS | 12 |
| 1 INTRODUÇÃO | 13 |
| 1.1 Introdução | 13 |
| 1.2 Justificativa | 13 |
| 1.3 Objetivos | 14 |
| 1.3.1 Objetivos Gerais | 14 |
| 1.3.2 Objetivos específicos | 14 |
| 2 REFERENCIAL TEÓRICO E BIBLIOGRÁFICO | 15 |
| 2.1 Introdução | 15 |
| 2.2 Classificação de series temporais | 16 |
| 2.2.1 Métricas de classificação | 16 |
| 2.2.2 Classificadores | 18 |
| 2.2.3 Métricas de avaliação do classificador | 21 |
| 2.3 Decomposição de sinais | 22 |
| 2.3.1 Decomposição em Modos Empíricos - <i>Empirical Mode Decomposition (EMD)</i> | 22 |
| 2.3.2 Ensemble Empirical Mode Decomposition (EEMD) | 25 |
| 2.3.3 Transformada de Wavelet Estacionária (TWE) | 25 |
| 2.4 Separação cega de fontes - SCF | 26 |
| 2.4.1 Análise de componentes independentes | 27 |
| 2.5 Separação cega de fontes conjunta - <i>Joint Blind Source Separation - JBSS</i> | 28 |
| 2.5.1 Notações e formulação usadas em JBSS | 29 |
| 2.5.2 <i>Multiset Canonical Correlation Analysis</i> | 29 |
| 2.5.3 Independent Vector Analysis | 31 |
| 2.6 Revisão bibliográfica | 32 |
| 2.6.1 Revisão bibliográfica de detecção de artefatos em sinais cardíacos | 32 |
| 2.6.2 Revisão bibliográfica de remoção de artefatos em sinais cardíacos | 33 |
| 2.6.3 Revisão Bibliográfica de remoção e artefatos em biosinais não cardíacos | 35 |

| | | |
|------------|---|----|
| 3 | METODOLOGIA | 38 |
| 3.1 | Banco de dados | 38 |
| 3.2 | Deteção de artefatos | 39 |
| 3.2.1 | Estudo preliminar | 40 |
| 3.2.2 | Métricas Estatísticas como Detectores de Artefatos | 40 |
| 3.2.3 | Pré-processamento do sinal | 44 |
| 3.2.4 | Classificador | 44 |
| 3.3 | Remoção de Artefatos utilizando Decomposição de Sinais | 47 |
| 3.3.1 | Decomposição de sinais | 49 |
| 3.3.2 | Extração das métricas estatísticas | 53 |
| 3.3.3 | Classificadores de componentes | 54 |
| 3.4 | Remoção de Artefatos com Separação Cega de Fontes | 56 |
| 3.4.1 | Estudo Preliminar | 57 |
| 3.4.2 | Análise no espaço das fontes | 58 |
| 3.4.3 | Segmentação no espaço das fontes | 59 |
| 3.4.4 | Classificador | 61 |
| 3.4.5 | Remoção de segmentos com artefato e Reconstrução do sinal ECG | 65 |
| 4 | RESULTADOS | 67 |
| 4.1 | Resultados da Deteção de Artefatos | 67 |
| 4.1.1 | Comparações | 68 |
| 4.2 | Resultado da remoção de artefato utilizando Decomposição de Sinais | 69 |
| 4.2.1 | Resultados do classificador EEMD | 69 |
| 4.2.2 | Resultados do classificador EMD | 72 |
| 4.2.3 | Resultados do classificador Transformada Wavelet Estacionária - TWE | 75 |
| 4.2.4 | Resultado do sistema usando a deteção e remoção de artefatos | 78 |
| 4.3 | Resultados da remoção de artefatos usando Decomposição e JBSS | 78 |
| 5 | CONCLUSÃO | 81 |
| 6 | TRABALHO FUTUROS | 82 |
| | REFERÊNCIAS | 83 |
| | APÊNDICE A | 88 |
| A.1 | Classificador de componentes - EEMD | 88 |
| A.2 | Classificador de componentes - EMD | 89 |
| A.3 | Classificador de componentes - TWE | 90 |

LISTA DE ILUSTRAÇÕES

| | | |
|------------|--|----|
| Figura 1: | Diagrama em blocos proposto | 15 |
| Figura 2: | Espectro frequencial do sinal de ECG e do Artefato simultaneamente | 16 |
| Figura 3: | Figura retirada do e-book Mastering Machine Learning with Matlab . | 19 |
| Figura 4: | Figura adaptada do livro (HAYKIN, 2009) | 20 |
| Figura 5: | Sinal de exemplo da decomposição EMD formado pela soma de um ton senoidal e um chirp | 22 |
| Figura 6: | Primeira etapa de interpolação cúbica nos pontos de máxima e pontos de mínima e sinal médio | 23 |
| Figura 7: | Oitava iteração no processo de busca pela primeira IMF | 24 |
| Figura 8: | Modelo de misturas adaptado de (CARDOSO, 1998) | 27 |
| Figura 9: | Estágios de separação de fontes adaptado de (CARDOSO, 1998) . . . | 28 |
| Figura 10: | Exemplo dos 3 tipos de sinais de artefatos coletados em 2 canais. . . | 39 |
| Figura 11: | Exemplo de um frame com os sinais ECG MCLII e ECG II sem artefato e com artefato com SNR 0dB do paciente 118 | 40 |
| Figura 12: | Exemplo de um frame com os sinais ECG MCLII e ECG II sem artefato e com artefato com SNR 0dB do paciente 119 | 40 |
| Figura 13: | Skewness | 41 |
| Figura 14: | Kurtosis | 41 |
| Figura 15: | Kurtosis no domínio frequência | 42 |
| Figura 16: | Entropia | 42 |
| Figura 17: | Entropia de Permutação | 42 |
| Figura 18: | Shannon Entropia | 43 |
| Figura 19: | Autocorrelação lag1 | 43 |
| Figura 20: | Área abaixo do sinal de autocorrelação | 43 |
| Figura 21: | Diagrama esquemático proposto para detectar segmentos com artefato | 44 |
| Figura 22: | Representação da composição dos conjuntos de treinamento e teste . | 45 |
| Figura 23: | Projeção sobre os eixos Kurtosis e Skew das instâncias de treinamento e dos vetores de suporte | 46 |
| Figura 24: | Parte da árvore de decisão gerada a partir dos dados de treinamento. . | 47 |
| Figura 25: | Distâncias testadas para dois exemplos, um alfa e um com artefato. . | 48 |
| Figura 26: | centroides de cada uma das classes | 48 |
| Figura 27: | Diagrama em blocos do sistema proposto | 49 |
| Figura 28: | Tempo de processamento de decomposição versus tamanho dos frames | 51 |
| Figura 29: | Exemplo de decomposição por EEMD de segmento com e sem artefato | 52 |
| Figura 30: | Exemplo de decomposição por EMD de segmento com e sem artefato | 53 |
| Figura 31: | Exemplo de decomposição por Wavelet Estacionária de segmento com e sem artefato | 54 |

| | | |
|------------|---|----|
| Figura 32: | Conjunto de treinamento e teste dos classificadores | 55 |
| Figura 33: | Diagrama em blocos da metodologia proposta | 57 |
| Figura 34: | Fontes referentes às componentes de um sinal de ECG com SNR de 0dB de artefato | 58 |
| Figura 35: | Sinal reconstruído na etapa de remoção de artefatos com EEMD | 59 |
| Figura 36: | Imagem referente ao conjunto de fontes calculadas a partir das componentes. | 60 |
| Figura 37: | Processo para realçar segmentos com maior energia. | 60 |
| Figura 38: | Realce da imagem para evidenciar os segmentos com maior energia. | 60 |
| Figura 39: | Separação em segmentos diferentes. | 61 |
| Figura 40: | Segmentos após processo morfológico de fechamento | 61 |
| Figura 41: | Comparação da Entropia de Shannon das instâncias de Artefato e ECG | 63 |
| Figura 42: | Comparação da Entropia de Shannon das instâncias de Artefato e ECG | 63 |
| Figura 43: | Comparação da Entropia de Shannon das instâncias de Artefato e ECG | 64 |
| Figura 44: | Sinal reconstruído na etapa de remoção de artefatos com JBSS em comparação com o Sinal de entrada SNR 0dB | 66 |
| Figura 45: | Sinal reconstruído na etapa de remoção de artefatos com JBSS em comparação com o Sinal reconstruído usando EEMD | 66 |
| Figura 46: | Sinal reconstruído na etapa de remoção de artefatos com JBSS em comparação com o Sinal sem artefatos | 66 |
| Figura 47: | NRMSE do Recuperação utilizando EEMD do sinal do paciente 118 | 70 |
| Figura 48: | NRMSE do Recuperação utilizando EEMD do sinal do paciente 119 | 70 |
| Figura 49: | NRMSE de entrada versus NRMSE de saída do sinal do paciente 118 | 70 |
| Figura 50: | NRMSE de entrada versus NRMSE de saída do sinal do paciente 119 | 71 |
| Figura 51: | Exemplo de decomposição por EEMD de segmento com e sem artefato | 71 |
| Figura 52: | Exemplo da reconstrução do artefato usando EEMD | 72 |
| Figura 53: | NMSE do Recuperação utilizando EMD do sinal do paciente 118 | 72 |
| Figura 54: | NMSE do Recuperação utilizando EMD do sinal do paciente 119 | 73 |
| Figura 55: | NRMSE de entrada versus NRMSE de saída utilizando EMD do paciente 118 | 73 |
| Figura 56: | NRMSE de entrada versus NRMSE de saída utilizando EMD do paciente 119 | 74 |
| Figura 57: | Exemplo de decomposição por EMD de segmento com e sem artefato | 74 |
| Figura 58: | Exemplo da reconstrução do artefato usando EMD | 75 |
| Figura 59: | NRMSE do Recuperação utilizando TWE | 75 |
| Figura 60: | NRMSE do Recuperação utilizando SWL | 76 |
| Figura 61: | NRMSEin x NRMSE utilizando SWL do paciente 118 | 76 |
| Figura 62: | NRMSEin x NRMSE utilizando SWL do paciente 119 | 77 |
| Figura 63: | Exemplo de decomposição por Wavelet Estacionária de frame com e sem artefato | 77 |
| Figura 64: | Exemplo da reconstrução do artefato usando TWE | 78 |
| Figura 65: | NMSE do Recuperação utilizando EEMD | 79 |
| Figura 66: | Comparação entre NRMSE do sinal Original, do sinal reconstruído por EEMD e do sinal reconstruído por EEMD+MCCA | 80 |
| Figura 67: | Comparação entre a correlação do sinal Original, do sinal reconstruído por EEMD e do sinal reconstruído por EEMD+MCCA | 80 |

LISTA DE TABELAS

| | | |
|------------|---|----|
| Tabela 1: | Matriz de Confusão | 21 |
| Tabela 2: | Avaliação dos classificadores das componentes EEMD | 56 |
| Tabela 3: | Avaliação dos classificadores das componentes EMD | 56 |
| Tabela 4: | Avaliação dos classificadores das componentes TWE | 56 |
| Tabela 5: | Matriz de confusão do classificador SVM com kernel linear | 64 |
| Tabela 6: | Matriz de confusão do classificador SVM com kernel Gaussiano | 64 |
| Tabela 7: | Matriz de confusão do classificador Conjunto de árvores de decisão | 65 |
| Tabela 8: | Matriz de Confusão do Classificador SVM | 67 |
| Tabela 9: | Matriz de Confusão do Classificador Árvore de decisões | 67 |
| Tabela 10: | Matriz de Confusão do Classificador Árvore de decisões | 67 |
| Tabela 11: | Matriz de Confusão do Classificador K vizinhos mais próximos | 67 |
| Tabela 12: | Matriz de Confusão do Classificador K médio | 68 |
| Tabela 13: | Comparação de desempenho entre os classificadores | 68 |
| Tabela 14: | Compação com outros trabalhos | 68 |
| Tabela 15: | Comparação entre metodologias | 68 |
| Tabela 16: | Comparações do resultado de NRMSE entre métodos para cada dosagem de SNR | 79 |
| Tabela 17: | Comparações do resultado de correlação entre métodos para cada dosagem de SNR | 79 |

LISTA DE ABREVIATURAS

| | |
|-------|--|
| BSS | - <i>Blind Source Separation</i> |
| ECG | - Eletrocardiograma |
| EEMD | - <i>Ensemble Empirical Mode Decomposition</i> |
| EMD | - <i>Empirical Mode Decomposition</i> |
| FFT | - <i>Fast Fourier Transform</i> |
| FIR | - <i>Finite Impulse Response</i> |
| HOS | - <i>High Order Statistics</i> |
| ICA | - <i>Independent Component Analysis</i> |
| IMF | - <i>Intrinsic Mode Function</i> |
| IVA | - <i>Independent Vector Analysis</i> |
| JBSS | - <i>Joint Blind Source Separation</i> |
| MCCA | - <i>Multiset Canonical Correlation Analysis</i> |
| NMSE | - <i>Normalised Means Squared Error</i> |
| NRMSE | - <i>Normalised Root Means Squared Error</i> |
| PCA | - <i>Principal Component Analysis</i> |
| PPG | - Photoplethysmografia |
| SNR | - <i>Signal Noise Ratio</i> |
| SOS | - <i>Second Order Statistics</i> |
| TWE | - Transformada Wavelet Estacionaria |

LISTA DE SÍMBOLOS

| | |
|-------------|-------------------------------|
| \sum | Somatório |
| $E(.)$ | Valor esperado, operado media |
| $\ \cdot\ $ | Norma L2 do vetor |
| \int | Integral |

1 INTRODUÇÃO

1.1 Introdução

No contexto de monitoramento de sinais vitais, tanto em monitores hospitalares e ambulatoriais quanto em dispositivos vestíveis, os artefatos atrapalham as medidas, levam a degradação da qualidade do sinal, geram alarmes falsos, podendo levar a *diagnosticoserrados*. Este trabalho propõe a aplicação de algumas técnicas de processamento de sinais para detectar e remover artefatos de movimentos de biosinais.

1.2 Justificativa

Doenças cardiovasculares são as principais causas globais de morte, respondendo por mais de 17,3 milhões de mortes por ano, número que deve crescer para mais de 23,6 milhões até 2030 de acordo com (MOZAFFARIAN et al., 2015). O número de pessoas internadas em hospitais tem crescido nas últimas décadas. Isto se deve em parte ao aumento na expectativa de vida das pessoas e ao aumento da incidência de doenças crônicas (SWEENEY; WARD; MCLOONE, 2012). A capacidade de monitorar o paciente no conforto de sua própria casa pode aumentar sua qualidade de vida, com o benefício adicional de que o paciente fora do hospital pode custar 50% menos que um paciente hospitalizado. A monitoração dos sinais cardíacos do paciente em ambiente doméstico permite adquirir informações durante suas atividades diárias, resultando em um conjunto de dados mais representativo. Embora proporcione mais comodidade e menor custo financeiro ao paciente, pode trazer algum prejuízo na qualidade do sinal adquirido pois, em casa, há menor controle contra ruídos. Por se tratar de um ambiente não controlado, também há menor confiabilidade de que o procedimento de medida será adequado por todo o período de medição (SWEENEY; WARD; MCLOONE, 2012).

Em alguns casos, o paciente necessita de dispositivos como monitor de ECG (e.g. monitor *Holder*), para diagnóstico ou monitoramento de alguma patologia cardíaca como a fibrilação atrial, por exemplo. Sobretudo nesses casos, artefatos degradam significativamente a qualidade da monitoração e podem gerar alarmes falsos (LEE et al., 2012). Problema semelhante ocorre nos monitores de eletrocardiograma (ECG) em ambulatórios. Por exemplo, artefatos podem resultar do movimento dos eletrodos na superfície da pele, interferência de linhas de transmissão, atividade muscular e variação da linha base. A utilização dos dados com estes ruídos dificulta o desempenho dos algoritmos usados nos ambulatórios, como os usados para detectar batimento ou classificadores de arritmias (SHOAIIB et al., 2012). A monitoração de biosinais, sobretudo o sinal de ECG, tem aplicações diretas em hospitais e também em ambiente doméstico, e o estudo dos algoritmos de classificação e análise de sinais são áreas de grande interesse atualmente.

Os dispositivos de ECG usualmente utilizam eletrodos com gel para fazer o contato na pele. Apesar do eletrodo com gel ser menos sensível a ruídos, ele não é adequado para uso por longos períodos de tempo, como é o caso dos dispositivos vestíveis, pois o gel é absorvido pela pele e seca. Por outro lado, existem os eletrodos de contato seco que são mais indicados para uso ao longo do dia, porém estes são mais sensíveis a ruídos e artefatos (NAGAI; ANZAI; WANG, 2017). Assim, algoritmos de detecção e remoção de artefatos são necessários nesses casos.

1.3 Objetivos

Existem vários tipos de artefatos que corrompem as medidas de biosinais, tais como interferência eletromagnética, atividade muscular e movimento do eletrodo. Destes, os mais difíceis de detectar e remover são os artefatos de movimento de eletrodo, pois eles possuem morfologia semelhante ao sinal ECG. Porém podem ser detectados por métricas estatísticas.

1.3.1 Objetivos Gerais

Os principais objetivos deste trabalho são desenvolver metodologias de detecção de biosinais contaminados por artefatos e a remoção desses ruídos de artefato visando melhoria na qualidade de sinal.

1.3.2 Objetivos específicos

Os objetivos específicos desse trabalho consistem em:

- Desenvolvimento de um sistema para detecção de artefatos de movimento em sinais de ECG.
- Implementação de técnicas de decomposição de sinais de ECG para remoção de artefato de movimento;
- Implementação de metodologias de separação cega de fontes, para análise de sinais multi-sensores.

2 REFERENCIAL TEÓRICO E BIBLIOGRÁFICO

2.1 Introdução

Neste capítulo serão descritos os algoritmos utilizados no projeto para detectar e remover artefatos de biosinais. Ainda neste capítulo serão mostrados os principais trabalhos da detecção e remoção de artefatos em biosinais cardíacos e não cardíacos.

Na Figura 1 é mostrado o arranjo de blocos do sistema proposto para remover artefatos. Neste sistema, o detector testa os segmentos de biosinais quanto à presença ou não de artefatos. No caso do detector não encontrar artefatos, o sinal é entregue à saída não processado. No caso do detector encontrar artefatos o sinal é processado pela etapa de remoção de artefatos. A detecção é importante nas estratégias de remoção de artefatos, pois a aplicação dessas estratégias em sinais sem artefatos pode degradar o sinal (TAJI; CHAN; SHIRMOHAMMADI, 2017).

O processo de remoção de artefatos foram construídos dois modelos de remoção de artefatos. Um com decomposição de sinais e um com decomposição de sinais e *Joint Blind Source Separation - JBSS*. Os algoritmos de decomposição e JBSS são apresentados ao longo deste capítulo.

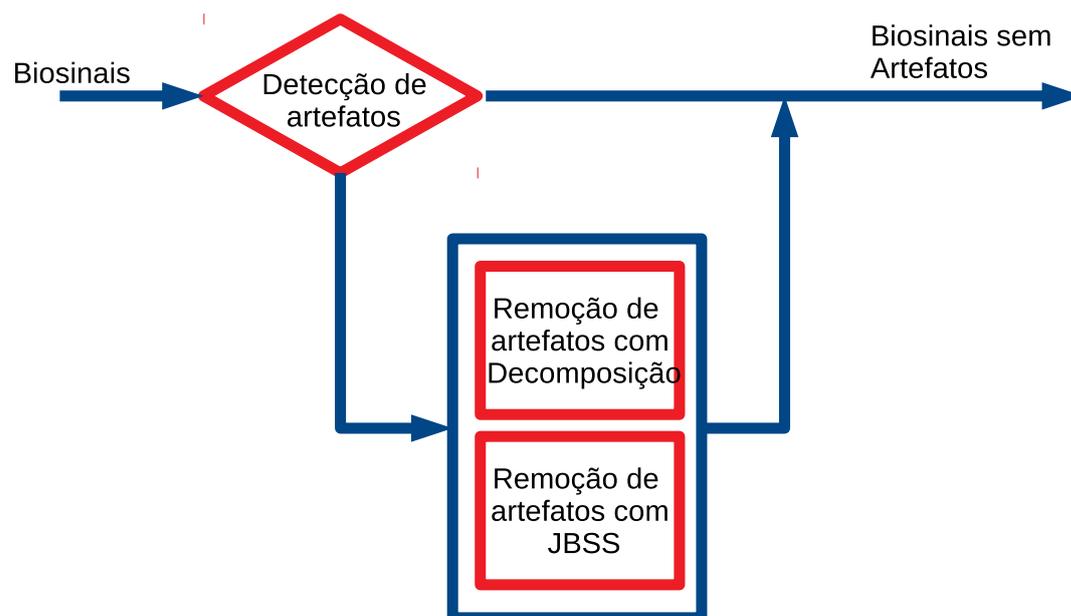


Figura 1: Diagrama em blocos proposto

Ao longo das próximas seções serão descritos as teorias utilizadas no desenvolvi-

mentos dos blocos descritos. O bloco de detecção de artefatos utilizou algoritmos de classificação de series temporais com métricas estatísticas. Os blocos de remoção de artefatos utilizou decomposição de sinais e JBSS. São estudados os metodos de *Empirical Mode Decomposition - EMD*, *Ensemble Empirical Mode Decomposition - EEMD* e Transformada Wavelet Estacionária - TWE. E para JBSS são estudados os metodos *Multiset Canonical Correlation Analysis - MCCA* e *Independent Vector Analysis - IVA*.

2.2 Classificação de series temporais

Este trabalho apresenta três classificadores de sinais temporais, cada um em uma etapa do projeto apresentado. Todos os classificadores apresentados são baseados em estatísticas do sinal e não no sinal em si, esta metodologia de classificação é adotada em (ZHANG et al., 2017; ZHANG; ZHOU; ZENG, 2017, 2016).

Em cada etapa do processamento dos sinais biomédicos o classificador tem o objetivo de descobrir se um determinado trecho de biosinais está contaminado com artefato. Nesta seção serão estudadas medidas estatísticas capazes de discriminar artefatos. Também serão estudadas técnicas de classificação de sinais temporais baseados em medidas estatísticas.

2.2.1 Métricas de classificação

Nesta seção serão descritas as métricas utilizadas na detecção de segmentos com artefato. Como dito anteriormente, alguns artefatos de movimento são sinais muito semelhantes ao sinal de ECG. Esse aspecto se reflete também no espectro de frequências, como mostra a Figura 2. Nessa figura pode-se ver, em azul, o espectro de frequência de um sinal de ECG e, em laranja, um sinal de artefato. Observa-se que ambos os espectros sobrepõem-se.

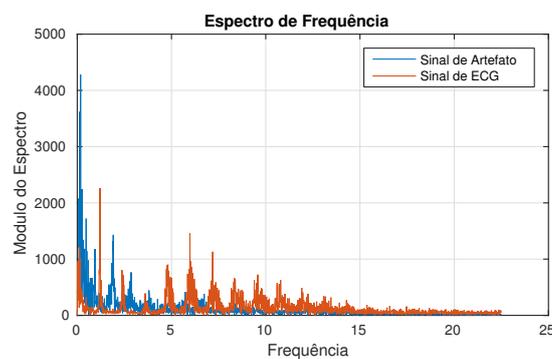


Figura 2: Espectro frequencial do sinal de ECG e do Artefato simultaneamente

Uma das maneiras de diferenciar esses sinais, é aplicar métricas estatísticas para detectar artefatos. Na literatura são apresentadas muitas métricas (KRISHNAN; NATARAJAN; WARREN, 2010) (ZHANG et al., 2017) (ZHANG; ZHOU; ZENG, 2016) (RAM et al., 2013) (SELVARAJ et al., 2011) (LEE et al., 2012) (WENG; BLANCO-VELASCO; BARNER, 2006) (MILANESI et al., 2008) (BARHATTE; GHONGADE; TEKALE, 2016) (CLERCQ et al., 2006) (MAHAJAN; MORSHED, 2013) (MAHAJAN; MORSHED, 2015). Neste trabalho foram feitos testes preliminares para verificar quais as métricas que melhor descrevem os artefatos.

- Desvio padrão: Medida estatística de segunda ordem, usada para fornecer um parâ-

metro quantitativo de dispersão dos dados em torno da média. Também é usada para medir a energia AC de um sinal. Esta métrica é utilizada no segundo classificador, visto que todos os segmentos do sinal ECG possuem desvio padrão normalizado. Desvio padrão é definido na equação 1.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}, \text{ Onde } \mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (1)$$

- Obliquidade (*skweness*): É o momento de terceira ordem e é uma medida de assimetria de uma distribuição de probabilidade, descrita pela equação 2. Esta medida estatística foi usada em (KRISHNAN; NATARAJAN; WARREN, 2010) como marcador de artefato em fotopletismografia.

$$\gamma_1 = E \left[\left(\frac{X - \mu}{\sigma} \right)^3 \right] = \frac{E[X^3] - 3\mu\sigma^2 - \mu^3}{\sigma^3}. \quad (2)$$

- Curtose (*kurtosis*): É um valor quantitativo que indica o quanto a forma de uma distribuição se diferencia da Gaussiana. Quanto mais positivo for o valor de curtose, mais pontiaguda e maior é a cauda da distribuição de probabilidade. Quanto mais negativo o valor de curtose, mais achatada e menor é a cauda da distribuição. A título de exemplo, a distribuição de Laplace tem curtose igual a +3; a distribuição Gaussiana tem curtose igual a zero e a distribuição normal tem curtose igual a -1,2. Esta medida estatística foi usada em (BARHATTE; GHONGADE; TEKALE, 2016), (KRISHNAN; NATARAJAN; WARREN, 2010), (ZHANG; ZHOU; ZENG, 2016) e (MAHAJAN; MORSHED, 2015)

$$\text{Kurt}[X] = E \left[\left(\frac{X - \mu}{\sigma} \right)^4 \right] = \frac{E[(X - \mu)^4]}{(E[(X - \mu)^2])^2}, \quad (3)$$

- Curtose no domínio da frequência: Esta métrica foi usada para detectar artefatos em sinais de fotopletismografia em (KRISHNAN; NATARAJAN; WARREN, 2010), e consiste no cálculo da *kurtosis* da transformada de Fourier do sinal. A função *FFT* retorna uma variável complexa, então foi usado o módulo da transformada de Fourier do sinal como entrada do cálculo de Curtose no domínio da frequência.
- Entropia: Entropia é uma medida estatística de aleatoriedade, é definida pela equação 4

$$E = -\text{sum}(p * \log_2(p)) \quad (4)$$

onde p contem o histograma do sinal.

- Shannon Entropia: Os artefatos de movimento geralmente aparecem como sinais caóticos em contraste com o padrão quase-periódico livre de artefatos. O nível de incerteza no sinal, pode ser quantificado usando a entropia de Shannon (ROBLES-RUBIO; BROWN; KEARNEY, 2013). A entropia de Shannon descreve quanta informação um vetor possui (SELVARAJ et al., 2011). Esta medida estatística foi usada como marcador de artefatos em: (SELVARAJ et al., 2011), (LEE et al., 2012), (ROBLES-RUBIO; BROWN; KEARNEY, 2013), é descrita pela equação 5.

$$E.S = - \sum_i s_i^2 \log(s_i^2) \quad (5)$$

- **Permutação Entropia:** Entropia de Permutação (PE) é uma medida para séries temporais arbitrárias baseada na análise de padrões de permutação. Este método permite estimar a complexidade das séries temporais, levando em consideração a ordem temporal dos valores (RAVELO-GARCÍA et al., 2015).

Abordagens comuns para quantificar a complexidade de uma série temporal negligenciam efeitos decorrentes da ordem temporal. Para levar em conta essa informação causal, as séries temporais podem ser codificadas em sequências de símbolos. Esta abordagem propõe uma codificação natural que reflete a ordem de n elementos em sequências e, portanto, define a entropia de permutação pela equação 6 (MAIK RIEDL ANDREAS MÜLLER, 2013).

$$h_n = \frac{-1}{(n-1)} \sum_{n!}^{j=1} p'_j \log_2(p'_j) \quad (6)$$

Os p'_j representam as frequências relativas dos possíveis padrões de sequências de símbolos, denominadas permutações. Neste trabalho foi utilizado $n=3$, com base em (RAVELO-GARCÍA et al., 2015) e em testes preliminares.

- **Autocorrelação coeficiente 1:** Esta medida consiste em tomar o segundo valor do vetor de autocorrelação normalizada. O coeficiente 0 não é usado, pois é uma constante. Trabalhos que usam autocorrelação coeficiente 1 para detectar artefato são: (VARON et al., 2012), (SWEENEY; MCLOONE; WARD, 2013) e (CLERCQ et al., 2006)
- **Área abaixo do sinal de autocorrelação:** Métrica semelhante à anterior, porém esta toma a integral do vetor de autocorrelação. Esta medida foi usada em (MILANESI et al., 2008), (MILANESI et al., 2005), (MILANESI et al., 2006) para classificar sinais como artefato.

2.2.2 Classificadores

Existem atualmente várias metodologias de classificação. O ramo de aprendizagem de máquina é um ramo da ciência em pleno crescimento. O processo de aprendizado pode ser dividido em duas etapas: a primeira, um processo iterativo em um conjunto de dados, afim de gerar um modelo de classificação. A segunda é a etapa de teste do classificador baseada no modelo gerado previamente (HAYKIN, 2009) (BISHOP, 2006). A Figura 3 ilustra essas etapas. Neste trabalho são aplicados mais de um tipos de classificadores de sinais nas etapas de processamento de sinal apresentadas.

Existem três principais tipos de algoritmos de aprendizagem usados para classificação. A diferença entre eles diz respeito à maneira de treinamento do aprendizado, e podem ser: *Supervisionado*, *Não-Supervisionado* e *Semi-Supervisionado* (HAYKIN, 2009). Dentro da classe dos algoritmos Supervisionados pode-se citar: KNN, Máquina de vetor de suporte -(*Support Vector Machine - SVM*), árvore de decisões e Redes Neurais. Detro da classe dos Algoritmos de classificação Não-Supervisionados tem-se: Kmeans, Expectation-Maximization e Hierarchical Cluster Analysis (HCA). E dentro da classe dos

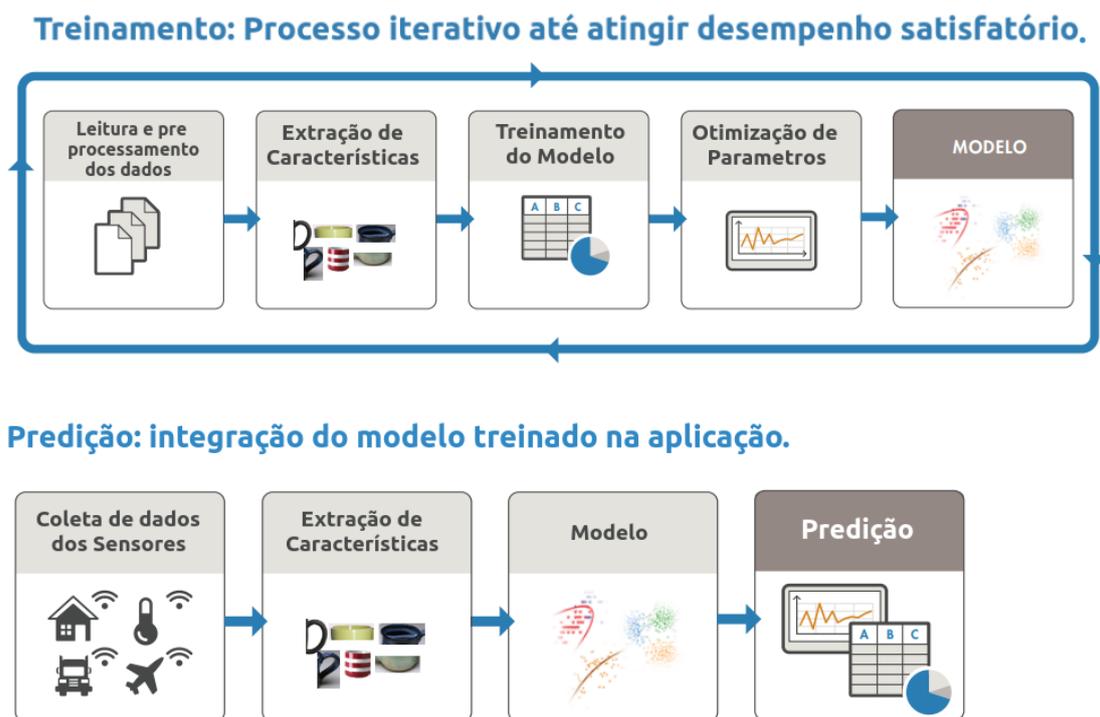


Figura 3: Figura retirada do e-book *Mastering Machine Learning with Matlab*

algoritmos Semi-Supervisionados pode-se citar: *Deep Belief Networks - dBN* o qual é baseado em componentes não supervisionados chamado *Restricted Boltzmann Machines - RBM* (GÉRON, 2017).

Existem também metodologias que não usam etapas de treinamento, e seu aprendizado ocorre no decorrer da sua atuação, como o Aprendizado por reforço. Nele, um agente executa uma ação no ambiente e recebe deste uma recompensa (reforço positivo) ou uma punição (reforço negativo), e assim ele deve aprender a melhor estratégia chamada "Política", afim de receber a maior recompensa ao longo do tempo. Esta metodologia, no entanto, está fora do escopo do trabalho (GÉRON, 2017). Neste trabalho serão testados os classificadores: SVM, árvores de decisões, KNN e Kmeans. Estes serão estudados a seguir.

2.2.2.1 Máquina de vetor de suporte

Uma máquina de vetores de suporte é uma máquina de aprendizagem para problemas de classificação em duas classes. Nestas máquinas, vetores de entrada são mapeados não-linearmente para um espaço de características de alta dimensionalidade, podendo se tornar linearmente separáveis. A alta capacidade de generalização é obtida com o hiperplano ótimo de separação das classes, que é definido como a função de decisão com a maior margem de separação. Constatou-se que para construir este hiperplano ótimo só é necessário levar em conta uma pequena quantidade dos dados de treinamento: os vetores de suporte, como mostrado na Figura 4. Mostrou-se que a capacidade de generalização é grande se o hiperplano puder ser construído por um número pequeno de vetores de suporte (HAYKIN, 2009).

A função de decisão SVM é apresentada em (7), onde x é o vetor de entrada com dimensão igual ao número de métricas estatísticas utilizadas no treinamento, x_i é o i -

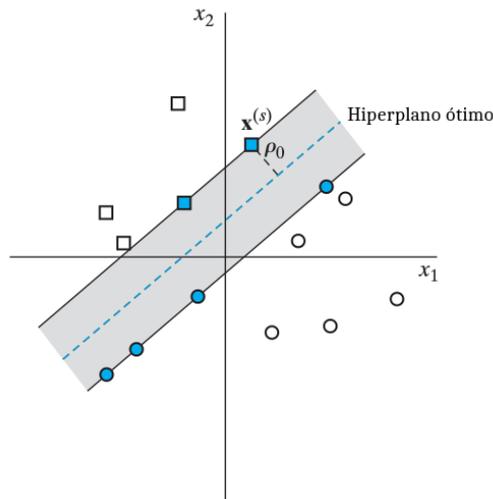


Figura 4: Figura adaptada do livro (HAYKIN, 2009)

ésimo vetor de suporte entre o m vetores de suporte aprendidos e y_i é o rótulo da classe referente à x_i , α_i é o vetor de pesos aprendido, b é bias aprendido, e k é o kernel o qual usualmente é linear ou gaussiano (ZHANG et al., 2017).

$$f(x) = \text{sign}\left(\sum_{i=1}^m \alpha_i * y_i * k(x, x_i) + b\right) \quad (7)$$

2.2.2.2 Árvore de decisão

Uma árvore de decisão representa uma série de testes encadeados acerca de atributos de um objeto do domínio. Um dado entra na árvore pelo nó raiz, tradicionalmente colocado no topo da representação gráfica, e a árvore se desenvolve para baixo, até chegar a um nó folha, representando uma classe. A partir de um nó (pai), é feito um teste para decidir qual nó filho deve ser pesquisado a seguir. Existe apenas um caminho da raiz até cada folha. Este caminho é uma expressão da regra usada para classificar os dados (HAYKIN, 2009).

2.2.2.3 K vizinhos mais próximos

O classificador baseado em K vizinhos mais próximos (*K-nearest neighbor-KNN*) é um método não paramétrico, o qual analisa a distribuição das instâncias para construir o modelo. Este método não faz nenhuma suposição sobre a distribuição dos dados (ZHANG; ZHOU; ZENG, 2017).

2.2.2.4 k-Means

K-means é uma técnica de classificação não-supervisionada: as classes não são pré-definidas e devem ser aprendidas com base na similaridade entre os padrões. O método K-means deriva o seu nome do fato de ele iniciar com um conjunto de k “germes” escolhidos como suposição inicial para os centroides, ou médias, dos agrupamentos. No segundo passo do algoritmo, cada vetor de dado recebe o rótulo do agrupamento que estiver mais próximo. Isto é feito medindo-se a distância entre o vetor e cada centroide dos agrupamentos. Após a rotulação de todos os dados, os centroides dos agrupamentos

são atualizados, calculando-se cada um como a média de todos os vetores que pertencem ao agrupamento correspondente. A atualização dos centroides é repetida até eles não se modificarem mais (HAYKIN, 2009).

2.2.3 Métricas de avaliação do classificador

A avaliação de um classificador é feita inicialmente pela análise da sua *matriz de confusão*. Uma matriz de confusão é uma tabela com duas linhas e duas colunas que informa o número de falsos positivos, falsos negativos, verdadeiros positivos e verdadeiros negativos. Na tabela abaixo esta mostrada uma representação da matriz de confusão (GÉRON, 2017).

Tabela 1: Matriz de Confusão

| | | Classes Previstas | |
|---------------------|--------------|--------------------------|--------------------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | Verdadeiro Positivo (VP) | Falso Negativo (FN) |
| | Não Artefato | Falso Positivo (FP) | Verdadeiro Negativo (VN) |

A matriz de confusão permite uma análise mais detalhada do que a mera proporção de classificações corretas, medida conhecida como precisão. A precisão é definida por:

$$Precisao = \frac{VerdadeirosPositivos}{VerdadeirosPositivos + FalsosPositivos} \quad (8)$$

A precisão não é uma métrica confiável para o desempenho real de um classificador, porque produzirá resultados enganosos se o conjunto de dados estiver desequilibrado (ou seja, quando o número de observações em diferentes classes variar muito). Por exemplo, um classificador para detectar uma doença, se houvesse 97 pessoas saudáveis e apenas 3 pessoas doentes nos dados (plausível, visto que a maioria da população é saudável), um classificador poderia classificar todas as observações como saudáveis. A precisão geral seria de 97%, ou seja, erraria justamente nos casos em que mais precisava acertar (GÉRON, 2017).

Ainda seguindo o exemplo, este classificador teria uma taxa de reconhecimento de 100% para a classe saudável, mas uma taxa de reconhecimento de 0% para a classe doente. Estas taxas de reconhecimento são conhecidas como *sensitivity* e *specificity* (LEE et al., 2012) (VARON et al., 2012), definidas por:

$$sensitivity = \frac{VerdadeirosPositivos}{VerdadeirosPositivos + FalsosNegativos} \quad (9)$$

$$specificity = \frac{VerdadeirosNegativos}{VerdadeirosNegativos + FalsosPositivos} \quad (10)$$

Existe uma métrica que combina essas duas, e mostra quantas vezes o classificador acerta, sobre o total de instâncias de teste, chamada *accuracy*, definida por:

$$accuracy = \frac{VerdadeirosNegativos + VerdadeirosPositivos}{Total} \quad (11)$$

Onde Total é igual ao total de instâncias de testes = Verdadeiros Positivos + Verdadeiros Negativos + Falso Positivos + Falsos Negativos.

2.3 Decomposição de sinais

Decomposição de sinais consiste em transformar um série temporal $x = (x_1, x_2, \dots, x_N)$ de comprimento N amostras, em um conjunto de M séries temporais diferentes também de comprimento N , os quais podem ser transformados de volta em x sem perda de informação. Esta seção tratará dos métodos de Decomposição de sinais usados neste trabalho.

2.3.1 Decomposição em Modos Empíricos - *Empirical Mode Decomposition (EMD)*

Decomposição em Modos Empíricos é um métodos de decomposição baseado em dados. Isto significa que não requer nenhum conhecimento *a priori* do sinal a ser decomposto. Ou seja, é adaptativo a qualquer sinal (TAN et al., 2014) (ZHAOHUA WU, 2009). A Decomposição EMD é largamente utilizada para remover artefatos de biosinais, como por exemplo ECG, EEG, PPG, Eletrohystogram (EHG)

EMD é baseado em características locais na escala do tempo do próprio sinal de entrada. Este método é capaz de ser aplicado na análise de processos não lineares e não-estacionários (ZHAOHUA WU, 2009). EMD decompõe um sinal em múltiplas funções de modo intrínseco - ("*Intrinsic Mode Functions*" - IMF) que somados resultam no sinal original. Uma IMF é uma função que satisfaz duas condições:

1) Ao longo de toda a série o número de máximas e o número de cruzamentos por zero devem ser iguais ou diferentes de no máximo 1.

2) Em qualquer ponto da série, a média entre o envelope definido pelos pontos de máxima e o envelope definido pelos pontos de mínima, deve ser zero (SWEENEY; MCCLONE; WARD, 2013; HUANG et al., 1998).

EMD decompõe o sinal em vários IMFs da seguinte maneira: Neste exemplo $x(t)$ é um sinal formado pela soma de uma *ton* senoidal e um *chirp*, conforme mostra a Figura , este sinal original é designado como $x(t)$.

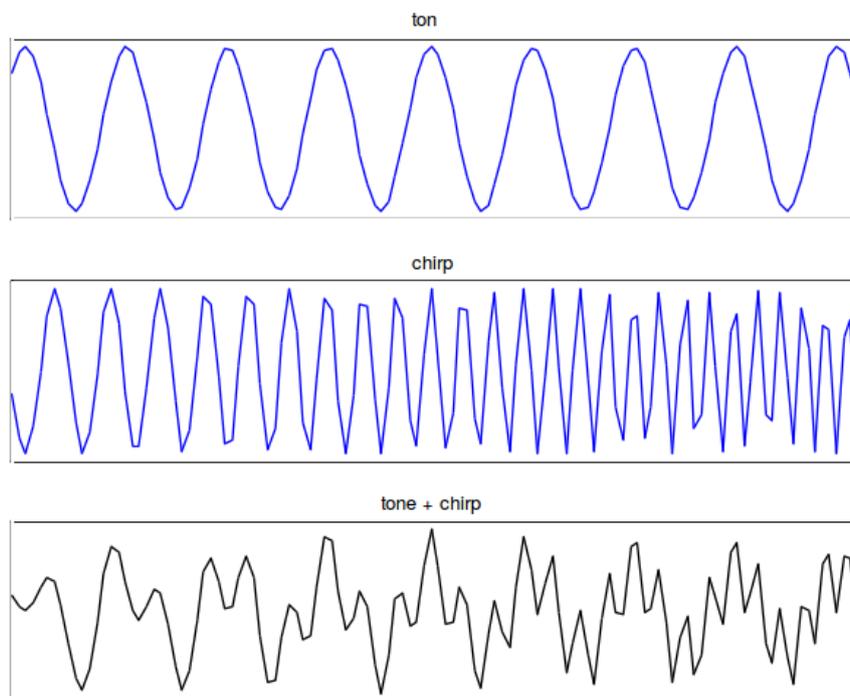


Figura 5: Sinal de exemplo da decomposição EMD formado pela soma de um ton senoidal e um chirp

O primeiro passo do EMD é identificar todos os pontos de máximos locais e mínimos locais de $x(t)$. Os dois envelopes $e_{max}(t)$ e $e_{min}(t)$ são obtidos pela interpolação *spline* cúbica respectivamente dos máximos locais e mínimos locais de $x(t)$.

A Figura 6 a) mostra os pontos de máximos em azul e os pontos de mínimos em vermelho. Também são mostrados os envelopes máximo e mínimo $e_{max}(t)$ e $e_{min}(t)$. O valor médio dos dois envelopes é obtido pela equação 12. Na Figura 6 a) mostra a média entre os dois envelopes em rosa. Na Figura 6 b) esta mostrado o resíduo, que é o sinal original menos a média dos envelopes.

$$m_1(t) = [e_{mx}(t) + e_{mn}(t)]/2. \quad (12)$$

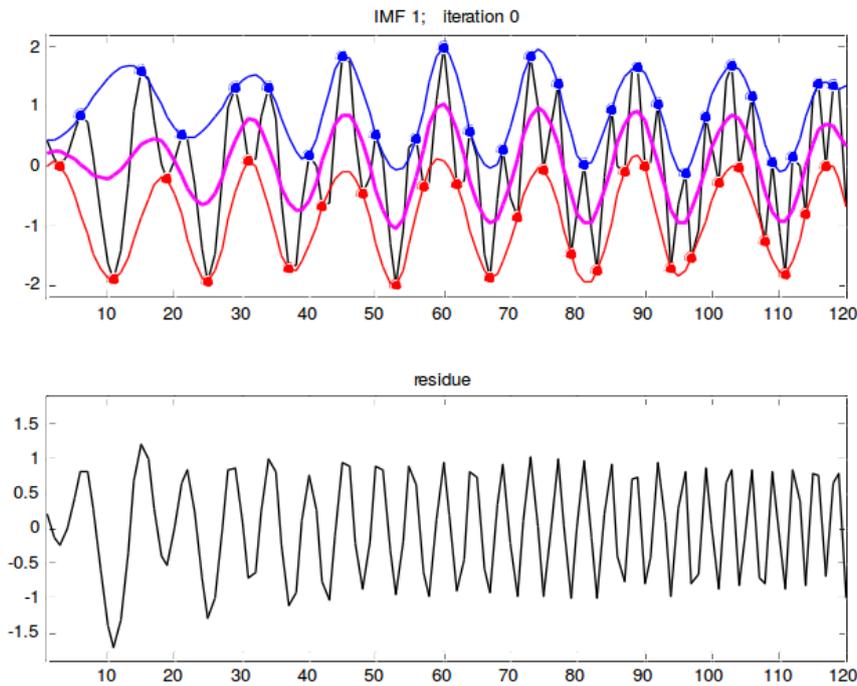


Figura 6: Primeira etapa de interpolação cúbica nos pontos de máxima e pontos de mínima e sinal médio

O primeiro componente $h_1(t)$ é obtido pela equação 13. A equação 14 descreve o processo iterativo de busca de cada IMF.

$$h_1(t) = x(t) - m_1(t). \quad (13)$$

Se $h_1(t)$ não satisfaz as duas características do *IMF* o processo deve iterar novamente, tratando $h_1(t)$ como um sinal original. Quando os dois critérios são satisfeitos $h_{1,k}(t)$ é tomado como primeira IMF designado pela equação 14

$$h_{1,k}(t) = h_{1,(k-1)} - m_{1,k}(t). \quad (14)$$

Onde $m_{1,k}(t)$ na equação 14 é a média dos dois envelopes de $h_{1,k}(t)$. O processo é iterado até que se encontre $h_{1,k}(t)$ (definida na equação 14) que satisfaça as duas condições, onde k é o número de iterações (CHEN; HE; PENG, 2014; HUANG et al., 1998).

Neste exemplo a primeira iteração de $h_{1,k}(t)$ não satisfaz as duas condições até a oitava iteração, $h_{1,8}(t)$. Na Figura a) são mostrados os envelopes e suas médias, da primeira IMF na oitava iteração. Na figure b) esta mostrado o respectivo resíduo.

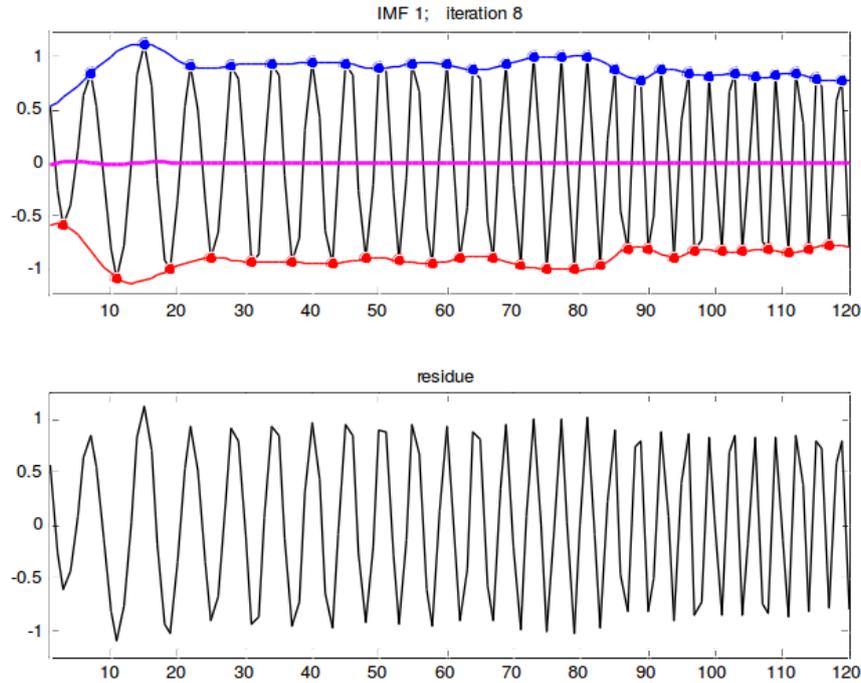


Figura 7: Oitava iteração no processo de busca pela primeira IMF

Então $h_{1,8}(t)$ é a primeira IMF. A primeira componente IMF derivada do sinal original é descrita pela equação 15

$$c_1(t) = h_{1,k}(t). \quad (15)$$

Para extrair a segunda IMF, removemos c_1 do sinal original, conforme 16, para obter $r_1(t)$, chamado de resíduo.

$$r_1(t) = x(t) - c_1(t). \quad (16)$$

O resíduo é tratado como um novo sinal original e o mesmo processo iterativo é aplicado para obter a segunda IMF c_2 e um novo resíduo. O resíduo em cada iteração é descrito por:

$$\begin{aligned} r_2(t) &= r_1(t) - c_2(t) \\ &\dots \\ r_n(t) &= r_{n-1}(t) - c_n(t). \end{aligned} \quad (17)$$

O processo termina quando $r_n(t)$ não puder ser mais decomposto em IMFs. Neste caso $r_n(t)$ ou é uma função monotônica ou com um extremo apenas. $x(t)$ pode assim ser escrita como a soma de todas IMFs, mais o último resíduo, conforme a equação 18.

$$x(t) = \sum_{i=1}^L c_i(t) + r_L(t) \quad (18)$$

onde L é o número de IMFs e $r_L(t)$ é o sinal de resíduo. Assim, o sinal original $x(t)$ é decomposto em i funções de modo empírico c_i e um resíduo r_L .

À medida que o índice i aumenta, os componentes de período contidos em $c_i(t)$ se tornam mais longos. Nesse sentido, $c_i(t)$ deve conter a melhor escala de $x(t)$, e $r_L(t)$ apresenta a tendência de $x(t)$ (CHEN et al., 2014).

2.3.2 Ensemble Empirical Mode Decomposition (EEMD)

O algoritmo EMD é muito sensível a ruído dos sinais adquiridos. Isto pode causar oscilações muito diferentes na mesma Função de Modo Intrínseco (IMF). Este fenômeno é conhecido como mistura de modos. A mistura de modos é um problema na decomposição, porque as Funções de Modo Intrínseco (IMFs) ficam compostas por sinais de escalas muito diferentes (disperses), ou sinais de escalas muito similares residentes em IMFs diferentes.

Para tentar contornar esse problema, (ZHAOHUA WU, 2009) propuseram o método de análise de sinais assistido por ruído, chamado EEMD. Esta melhoria no método define que a melhor escolha de IMFs será a média de um conjunto de ensaios de EMD. Cada ensaio consiste na decomposição EMD do sinal original somado a um ruído branco independente e identicamente distribuído (IID) de desvio padrão definido ϵ , usualmente 20% do desvio padrão do sinal.

Assim cada IMF_{EEMD} é a média de vários IMF_{EMD} sendo que cada decomposição EMD decompõe o sinal original $x(t)+ruído(t)$. Como cada ensaio individual tem um ruído diferente, na média de vários ensaios este ruído tende a se cancelar em número suficiente de ensaios, uma vez que o ruído em cada tentativa é considerado independente (SWEENEY; MCLOONE; WARD, 2013; CHEN et al., 2014). A adição de ruído de desvio padrão *epsilon* força o conjunto a esgotar todas as possibilidades de solução no processo de busca de IMF (CHEN et al., 2014).

Em relação ao número de tentativas, algumas centenas são geralmente suficientes para levar a um resultado razoável. Porém neste trabalho foram utilizadas 10, devido ao tempo de processamento. Testes preliminares mostraram diferenças significativas usando mais de 100 tentativas, porém, tempo de processamento torna-se inviável. Um ruído gaussiano com desvio padrão de 20% do sinal original é sugerido para o termo de ruído (ZHAOHUA WU, 2009). O objetivo do EEMD é obter uma melhor separação espectral em cada modo oscilatório do IMF.

2.3.3 Transformada de Wavelet Estacionária (TWE)

A transformada Wavelet decompõe uma função definida no domínio do tempo em um conjunto de funções, definidas no domínio do tempo e no domínio da frequência (MALLAT, 1989). A diferença entre a transformada de Wavelet e a transformada de Wavelet estacionária é que na primeira cada função de tempo no domínio transformado passou por um processo de *downsampling*, e logo cada componente tem um tamanho (em número de amostras) diferente, a transformada de Wavelet estacionária as sequências de coeficiente não são dizimadas em cada estágio (NASON; SILVERMAN, 1995), assim todas as componentes tem o mesmo tamanho.

A transformada Wavelet de um sinal $x(t)$ é definida por

$$W(b, a) = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{a}} \psi^* \left(\frac{t-b}{a} \right) dt \quad (19)$$

Onde a é a escala e b é o deslocamento, ψ^* é o complexo conjugado da Wavelet mãe ψ . Função Wavelet mãe deve satisfazer a condição:

$$C_\psi = 2\pi \int_{-\infty}^{+\infty} \frac{|\hat{\psi}(\omega)|^2}{\omega} d\omega \quad (20)$$

Onde $\hat{\psi}(\omega)$ é a transformação de Fourier de ψ . Como mostrado em (MALLAT, 1989), para uma transformada discreta de Wavelets, usando valores discretos para a e b , $a = 2^j$ e $b = 2^j k$, a transformada Wavelet discreta é definida por:

$$W(k, j) = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{2^j}} \psi^*(2^{-j}t - k) dt \quad (21)$$

Os coeficientes da transformada Wavelet são dados pela sequência d_1, d_2, \dots, d_j , onde j representa a ordem da TWE.

Neste trabalho foi escolhida a função mãe Daubchiet 4 (dB4), pois é a que mais se assemelha ao sinal de ECG. Esta função mãe também foi usada por (NAGAI; ANZAI; WANG, 2017; BHOWMIK; DEY; TIWARI, 2017).

2.4 Separação cega de fontes - SCF

A separação cega de fontes (SCF) consiste na recuperação de um conjunto de fontes não observadas de um conjunto de misturas observadas das fontes. As observações são sinais de sensores que recebem uma combinação diferente das fontes (CARDOSO, 1998). A combinação de fontes pode se referir a uma combinação espacial, uma combinação temporal ou ambas.

As técnicas de separação cega de fontes baseiam-se em uma ampla classe de algoritmos de aprendizado não supervisionado, com aplicação em diversos campos da engenharia (CHOI et al., 2005). Tais técnicas consistem em tomar os sinais lidos pelos sensores, provenientes da mistura das fontes, separá-los em seus componentes independentes ou pelo menos não correlacionados, com o objetivo de recuperar as fontes, não observáveis, usando apenas os sinais observados.

Nessa classe de técnica, cego refere-se ao fato de que

1. Os sinais das fontes não são observáveis,
2. Não há informações disponíveis sobre o sistema de mistura.

Isso torna a SCF uma ferramenta versátil para explorar a diversidade espacial de uma matriz de sensores (CARDOSO, 1998).

O modelo SCF assume n fontes $s_1(t), \dots, s_n(t)$ e m fontes, tantos quantos sensores, $x_1(t), \dots, x_m(t)$, para a forma mais simples, as misturas são lineares, instantâneas e o número de fontes é igual ao número de sensores, *i.e.*, $x_i(t) = \sum_{j=1}^n a_{ij} s_j(t)$ para $i = 1, 2, \dots, n$. Pode ser representado como uma equação matricial da forma:

$$X(t) = A.S(t) \quad (22)$$

O esquema exposto de fontes misturadas e separadas, pode ser visto na Figura 8. As fontes em S são misturadas pela matriz de mistura A formando os sinais X , únicos que são observáveis (mensuráveis). As fontes podem ser extraídas a partir dos sinais observados X , através da Matriz B , a qual produz Y , que é uma estimativa de S .

Uma estimativa das fontes pode ser recuperada das misturas observadas pela equação:

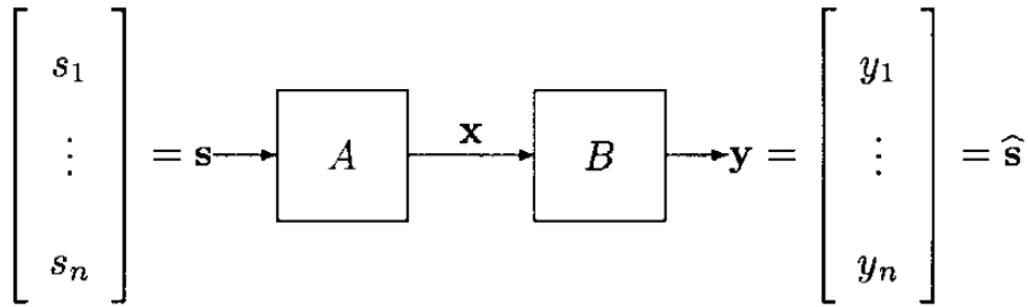


Figura 8: Modelo de misturas adaptado de (CARDOSO, 1998)

$$\hat{S}(t) = Y(t) = W.X(t) \quad (23)$$

Onde W implementa a matriz inversa de A , e $\hat{S}(t)$ é a estimativa de S .

2.4.1 Análise de componentes independentes

A análise de componentes independentes (ICA) é um método para encontrar fontes estatisticamente independentes a partir de misturas observáveis, utilizando estatísticas de ordem superior. ICA é um método de separação de fontes de classe cega, amplamente usado para remover artefatos (ZENG et al., 2016; MILANESI et al., 2008; MAHAJAN; MORSHED, 2015).

O conceito de independência é definido por 1) minimização da informação mútua ou 2) maximização da não-Gaussianidade (ZHANG; LI; MANDIC, 2016). O primeiro modo usa uma medida como Divergência de Kullback-Leibler e entropia máxima, e o segundo modo é motivado pelo teorema do limite central e usa curtose e negentropia. De acordo com o teorema do limite central, uma mistura linear de variáveis aleatórias independentes é necessariamente mais Gaussiana que as variáveis originais. Isto implica que o algoritmo ICA é restrito a no máximo um sinal de fonte Gaussiana.

O algoritmo do ICA tem dois estágios: o primeiro é o *whitening*, ou branqueamento e o segundo é uma transformação ortogonal. No estágio de *whitening*, o objetivo é remover quaisquer correlações nos dados, isto é, forçar os dados a serem descorrelacionados.

Para este propósito é usada uma transformação V , tal que $y = Vx$, de tal forma que $E\{yy'\} = I$, isto é conseguido definindo $V = C^{-1/2}$, onde $C = E\{xx'\}$ é a matriz de correlação dos dados. Então $E\{yy'\} = E\{Vyy'V'\} = C^{-1/2}CC^{-1/2} = I$, como desejado. O segundo estágio do ICA é uma transformação ortogonal do sinal descorrelacionado y , que faz uma rotação na densidade conjunta do sinal. A rotação apropriada é procurada iterativamente, maximizando a não-gaussianidade das densidades marginais (HYVÄRINEN; OJA, 2000, 1997).

Os dois estágios podem ser observados na Figura 9. De forma análoga à Figura 8, a matriz A é a matriz de misturas e a matriz B é a matriz de desmistura. Esta última é formada pela matriz W seguida pela matriz de rotação U (CARDOSO, 1998). Ambos os estágios estão representados na Figura 9.

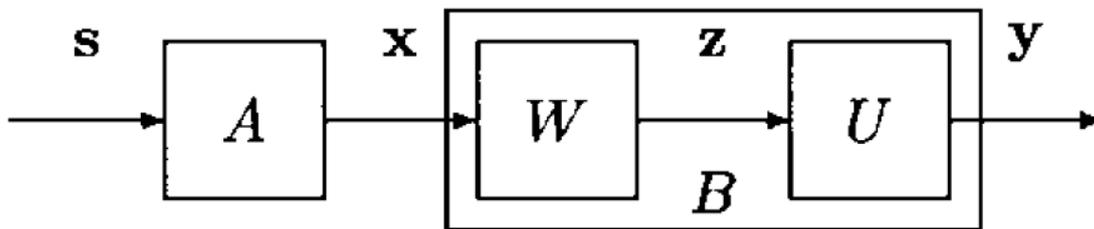


Figura 9: Estágios de separação de fontes adaptado de (CARDOSO, 1998)

2.5 Separação cega de fontes conjunta - *Joint Blind Source Separation - JBSS*

A SCF é útil para a decomposição de um conjunto de sinais em componentes independentes / não correlacionados. Os métodos de separação cega de fontes tornaram-se uma ferramenta amplamente utilizada para a análise de dados para o processamento de sinais biomédicos medidos de misturas de fontes não acessíveis (CHEN; WANG; MCKEOWN, 2016). Com a identificação das fontes de interesse e das fontes de artefatos, estas podem ser eliminadas antes do processo de reconstrução (CHEN et al., 2014). Uma limitação da SCF é que o resultado não garante o ordenamento original das fontes (CARDOSO, 1998). Porém, em muitas aplicações existem múltiplos conjuntos de dados compartilhando algumas fontes em comum. Os métodos JBSS (*Joint Blind Source Separation*) foram propostos para separar as fontes implícitas de cada conjunto de dados, mantendo um ordenamento consistente (CHEN et al., 2014).

Aqui, o termo *joint* significa que vários conjuntos de fontes misturadas são simultaneamente recuperadas dos múltiplos conjuntos de dados de sinais observados com base em suposições sobre dependências entre os conjuntos de dados (CHEN; WANG; MCKEOWN, 2016). A principal diferença entre a SCF e o JBSS é que a SCF analisa apenas um conjunto de dados individualmente, enquanto o JBSS generaliza a SCF para incluir relações de dependências semelhantes em vários conjuntos de dados (CHEN; WANG; MCKEOWN, 2016).

Separação cega conjunta de fontes (JBSS) é um meio de extrair fontes comuns presentes através de múltiplos conjuntos de dados, por exemplo, (EEG) e dados cinemáticos em conjunto para atingir os movimentos (CHEN et al., 2014) ou EEG e ressonância magnética funcional (LI et al., 2009). É um meio para examinar fontes comuns que podem ser encontradas em todos conjuntos de dados multidimensionais (CHEN et al., 2014). Neste trabalho busca-se descobrir os componentes independentes relacionados com a atividade cardíaca e os relacionados com os artefatos através dos conjuntos de dados de ECG.

Em problemas com múltiplos conjuntos de dados chamado *dataset*, assume-se que cada fonte latente dentro de um *dataset* é independente de todas as outras fontes dentro do *dataset* e relacionadas a uma única fonte latente dentro de cada outro *dataset*. Isso significa que as fontes dentro de cada conjunto de dados são independentes umas das outras e cada fonte é correlacionada com uma fonte dentro de cada outro conjunto de dados. Assim, o JBSS pode explorar as dependências das fontes nos conjuntos de dados. Além disso, o JBSS pode "alinhar" fontes dependentes nos conjuntos de dados (ANDERSON; ADALI; LI, 2012).

2.5.1 Notações e formulação usadas em JBSS

Existem duas formulações comuns de JBSS. A primeira pressupõe que o número de variáveis (número de amostras no tempo) é igual em todos os conjuntos de dados. Essa formulação emprega o conceito de Vetor de Componentes de fontes (*Source Componentes Vector - SCV*) definido através de vários conjuntos de dados em que todos os vetores tem o mesmo número de amostras. A segunda formulação pressupõe que todas as observações $P_m s$, ou seja, o número de sensores é igual entre os conjuntos de dados, é o *profile componentes vector - PCV* (CHEN; WANG; MCKEOWN, 2016). Os problemas que tratamos se encaixa nas duas situações, pois todos os segmentos tratados tem o mesmo número de amostras, e sempre todos os conjuntos de dados possuem o mesmo número de observações (número de sensores).

Suponha-se um total de M *datasets*, considere-se que $X^{[m]}$ denota o m -ésimo *dataset* com o tamanho $P_m \times N_m$, onde P representa o número de observações, no caso de biosinais P é o número de eletrodos sensores, e N representa o número de amostras coletadas em cada observação (sensor) (CHEN; WANG; MCKEOWN, 2016). O problema do JBSS agora é:

$$X^{[m]} = A^{[m]}S^{[m]}, 1 \leq m \leq M \quad (24)$$

Onde cada conjunto de dados é considerado uma mistura linear de fontes subjacentes não correlacionadas (ou independentes). $S^{[m]}$ é um vetor fonte aleatório com tamanho $L \times 1$, isto é, $\mathbf{S}^{[m]} = [\mathbf{s}_{(1)}^{[m]}, \mathbf{s}_{(2)}^{[m]}, \dots, \mathbf{s}_{(P_m)}^{[m]}]$

$X^{[m]}$ pode ser expresso por seus vetores de coluna como $\mathbf{X}^{[m]} = [\mathbf{x}_{(1)}^{[m]}, \mathbf{x}_{(2)}^{[m]}, \dots, \mathbf{x}_{(P_m)}^{[m]}]$

Nas últimas décadas, vários métodos de separação cega de fontes conjuntas foram propostos para conjuntos de dados múltiplos simultâneos (CHEN; WANG; MCKEOWN, 2016). Aqui, discutiremos brevemente a Análise de Correlação Canônica Multiset.

2.5.2 Multiset Canonical Correlation Analysis

Diferente do ICA, o CCA usa estatísticas de segunda ordem (SOS) para gerar componentes derivados de sua natureza não correlacionada, em vez de sua independência (SWEENEY; MCLOONE; WARD, 2013). CCA resolve o problema da SCF forçando as fontes a serem maximamente auto correlacionadas e mutuamente não correlacionadas, e a matriz de mistura é assumida como quadrada (CLERCQ et al., 2006; LI et al., 2009). Na estatística, a independência é uma condição mais forte do que decorrelação (CHEN et al., 2014). Por outro lado, como o CCA usa condições mais fracas que o ICA, é menos complexo computacionalmente devido ao uso de estatísticas de segunda ordem. Além disso, o algoritmo ICA não leva em conta a correlação temporal, o CCA é capaz de encontrar componentes não correlacionados que têm correlação espacial ou temporal máxima dentro de cada componente (SWEENEY; MCLOONE; WARD, 2013).

A análise de correlação canônica (CCA) é usada para identificar fontes correlatas quando há dois conjuntos de dados, quando as fontes contêm correlações cruzadas entre conjuntos de dados (ANDERSON; ADAL1; LI, 2012). Esse método usa um procedimento deflacionário para derivar pares de fontes que garantem que as fontes canônicas correspondentes entre dois conjuntos de dados sejam correlacionadas ao máximo e que as fontes canônicas dentro de cada conjunto de dados sejam mutuamente não correlacionadas (CHEN; WANG; MCKEOWN, 2016).

Considere-se dois conjuntos de dados com média zero em X_1 e X_2 com o tamanho

$P \times T$ onde P representa o número de sensores e T é o número de amostras no tempo. O CCA busca encontrar as matrizes W_1 e W_2 , chamadas de conjunto de vetores básicos, tal que a correlação entre as projeções dos sinais nesses vetores básicos seja mutualmente maximizada (CHEN; WANG; MCKEOWN, 2016; CHEN et al., 2017). A análise de correlação canônica consiste em encontrar uma combinação linear das variáveis X_1 e X_2 que tenham máximo coeficiente de correlação entre si. Isso leva à função objetivo com restrições da equação 25 (CHEN et al., 2017; CHEN; HE; PENG, 2014)

$$\max_{W_1, W_2} (W_1^T X_1 X_2^T W_2)^2 \quad (25)$$

Tal que:

$$W_1^T X_1 X_1^T W_1 = 1 \quad e \quad W_2^T X_2 X_2^T W_2 = 1 \quad (26)$$

Isto significa maximizar:

$$\max_{W_1, W_2} \frac{W_1^T C_{12} W_2^T}{\sqrt{W_1^T C_{11} W_1} \sqrt{W_2^T C_{22} W_2}} \quad (27)$$

Onde W_1 e W_2 são os vetores básicos, C_{11} e C_{22} são as matrizes de covariância de X_1 e X_2 respectivamente e C_{12} é a matriz de covariância cruzada de X_1 e X_2 (CLERCQ et al., 2006; SWEENEY; MCLOONE; WARD, 2013). A Matriz de auto-covariância é definida na equação 28, (CLERCQ et al., 2006)

$$C = E \left[\begin{pmatrix} X_1 \\ X_2 \end{pmatrix} \begin{pmatrix} X_1 \\ X_2 \end{pmatrix}^T \right] = \begin{bmatrix} C_{11} & C_{12} \\ C_{21} & C_{22} \end{bmatrix} \quad (28)$$

As matrizes de covariância são definidas na equação 29 (CHEN et al., 2017)

$$C_{ii} = E[(X_i - E(X_i))(X_i - E(X_i))^T] = \begin{bmatrix} cov(x_1, x_1) & cov(x_1, x_2) & \dots & cov(x_1, x_P) \\ cov(x_2, x_1) & cov(x_2, x_2) & \dots & cov(x_2, x_P) \\ \vdots & \vdots & \ddots & \vdots \\ cov(x_P, x_1) & cov(x_P, x_2) & \dots & cov(x_P, x_P) \end{bmatrix} \quad (29)$$

onde covariância $cov(x_i, x_j)$, pode ser obtido pela equação 30

$$cov(x_i, x_j) = E[(x_i - E(x_i))(x_j - E(x_j))^T] \quad (30)$$

A matriz de covariância cruzada é definida na equação 31

$$C_{ij} = E[(X_i - E(X_i))(X_j - E(X_j))^T] \quad (31)$$

Através de um processo deflacionário e usando o método de multiplicador de Lagrange em CCA encontra as matrizes W_1 e W_2 que maximizam a correlação ρ entre X_1 e X_2 (SWEENEY; MCLOONE; WARD, 2013)

$$\rho = \frac{W_1^T C_{12} W_2^T}{\sqrt{W_1^T C_{11} W_1} \sqrt{W_2^T C_{22} W_2}} \quad (32)$$

Derivando a equação 32 com relação a W_1 e W_2

$$C_{11}^{-1}C_{12}C_{22}^{-1}C_{21}W_1 = \rho^2W_1 \quad (33)$$

$$C_{22}^{-1}C_{21}C_{11}^{-1}C_{12}W_2 = \rho^2W_2 \quad (34)$$

Explorando as matrizes de covariância, vários pares de vetores básicos podem ser derivados para assegurar que as variáveis canônicas correspondentes entre os dois conjuntos de dados sejam correlacionadas ao máximo e as variáveis canônicas dentro de cada conjunto de dados são mutuamente não correlacionados (CHEN et al., 2017).

A correlação canônica entre X_1 e X_2 pode ser calculada resolvendo as equações 33 e 34. Assim, W_1 e W_2 são determinadas como os autovetores das matrizes $C_{11}^{-1}C_{12}C_{22}^{-1}C_{21}$ e $C_{22}^{-1}C_{21}C_{11}^{-1}C_{12}$ respectivamente, e o correspondente autovalor ρ^2 é o quadrado do coeficiente de correlação canônica (SWEENEY; MCLOONE; WARD, 2013). Uma dedução mais completa da metodologia pode ser encontrada em (KETTENRING, 1971; LI et al., 2009).

O primeiro par de variáveis (fontes) são os autovetores de W_1 e W_2 que correspondem ao maior coeficiente de correlação (ou autovalor) ρ_{max}^2 . Os próximos pares de sinais $(W_1, W_2)_{2...P}$ (sendo P sensores, ou P sinais) são os autovetores restantes em ordem decrescente de correlação (CHEN; HE; PENG, 2014), os quais são, eles mesmos, decorrelacionados com os autovetores anteriores (SWEENEY; MCLOONE; WARD, 2013).

Isso indica que as linhas correspondentes entre $\hat{S}_1(t)$ e $\hat{S}_2(t)$ são altamente correlacionadas, enquanto as linhas dentro de cada matriz individual não são correlacionadas entre si (CHEN et al., 2017). A técnica CCA, portanto, cria um peso matriz W que pode ser usado para separar as sinais observáveis em fontes auto-correlacionadas e mutualmente não correlacionadas (LI et al., 2009).

Multiset CCA estende a teoria do CCA para mais de dois conjuntos de dados, para identificar fontes canônicas que resumem a estrutura de correlação entre vários conjuntos de dados por transformações lineares (CHEN; WANG; MCKEOWN, 2016; CHEN; HE; PENG, 2014). Diferente do CCA onde é maximizada a correlação entre duas fontes, o MCCA procura otimizar uma função objetiva para fazer as fontes canônicas alcançarem a correlação máxima global (CHEN; WANG; MCKEOWN, 2016).

A partir de M data sets X_m ($m = 1, 2, \dots, M$), cada um com tamanho $P \times T$. O objetivo do MCCA é extrair fontes componentes os quais são decorrelacionados dentro de cada data set individual X_m e bem correlacionado em todos os M data sets. Neste trabalho foi utilizada uma das cinco funções de custo propostas por (KETTENRING, 1971), função de custo conhecida como (*SSQCOR*) que maximiza a soma de todos coeficientes de correlação mutua.

2.5.3 Independent Vector Analysis

IVA é a generalização do ICA de um para múltiplos conjuntos de dados. Ele foi formulado para garantir que as fontes correspondentes extraídas dos diferentes conjuntos de dados sejam maximamente dependentes enquanto as fontes extraídas de cada conjunto de dados sejam independentes umas das outras (CHEN et al., 2017). A dedução do algoritmo IVA esta além dos objetivos deste trabalho e sua dedução pode ser encontrada em (HAO et al., 2010; CHEN et al., 2014, 2017).

2.6 Revisão bibliográfica

Nesta seção serão mostrados os trabalhos já realizados para detecção e remoção de artefatos em biosinais. Serão mostrados inicialmente os trabalhos na área de detecção de artefatos em biosinais cardíacos, remoção de artefatos e biosinais cardíacos e por fim metodologias de remoção de artefatos em biosinais não cardíacos, estes são interessantes por mostrarem algoritmos que são usados neste trabalho.

2.6.1 Revisão bibliográfica de detecção de artefatos em sinais cardíacos

Em (LEE et al., 2012) os autores desenvolveram um algoritmo para detectar segmentos de sinal de ECG contaminados por artefato de movimento em dispositivos tipo *holder*. Tais dispositivos são vestíveis e monitoram o sinal de ECG do indivíduo 24 horas por dia nas suas atividades diárias e, portanto, são muito sujeitos a artefatos de movimento. Nesse trabalho, os autores pretenderam detectar segmentos de sinal com artefato, para reduzir os falsos alarmes de detecção de fibrilação atrial em pacientes monitorados diariamente (constantemente) por dispositivos *Holder*.

O método proposto neste trabalho pelos autores consiste em duas etapas: a primeira usa a decomposição EMD (*Empirical Mode Decomposition*) para isolar a primeira componente; a segunda etapa calcula as métricas estatísticas dessa componente para procurar por assinaturas de aleatoriedade associadas aos artefatos. O método utiliza as métricas: *Shannon Entropy*, média e variância. Como comparação utilizam as métricas estatísticas da primeira componente de um sinal sem artefatos para comparações. O algoritmo utiliza três limiares de classificação como método de detecção, um para cada métrica, e declara o sinal como contaminado por artefato se todos forem acima do respectivo limiar. O valor dos respectivos limiares foi calculado usando a curva de Característica de Operação do Receptor. Com segmentos de 5 segundos de sinal o método conseguiu resultados de accuracy: 0.9688, sensitivity:0.9549 e specificity: 0.9792.

Em (TAJI; CHAN; SHIRMOHAMMADI, 2017) os autores apresentam um método que pretende classificar os sinais de acordo com o nível de artefato. Eles utilizam 5 classes de acordo com o SNR do sinal de entrada (-10dB, -5dB, 0dB, 5dB e 10dB). O classificador foi projetado baseado em uma Máquina de Boltzmann Restrita (*Restrict Boltzmann Machine - RBM*) com três camadas, das quais as duas primeiras são treinadas para extração de características aplicadas na terceira camada para classificar os dados. O banco de dados utilizado foi o MIT-BIH *Arrhythmia database* com os dados de ECG limpo e MIT-BIH *Noise Stress Test database* com os sinais de artefato. Os sinais de artefatos foram misturados em quantidades calibradas com relação sinal ruído de -10dB, -5dB, 0dB, +5dB e +10dB. O método foi treinado e testado com segmentos de 5 segundos de sinal de ECG e apresentou accuracy entre 0.75 e 0.995 dependendo da relação sinal ruído do sinal de entrada.

Em (KRISHNAN; NATARAJAN; WARREN, 2010) os autores propõem métodos de detecção e remoção de artefatos em sinais de fotopletiografia (PPG). São propostos dois métodos de detecção de artefatos de movimento e dois métodos de decisão entre as detecções. Os autores propõem ainda um método de remoção de artefatos baseado em reconstrução da série de Fourier e separação cega de fontes.

O primeiro método de detecção de artefatos usa medidas estatísticas no domínio do tempo (Skew e Kurtosis), as quais contém informações sobre as variações de amplitude do formato da onda do PPG, e medida estatísticas no domínio da frequência (Kurtosis no domínio da frequência). O segundo baseado em *quadratic phase coupling*. O critério de

detecção utilizado para calcular os limiares de detecção em cada métrica foi a regra de Neyman-Pearson.

Os autores testaram dois métodos de fusão de detecção para decidir se o sinal possui ou não artefato de movimento. O método *hard decision* cria pesos para cada probabilidade de detecção calculada pelo método de Neyman-Pearson a fim de minimizar a probabilidade de erro. E a *soft decision* particiona cada região de hipóteses em subregiões mutualmente excludentes e associa um nível de confiança para um deles. *Soft decision* mostrou maiores probabilidades de detecção, e menores probabilidade de falha. Os autores propuseram ainda uma técnica para remoção de artefatos de sinais contaminados utilizando uma reconstrução de série de Fourier e separação cega de fontes no domínio da frequência dos sinais infra-vermelho e sinal de excitação.

Os métodos foram testados nos dados de PPG de pessoas executando tarefas e mostrou bons resultados mesmo na presença de artefatos significativos. Os autores ainda definem que a correta utilização destes métodos depende de uma fase de aprendizagem, quando são calculados os limiares de Neyman-Pearson para cada métrica.

2.6.2 Revisão bibliográfica de remoção de artefatos em sinais cardíacos

Em (MILANESI et al., 2005) é explorado o algoritmo de ICA (*Independent Components Analysis*) para remover artefatos. O algoritmo ICA resolve o problema de separação cega de fontes instantâneas, caso em que não existe atrasos na mistura. O modelo básico do ICA é o modelo de misturas instantâneas, isto significa que nenhum atraso é considerado no processo de mistura das fontes, e considera que os sinais captados pelos eletrodos são misturas lineares das fontes. Porém, levando-se em consideração o tempo de propagação do sinal da sua fonte até o eletrodo para gerar um modelo de dinâmica espacial-temporal, deve-se introduzir convolução no processo de mistura e considerar que as fontes tem diferentes tempos de propagação até cada sensor.

Neste trabalho os autores apresentam uma abordagem no domínio da frequência para solucionar o problema de misturas convolucionais, explorando o algoritmo ICA para misturas instantâneas, uma vez que a convolução no domínio do tempo é o produto no domínio da frequência. A ideia proposta pelos autores é usar a FFT dos sinais ao invés de usar os sinais no domínio do tempo. Esta abordagem tem duas ambiguidades. A primeira é a impossibilidade em determinar a ordem das componentes independentes extraídas. A segunda é que as componentes são extraídas até um fator de escala e de um fator de fase. Os autores usaram esta abordagem do problema de separação cega de fontes para remoção de artefatos de sinais eletrocardiograma (ECG) adquiridos por sistemas vestíveis. As componentes relacionadas com ECG são identificadas fixando um limiar adequado para a área abaixo do sinal de autocorrelação de cada fonte. As fontes que não passam nesse teste são descartadas antes da reconstrução.

Em (MILANESI et al., 2008) os autores comparam a aplicação dos modelos sICA (*standard ICA*), fICA (*frequency ICA*) e cICA (*temporally constrained ICA*) para supressão de artefatos de movimento em sinais reais de ECG. O trabalho apresenta dois propósitos: o primeiro é descobrir se a aplicação de misturas convolucionais pode ser mais benéfica nas áreas que a sICA é usualmente empregada; e o segundo é propor um método para obter um sinal referência para cICA diretamente do ECG sem nenhuma identificação preliminar do complexo QRS. Para completar estes dois propósitos sICA, fICA e cICA são contrastados, avaliando a capacidade do algoritmo de reduzir a quantidade de artefatos de movimento e recuperar a morfologia do ECG.

O algoritmo de sICA utilizado foi o Fast-ICA desenvolvido por (HYVÄRINEN; OJA,

1997), o qual busca separar as fontes independentes pelo teorema do limite central, buscando a não-gaussianidade através da estimativa de negentropia. O algoritmo para o ICA convolutivo é tomar a FFT de cada sinal de entrada do ICA e calcular os filtros FIR que compõem a matriz de mistura. O cICA aplica juntamente com os sinais de ECG um sinal do ECG filtrado com o intuito de remover o máximo possível do sinal cardíaco, a fim de ter uma amostra do sinal de artefato.

Nas três abordagens, foi utilizado o mesmo critério para remover fontes consideradas artefato, o valor da área debaixo do sinal de autocorrelação. Os autores explicam que este critério aproveita o caráter repetitivo do sinal de ECG que o distingue do sinal de artefato. No trabalho foram utilizados sinais de ECG de 2 eletrodos. Assim a separação cega de fontes encontra 2 fontes, e exclui a fonte que tiver menor área abaixo do sinal de autocorrelação. Nos testes realizados, o algoritmo cICA apresentou o melhor resultado sobre o fICA e o sICA, sob a métrica do coeficiente de correlação e índice de erro quadrático.

Em (KHAN et al., 2015) os autores descrevem que os filtros não são capazes de remover artefatos de movimento, pois ambos podem ter a mesma frequência, principalmente sob atividade física. O número de passos por minuto pode ser muito próximo do número de batimentos por minuto, e nesses casos os espectros se sobrepõem. O projeto foi desenvolvido pensando em utilizar um dispositivo de fotopleletismografia - PPG juntamente com um acelerômetro triaxial, para fornecer a informação de movimento do indivíduo.

Os autores utilizaram sinais de PPG de pessoas em atividade física juntamente com a informação de *ground truth* de ritmo cardíaco. O sinal do PPG foi decomposto utilizando EEMD (*Ensemble Empirical Mode Decomposition*), e tomam a segunda componente, pois é a componente cujos picos mais vezes coincidiram com o *ground truth*. Em uma segunda etapa do algoritmo, eles utilizam um filtro adaptativo RLS para remover do sinal de PPG os sinais correlacionados com os sinais dos acelerômetros. O projeto mostrou bons resultados, fornecendo a informação de ritmo cardíaco com erro médio de 1.02 batimentos por minuto. Porém, a grande desvantagem deste algoritmo é a necessidade de utilizar um acelerômetro, pois nem sempre o sinal de artefato esta correlacionado com o movimento.

Em (NAGAI; ANZAI; WANG, 2017) os autores propõem um algoritmo usando a Transformada Wavelet Estacionária (TWE) para remover o artefato de movimento sobreposto ao sinal ECG ao usar eletrodos de acoplamento capacitivos com a pele. Os eletrodos capacitivos são mais indicados para uso em longos períodos, apesar de serem mais sensíveis a ruído. Os eletrodos com gel são mais robustos ao ruído, porém deterioram em pouco tempo, porque o gel é absorvido pela pele.

Na SWT, ao submeter ao up-sampling os coeficientes dos filtros passa-alta e os filtros passa-baixa, é possível realizar uma transformação wavelet invariante no tempo. Isso é importante para encontrar coeficientes discrepantes como o artefato devido ao movimento do corpo e os componentes do sinal especificado, como o complexo QRS.

As características principais do complexo QRS são observadas nos coeficientes wavelet de d_1 a d_6 . O algoritmo proposto esta dividido em duas etapas. Na primeira parte calcula a energia do sinal a cada 0.1 s, e encontra os picos de energia, os quais correspondem ao complexo QRS ou a artefatos, com os valores de pico e calcula o limiar como alfa vezes a mediana do sinal de energia. Quando a energia for inferior ao limiar, considera um complexo QRS e conta o tempo entre eles e calcula a mediana dos intervalos, para calcular o ritmo cardíaco, e um limiar temporal. Se um pico de energia ocorrer antes do limiar temporal é considerado um artefato, e os coeficientes d_1 a d_6 são zerados.

Na segunda etapa é focado nos coeficientes d_6 a d_9 que correspondem aos componentes de baixa frequência. Então calcula os limiares D_{max} e D_{minimo} pela mediana dos

máximos locais e mínimos locais respectivamente dos coeficientes d_6 a d_9 . Os autores criaram um algoritmo baseado no tempo médio entre os complexos QRS para determinar se os coeficientes wavelet representam artefato ou sinal cardíaco. A partir dessa informação recriam o sinal de artefato e o subtraem do sinal original.

Os autores avaliam o efeito na remoção do artefato de movimento deste algoritmo aplicando-o a vários sinais de ECG com artefatos de movimento sobrepostos. Como resultado, os coeficientes de correlação dos sinais de ECG em relação aos limpos foram melhorados de 0,71 para 0,88 na mediana antes e depois da remoção de artefatos de movimento, o que demonstra a validade do algoritmo proposto baseado em SWT.

Em (BARHATTE; GHONGADE; TEKALE, 2016) os autores descrevem os principais artefatos do sinal de ECG: *Power Interference*, causado por aterramento pobre do equipamento de ECG, normalmente corrigido com filtro *notch* na frequência da rede. *Baseline wander*: ruído causado pela respiração do paciente, causam variação na linha de base do sinal, estes artefatos apresentam frequência menor de 0,5Hz, normalmente são insignificantes e afeta apenas o segmento ST da onda de ECG. Artefatos de movimento: podem chegar a 500% do sinal de ECG com durações de 100ms a 500ms. Causado por mudança na impedância eletrodo-pele, são caracterizados por picos no sinal causado por perda do contato entre eletrodo e pele, podem causar saturação do sinal.

A solução proposta pelos autores consiste em inicialmente remover a média do sinal e aplicar o sinal de ECG num bloco de PCA para reduzir a dimensionalidade do sinal (pois, segundo os autores aplicar o sinal de ECG com grande dimensionalidade no bloco ICA fornece resultados pobres. O vetor de entrada é transformado por uma transformação linear em um vetor com dimensionalidade menor, onde os elementos são descorrelacionados. Esta transformação linear fornece os auto-valores (D) e os auto-vetores (E) da matriz de covariância, estes são processados pelo ICA. Para cada componente do ICA é calculado o Kurtosis, e as componentes com kurtosis acima de um limiar é considerado uma fonte de ECG e as outras são fontes de ruído. Os autores testaram seu método no banco de dados *MIT-BIH arrhythmisa* misturados com ruído branco e obteve bons resultados na separação.

2.6.3 Revisão Bibliográfica de remoção e artefatos em biosinais não cardíacos

Neste seção será feita uma revisão dos trabalhos mais relevantes de remoção de artefatos de biosinais. Muitas técnicas foram desenvolvidas para outros biosinais que não os cardíacos, como por exemplo o EEG, porém as técnicas são relevantes e, por isso, foram revisadas.

Em (ZENG et al., 2016) os autores propõem uma metodologia para remover artefatos como pré-processamento para a classificação de sinais de EEG. Os autores elegeram os artefatos: piscar os olhos, ruído musculares, discontinuidades (variações nos eletrodos), e ruído branco para testar o método de remoção de artefatos, e por fim validaram o algoritmo no desempenho do classificador de convulsão, nas classes: não convulsão, pré-convulsão e convulsão. Os sinais de EEG foram coletados de indivíduos, e misturados artificialmente com sinais de artefatos simulados. Os artefatos podem comprometer severamente a accuracy do classificador

O algoritmo desenvolvido pelos autores para remover artefatos de sinais EEG esta baseado em decomposição EEMD e separação cega de fontes. A primeira etapa do método é a decomposição EEMD, nesta etapa cada sinal de EEG é decomposto em seis IMFs (*Empirical Mode Function* - Funções de Modo Intrínseco). A segunda etapa classifica as IMFs como **artefatos** ou **sem artefato** baseado nas métricas: Entropia e Kurtosis de cada

IMF, os autores definiram limiares de classificação para cada métrica. Na terceira etapa as IMFs classificadas como artefatos passam pelo processo de separação cega de misturas, com o intuito de concentrar as componentes de artefatos dos componentes de sinal, para isso é usado o ICA. Na quarta etapa é feita nova classificação de artefatos, também baseado nas mesmas métricas, porém agora com valores de limiar mais restritivos, e os componentes considerados artefatos são zerados. O sistema é mais restritivo temporalmente, pois se o segmento analisado é subdividido em trechos de 0,5 segundos, e se uma componente tem mais de 20% do tempo com artefato, todo o componente é considerado uma fonte de artefato. Na quinta etapa os sinais são misturados novamente pelo processo inverso da separação cega de fontes (multiplicação dos vetores pelo inverso da matriz de separação). Na última etapa, para desfazer o processo de decomposição os sinais de IMF são somados para formar os sinais de EEG sem artefatos.

Os autores comparam a este método com os métodos clássicos de remoção de artefatos, ICA e AWICA, com as seguintes métricas de desempenho: Erro médio quadrático Normalizado (NMSE) e Similaridade Estruturada (SSIM). O método EEMD-ICA foi o melhor em todos os cenários. Estes sinais livres de artefatos são inseridos no classificador de convulsão. O sinal pré-processado apresentou acurácia de 87,4%, enquanto o sinal coletado sem artefatos teve accuracy de 89,7%.

Em (HASSAN et al., 2011) os autores estudam o hystereogram (EHG) que pode ser usado para prever o trabalho de parto. Este sinal é problemático porque apresenta frequência muito baixa e amplitude muito baixa, está contaminado a várias outras fontes de sinais indesejados (ruídos), como por exemplo ECG do feto e da mãe, músculos abdominais, artefatos de movimento do feto e da mãe além de interferências de dispositivos externos. EHG tem maior parte da sua energia entre 0,1 e 1,5 Hz, ECG materno 1,2 Hz, respiração materna 0,2Hz, respiração fetal 1Hz, não pode ser rejeitado pelo filtro wavelet clássico.

O método desenvolvido pelos autores para remover artefatos dos sinais de EHG utiliza a técnica de Separação Cega de Fontes (*Caninical Correlation Analysis*) CCA, e se baseia na hipótese de que sinais do útero possuem maior coeficiente de autocorrelação que o ruído, assim o resultado esperado é que os CCA seja capaz de extrair as rajadas de sinais do útero. Os sinais coletados possuem 16 canais, em 6 mulheres em trabalho de parto. CCA resolve o problema da separação cega de fontes forçando cada fonte ser maximamente autocorrelacionada e mutuamente descorrelacionada, enquanto a matriz de misturas é assumida ser quadrada.

A metodologia de remoção de artefatos proposta é composta de duas etapas, na primeira eles aplicam a separação cega de fontes CCA, que fornece fontes maximamente autocorrelacionadas e minimamente correlacionadas. No trabalho eles utilizam análise dos histogramas de coeficiente de autocorrelação e autocorrelação para determinar um limiar, abaixo do qual a componente canônica será zerada. Esta primeira etapa já é capaz de eliminar boa parte dos artefatos de ruído eletrônico, artefatos de movimento, ECG materno e fetal. Na segunda etapa, cada um dos 16 canais de EHG foi decomposto utilizando EMD, e baseado em inspeção visual, os três primeiros IMFs são zerados, pois estes representam as maiores frequências. O artigo não menciona os parâmetros utilizados na decomposição, nem em quantas IMFs cada canal foi decomposto. Os autores compararam o nível de SNR deste método com outros métodos de remoção de artefatos clássicos como FastICA, e Wavelet. O CCA-EMD apresentou a melhor média de SNR de 6.74dB, comparados com 3.16dB do Wavelet e 5.02dB do FastICA.

Em (MAHAJAN; MORSHED, 2015) os artefatos de piscada podem ser removidos de

sinais EEG de maneira robusta usando algoritmos de separação cega de fontes como o ICA, porém sua accuracy depende fortemente da capacidade de identificar as componentes independentes ligadas a artefatos. Neste trabalho os autores apresentam um algoritmo estatístico não-supervisionado que utilize *modified Multiscale Sample Entropy (mMSE)* e Kurtosis para identificar componentes ligados a piscada de olhos. A intuição de que o mMSE pode identificar componentes independentes relacionados com artefatos está no fato de que a piscada está concentrada em intervalos pequenos de tempo com alta probabilidade e baixa entropia, ou seja, o valor do mMSE esperado de um componente de piscada é baixo, porque o padrão é mais regular e previsível em comparação com sinais neuronais. Assim, mMSE pode ser uma boa medida estatística de reconhecimento de atividade da pálpebra. Sobre o Kurtosis, na prática os sinais de EEG com artefatos de ECG e piscada tem tipicamente distribuições com pico com altos níveis de Kurtosis positivo, enquanto o ruído induzido por correntes de linha e eletrodo frouxo tem distribuições planas com kurtosis negativo. Assim medindo o kurtosis é possível identificar o componente relacionado com piscada. A metodologia desenvolvida pelos autores inclui normalização dos dados (média=0, e desvio padrão =1), usaram distribuição *t-Student* para calcular os limites inferior e superior. A componente independente com entropia maior que o limiar inferior é classificado como artefato, e toda componente independente com kurtosis menor que o limiar superior é classificado como artefato. As componentes independentes consideradas artefatos são tratadas com Wavelet para remoção do ruído. Neste método ao invés de substituir a componente independente por zeros, ela é tratada com wavelet biortogonal. Somente as componentes independentes considerados artefatos são tratadas com wavelet, isto reduz o esforço computacional.

Em (SWEENEY; MCLOONE; WARD, 2013) os autores desenvolveram uma técnica EEMD-CCA para remover artefatos de sinais *Single Channel*. Este trabalho bem semelhante ao EEMD-ICA, utilizou o CCA como separação cega de fontes, que tem duas vantagens frente ao ICA, primeira que retorna sempre o mesmo resultado para a mesma entrada (o ICA sofre do problema de permuta das fontes) e segundo que o CCA utiliza SOS (estatísticas de segunda ordem) enquanto o ICA utiliza HOS (estatística de alta ordem) o que torna o CCA computacionalmente mais eficiente.

Os autores testaram o método em sinais de EEG e fNIRS coletados independentemente, os sinais possuem alta correlação para cada modalidade. Os sinais de artefatos foram induzidos (nos eletrodos ou optodos) em um dos sinais e o outro é rotulado com o *ground truth*. Assim ele considera qualquer componente, que quando retirado, aumenta a correlação entre o sinal reconstruído e o *ground truth* é considerado um componente de artefato. O problema reside no fato de que em utilização normal, não é possível ter um sinal *ground truth*. Um segundo método de classificação de componentes em “Sinal” e “artefato” utilizado pelos autores foi o método proposto por (HASSAN et al., 2011). Este método assume que o coef. 1 da autocorrelação diferem nos sinais de artefatos dos sinais desejados.

Para validar o método eles usaram duas métricas de avaliação de desempenho: variação de SNR e correlação. A variação de SNR é a diferença entre SNR antes da remoção de artefatos e o SNR depois da remoção de artefatos. Em ambas as métricas a metodologia EEMD-CCA foi levemente superior à EEMD-ICA.

3 METODOLOGIA

Neste capítulo serão apresentados os bancos de dados utilizados como fonte de sinais para o processamento proposto. A seguir serão descritas as técnicas de detecção e remoção de artefato em biosinais. Também será detalhada a metodologia proposta para alcançar estes objetivos.

3.1 Banco de dados

O trabalho se propõe em remover artefatos de biosinais, principalmente biosinais cardíacos, tais como ECG (qualquer *lead*, AVF, AVL, AVR, I, II, III, MCL, MCL1, V1 e V2), PPG ou Sinais de pressão cardíaca (*Arterial Blood Pressure - ABP*, ou *pulmonary arterial pressure PAP*). Todos os testes realizados foram feitos utilizando sinais de ECG (MCL1 e I). O projeto proposto foi pensado para utilizar quaisquer biosinais cardíacos, inclusive uma combinação de sinais diferentes, *e.g.* ECG V1, PPG e ABP.

Nesse projeto foram utilizados dois bancos de dados: o *MIT-BIH Arrhythmia Database* (GOLDBERGER et al., 2000), (MOODY; MARK, 2001), o qual contém sinais de ECG de pacientes com arritmia cardíaca, de onde foram usados os sinais considerados sem artefato. Na verdade estes sinais possuem artefatos de movimento ocasionados por movimentos do paciente no leito do hospital, porém são poucos e esparsos, assim eles serão considerados como "sem artefatos". Este banco de dados contém 48 trechos de 30 minutos de registros de ECG de dois canais, obtidos de 47 indivíduos estudados pelo Laboratório de Arritmias MIT-BIH entre 1975 e 1979. Destes, foram utilizados os sinais dos pacientes com identificador 118 e 119, como amostra de sinal sem artefato. Estes sinais possuem alguns artefatos, visto que são aquisições longas e movimentação do paciente no leito causa artefatos no sinal adquirido, porém neste estudo foram consideradas sem artefatos. Destes pacientes foram coletados sinais de ECG em dois eletrodos: MCL1 e II. Estes sinais serão chamados, por simplificação, de ECG1 e ECG2.

O banco de dados *MIT-BIH Noise Stress Test Database* (MOODY; MULDROW; MARK, 1984) foi escolhido para fornecer sinais de artefato. Esta base de dados inclui 3 tipos de gravações de meia hora de ruído/artefato, típicas em registros de Eletrocardiograma - ECG em ambulatorios. Os sinais foram adquiridos com a mesma frequência de amostragem de o *MIT-BIH Arrhythmia Database*, 360 amostras por segundo. As gravações de ruído foram feitas usando voluntários fisicamente ativos e sistemas de aquisição de ECG coletando em dois eletrodos. Os eletrodos foram colocados nos membros em posições nas quais os sinais cardíacos não eram sensíveis, afim de coletar apenas os sinais referentes ao artefato. Foram criados três registros de ruído, os quais foram montados a partir das gravações, selecionando intervalos que continham predominantemente artefato de linha de base ('bw'), muscular (EMG) ('ma') e artefato de movimento do eletrodo

(‘em’).

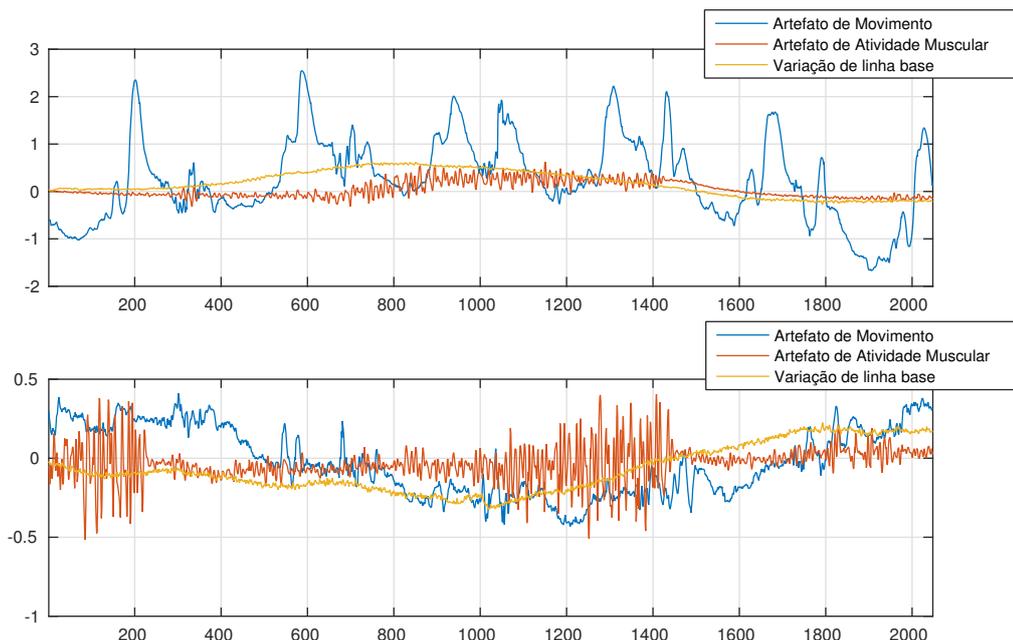


Figura 10: Exemplo dos 3 tipos de sinais de artefatos coletados em 2 canais.

A Figura 10 mostra um exemplo de cada um dos três tipos de sinais de artefatos coletados em dois eletrodos. O artefato de movimento de eletrodo é considerado o mais problemático, já que pode imitar a aparência de batimentos cardíacos e não pode ser removido por simples filtragem (GOLDBERGER et al., 2000), por isso foi o artefato utilizado neste trabalho.

Os sinais de ECG "limpos" do banco *MIT-BIH Arrhythmia Database* foram misturados com os sinais de artefato de movimento 'em' do banco de dados *MIT-BIH Noise Stress Test Database* por um processo de soma ponderada. A ponderação serve para criar sinais com diferentes SNR. Tanto os sinais limpos quanto os sinais de artefatos possuem meia hora de duração, assim a soma é feita amostra com amostra, pois ambos os sinais possuem o mesmo número de amostras. Os sinais de ECG contaminada com artefato foram criados usando os registros "limpos" (identificadores 118 e 119) do MIT-BIH Arrhythmia Database, aos quais foram adicionadas quantidades calibradas de ruído do registro 'em' sinais 'ruidosos' com relação sinal-ruído (SNR - *Signal Noise Ratio*) de: -6dB, 0dB, 6dB, 12dB, 18dB e 24dB. Ressalta-se que, com relação sinal ruído -6dB a potência do sinal de ruído é praticamente 4 vezes a potência do sinal de ECG. E com SNR de 24dB o ruído de artefato é muito pequeno.

A Figura 11 mostra um sinal de ECG com artefatos e sem artefato e um sinal de ECG com artefato do paciente 118, e a Figura 12 mostra o sinal com e sem artefato do paciente 119.

3.2 Detecção de artefatos

Nesta seção será detalhado o bloco de detecção de artefatos em segmentos de biosinais. Serão detalhados os algoritmos de classificação, bem como as métricas utilizadas na classificação.

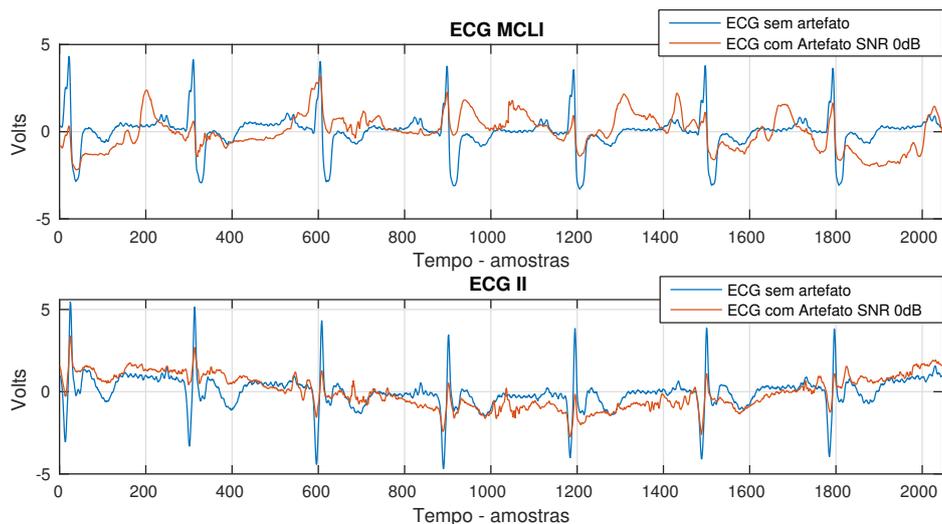


Figura 11: Exemplo de um frame com os sinais ECG MCLII e ECG II sem artefato e com artefato com SNR 0dB do paciente 118

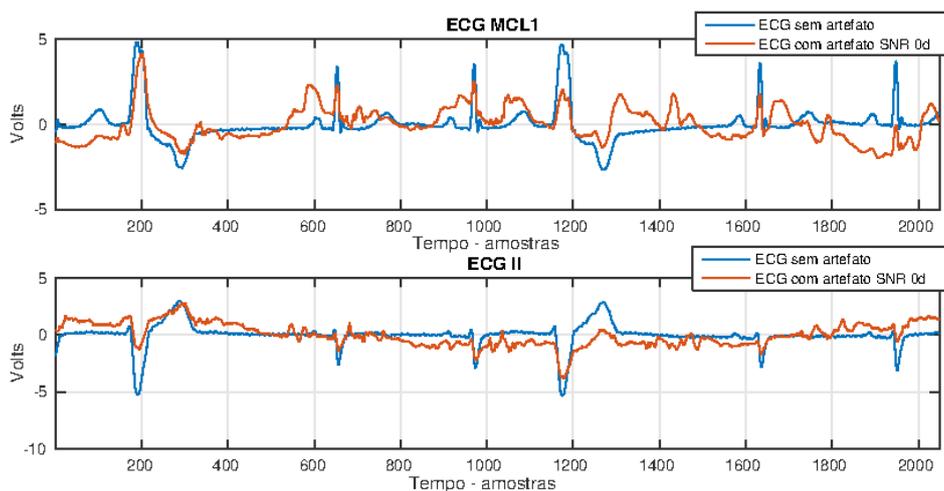


Figura 12: Exemplo de um frame com os sinais ECG MCLII e ECG II sem artefato e com artefato com SNR 0dB do paciente 119

3.2.1 Estudo preliminar

A metodologia de detecção de artefatos em biosinais foi baseada em um estudo preliminar do efeito do artefato sobre as métricas estatísticas. Cada métrica foi testada em segmentos com e sem artefatos, para verificar a sua capacidade discriminar entre segmentos contaminados ou não.

3.2.2 Métricas Estatísticas como Detectores de Artefatos

As métricas, apresentadas na seção 2.2.1 foram implementadas e aplicadas em ambos trechos de sinal: livre e contaminado por artefatos. Como já detalhado na seção 3.1, nesse trabalho tem-se o controle de ambos os sinais: de ECG e de artefato. Assim, foi criado um sinal específico para analisar o comportamento das métricas sobre sinais de ECG com e sem ruído de artefato. Foi adicionado após os primeiros 5 minutos de cada registro, durante segmentos de dois minutos, alternados com segmentos limpos de dois minutos.

As relações sinal-ruído (SNR) durante os segmentos ruidosos desses registros são: -12 dB, -6 dB, 0 dB, 6 dB, 12 dB, 18 dB e 24 dB.

Assim, foi calculado o valor de cada uma das métricas sobre cada segmento correspondente. As Figuras 13 a 20 mostram os trechos de sinais com diferentes intensidades de interferências de artefato (no tempo) e os resultados da métrica estatística por segmento. É possível ver nessas Figuras, que existe uma relação entre a presença de artefatos e os valores das métricas. Esta variação no valor das métricas com artefato e sem artefato não é direta, e será explorada com a decomposição dos sinais e separação cega de fontes nas seções subsequentes dessa dissertação. Nas Figuras, o traço "alfa" representa o sinal sem artefato.

Na Figura 13 é mostrado o efeito do artefato sobre a métrica skew. O Valor de skew é maior nos frames contaminados. Também o valor do skew é maior quanto maior a potência do artefato em relação à potência do sinal.

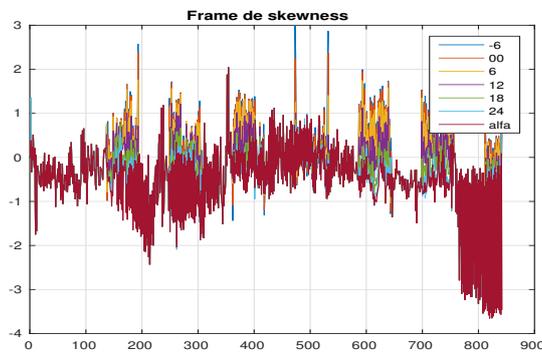


Figura 13: Skewness

Na Figura 14 é mostrado o efeito do artefato sobre a métrica kurtosis. No caso do kurtosis o artefato age diminuindo o valor desta métrica. O valor do kurtosis é ainda menor quanto maior a potência do artefato em relação à potência do sinal.

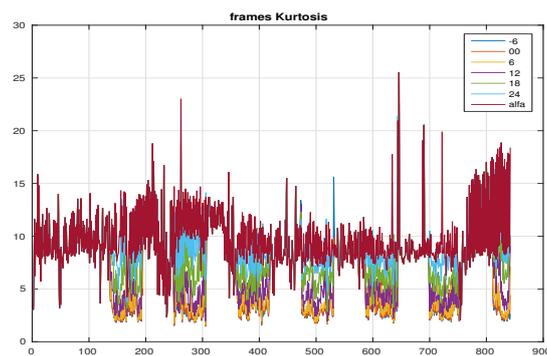


Figura 14: Kurtosis

A seguir, na Figura 15 a métrica Kurtosis no domínio frequência está representada para cada frame dos sinais. Esta métrica é sensível ao artefato, pois até um sinal com 24db de SNR (em ciano no gráfico), ou seja, muito pouco artefato, já apresenta visível diferença em comparação ao sinal sem artefatos.

Observa-se na figure 16 a diminuição do valor da entropia nos trechos contaminados por artefatos. Este efeito era esperado visto que, como mostrado em 2.2.1, a entropia mede o grau de aleatoriedade de um sinal.

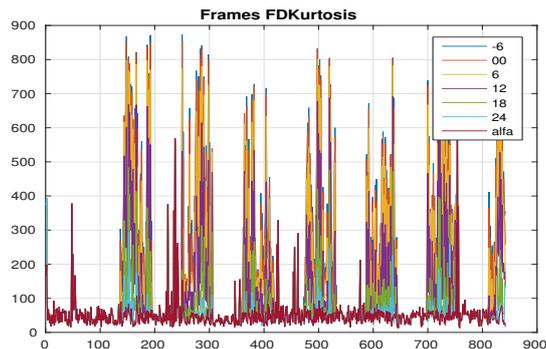


Figura 15: Kurtosis no domínio frequência

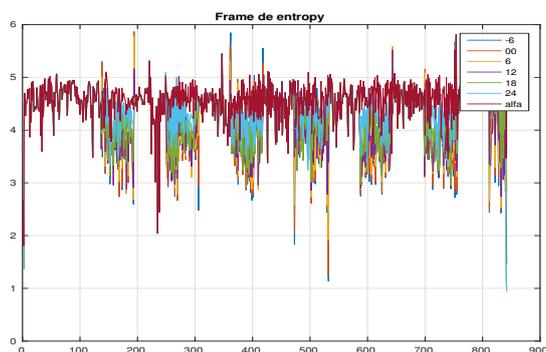


Figura 16: Entropia

Como descrito em 2.2.1 a Entropia de permutação analisa padrões de permutação em séries temporais. A métrica tem uma tendencia de apresentar valores menores para segmentos com artefato, isto pode ser visto na Figura 17.

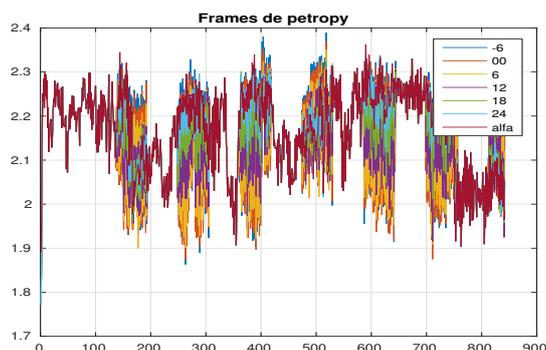


Figura 17: Entropia de Permutação

A entropia de Shannon é uma medida de quanta informação existe no sinal analisado. A entropia de Shannon caracteriza aleatoriedade (LEE et al., 2012). Quanto menor o valor da entropia de Shannon, mais informação o sinal possui. Na Figura 18 a) vemos que os trechos com artefato possuem maior valor de entropia de Shannon e consequentemente menos informação.

As métricas de autocorrelação coeficiente 2, são usadas em (CLERCQ et al., 2006) e (SWEENEY; MCLOONE; WARD, 2013) como um marcador de artefatos. Ambos os trabalhos estabelecem que sinais com autocorrelação coeficiente 2 abaixo de limiares fixos são considerados artefatos. Porém seus trabalhos são destinados a sinais muito diferentes

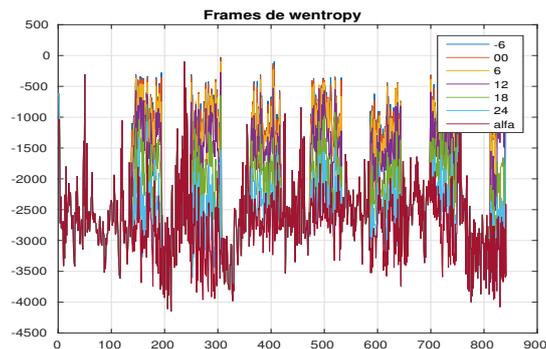


Figura 18: Shannon Entropia

dos cardíacos, eletro-histograma e eletro-encefalograma, respectivamente. Estes sinais são compostos por componentes de mais baixa frequência, e também os artefatos que contaminam estes sinais são diferentes dos tratados neste trabalho. Os testes preliminares mostraram que os sinais com altos valores de autocorrelação coeficiente 1 estão relacionados a artefato.

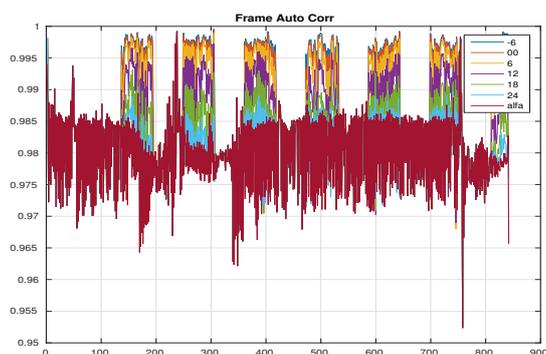


Figura 19: Autocorrelação lag1

A área abaixo do sinal de autocorrelação, mostrado na Figura 19, é baseada no mesmo fenômeno da autocorrelação coeficiente. E foi utilizada em (MILANESI et al., 2008) e (MILANESI et al., 2006) como marcador de artefato de movimento em ECG. Esta medida se aproveita a periodicidade do sinal de ECG, ou seja do complexo QRS, em comparação com outros sinais (MILANESI et al., 2005). Sinais com componentes consideravelmente periódicos mostram diferentes valores médios de magnitude da função de autocorrelação do espectrograma, em relação da computada para sinais não periódicos.

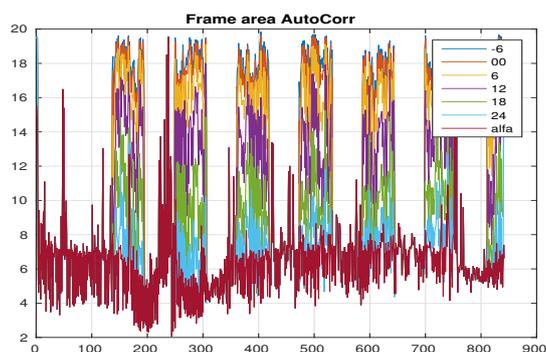


Figura 20: Área abaixo do sinal de autocorrelação

Os classificadores foram treinados usando as 8 métricas de cada sinal ECG. O banco de dados fornece sinais de 2 eletrodos de cada paciente e assim a classificação é feita no espaço das métricas, um espaço vetorial de 16 dimensões.

A Figura 21 mostra o diagrama de blocos par a detecção de artefatos em sinais de ECG. A etapa de aprendizagem ou treinamento está destacada em azul, e a etapa de testes em vermelho. A seguir serão descritos os blocos do diagrama.

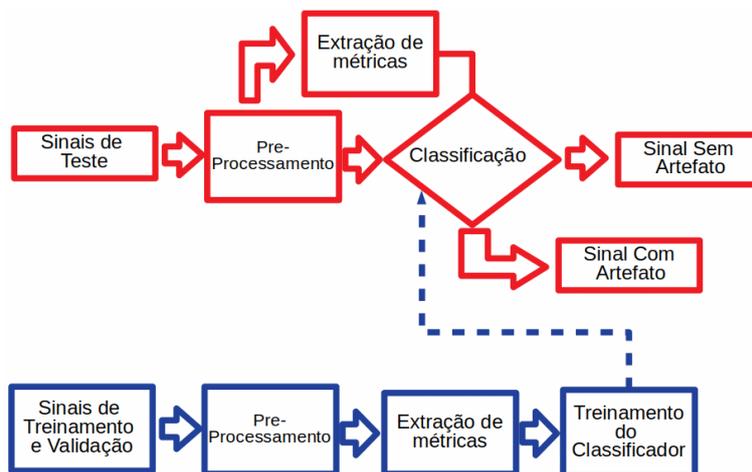


Figura 21: Diagrama esquemático proposto para detectar segmentos com artefato

3.2.3 Pré-processamento do sinal

O Pré-processamento consiste na segmentação dos sinais. Cada biosinal foi segmentado em blocos de 2048 amostras, com sobreposição de 256 amostras. O número de amostras foi definido em uma análise experimental de desempenho das métricas estatísticas, e suas capacidades de discriminar entre segmentos com artefato e segmentos sem artefatos. Neste estudo preliminar, foi observado como as métricas se comportavam em segmentos de 1024, 2048, e 4096 amostras. Verificou-se que quanto maior o tamanho do segmento, melhor as métricas discriminam os artefatos. Porém o segmento de 4096 mostrou-se muito lento (na estrutura utilizada nesse trabalho), na etapa de decomposição. Assim foi escolhido o tamanho intermediário de 2048 amostras para cada segmento.

O bloco de Pré-Processamento consiste em remover a média do sinal e dividir pelo desvio padrão. Esse procedimento normaliza o sinal. Assim, todos os trechos possuem média nula e desvio padrão unitário. A normalização é executada para que os resultados quantitativos se tornem independentes dos indivíduos nos quais os sinais são coletados.

3.2.4 Classificador

O banco de dados foi dividido em três partes: treinamento, validação e teste, conforme mostrado na Figura 22. Nessa Figura estão representados 4 sinais de 30 minutos. Eles foram subdivididos em segmentos de 2048 amostras com sobreposição de 256 amostras, totalizando 363 segmentos. Destes, foram escolhidos aleatoriamente 30% para servir de teste do sistema. Os outros 70% foram usados para treinamento e validação. Em (AHSAN H. KHANDOKER MARIMUTHU PALANISWAMI, 2009) são usados 66% dos dados em treinamento, e 34% dos dados para teste. Em (ZHANG et al., 2017), foram feitos ensaios reais de 30 minutos para treinamento e 30 minutos para teste. Em (GÉRON, 2017) menciona que usualmente 20% dos dados são deixados para a etapa de teste. Neste

trabalho optou-se por pela proporção mencionada. Todo o processo de treinamento dos classificadores foi feito utilizando o processo de validação cruzado com o método k-fold, com $k = 10$ (HAYKIN, 2009). Isso significa que o processo de treinamento foi repetido 10 vezes, cada vez com 90% dos dados de treinamento (GÉRON, 2017).

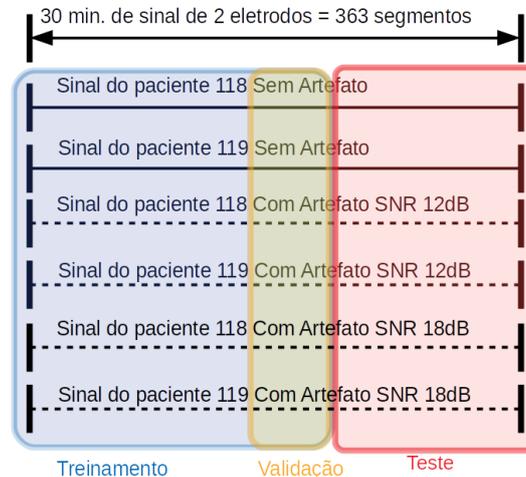


Figura 22: Representação da composição dos conjuntos de treinamento e teste

O conjunto de treinamento foi gerado a partir dos sinais com e sem artefatos. O banco de dados *MIT-BIH Noise Stress Test Database* (MOODY; MULDRON; MARK, 1984) utilizado é composto de sinais de 2 pacientes (identificados como 118 e 119). O sinal de cada paciente é composto por sinais ECG de dois eletrodos, e estes mesmos sinais misturados com os sinais de artefato de movimento com SNR de 12dB e um com SNR de 18dB, conforme mostra a Figura 22. A Figura 22 mostra uma representação destes sinais constituintes do banco de dados utilizado no processo de treinamento e validação. Os segmentos de treinamento foram escolhidos aleatoriamente no banco, embora na imagem pareça que são os 70% iniciais do banco. E 30% dos segmentos foi utilizado para teste do sistema. Os resultados apresentados de desempenho dos classificadores são referentes a 30% dos dados de teste.

No total foram 2544 segmentos, divididos em 1781 para treinamento/validação e 763 para teste. O conjunto de treinamento era composto por 611 segmentos sem artefatos e 1170 segmentos com artefato, os quais receberam o mesmo rótulo independente da relação sinal ruído. O conjunto de teste foi composto por 237 segmentos sem artefatos e 526 segmentos com artefato.

A detecção de artefato classifica o par de sinais conjuntamente, assim, os sinais dos dois eletrodos são classificados como artefato, ou como livre de artefato. No caso de ser classificado como artefato, ambos os sinais serão tratados na etapa de remoção de artefatos. Cada segmento composto por uma matriz de tamanho $[2 \times 2048]$ gera 16 métricas, sendo 8 de cada vetor $[1 \times 2048]$. Essas 16 métricas formam um ponto em um espaço de 16 dimensões do classificador e dependendo de onde este ponto estiver, ele será classificado com "Artefato" ou "Sem Artefato".

Foram testados 4 classificadores diferentes com 3 aprendizados supervisionados: Máquina de vetores de suporte (*SVM*), K vizinhos mais próximos, (*KNN - k-nearest neighbors*), Árvore de decisão (*Decision Trees*) e um aprendizado não-supervisionado: *Kmeans*. Este classificador serve para detectar os segmentos que possuem artefato. Os algoritmos de classificação serão avaliados principalmente de acordo com a capacidade de reduzir o número de falsos negativos, já que esse é o pior caso.

O classificador SVM, conforme já relatado não utiliza todas as instâncias do conjunto de treinamento para criar a função discriminante. Este algoritmo baseia-se apenas em instâncias limítrofes de cada região. Uma das etapas do algoritmo de classificação é selecionar as instâncias que servirão de vetores de suporte. São escolhidas as instâncias mais próximas do limiar de classificação. Entre as 1781 instâncias de treinamento foram utilizadas cerca de 200 instâncias como vetor de suporte. Estas instâncias escolhidas são chamadas de vetores de suporte. A Figura 23 mostra as instâncias de treinamento e os vetores de suporte escolhidos no treinamento. Embora o conjunto de treinamento possua 16 dimensões, a imagem mostra uma projeção em apenas duas dimensões para melhor compreensão: o kurtosis e skew do canal 1.

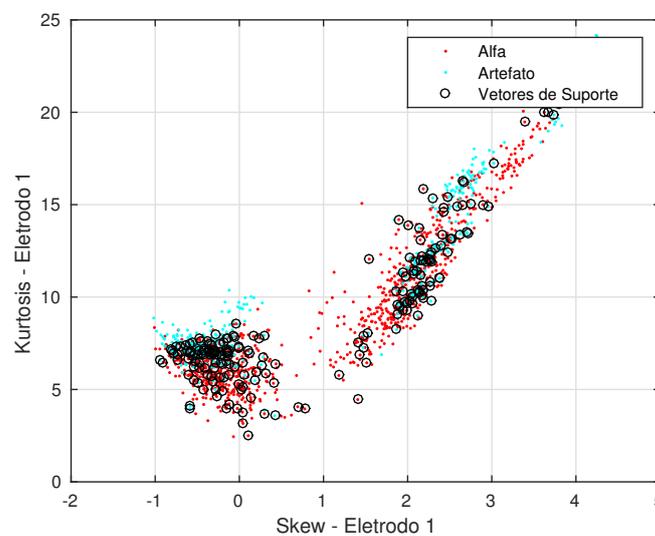


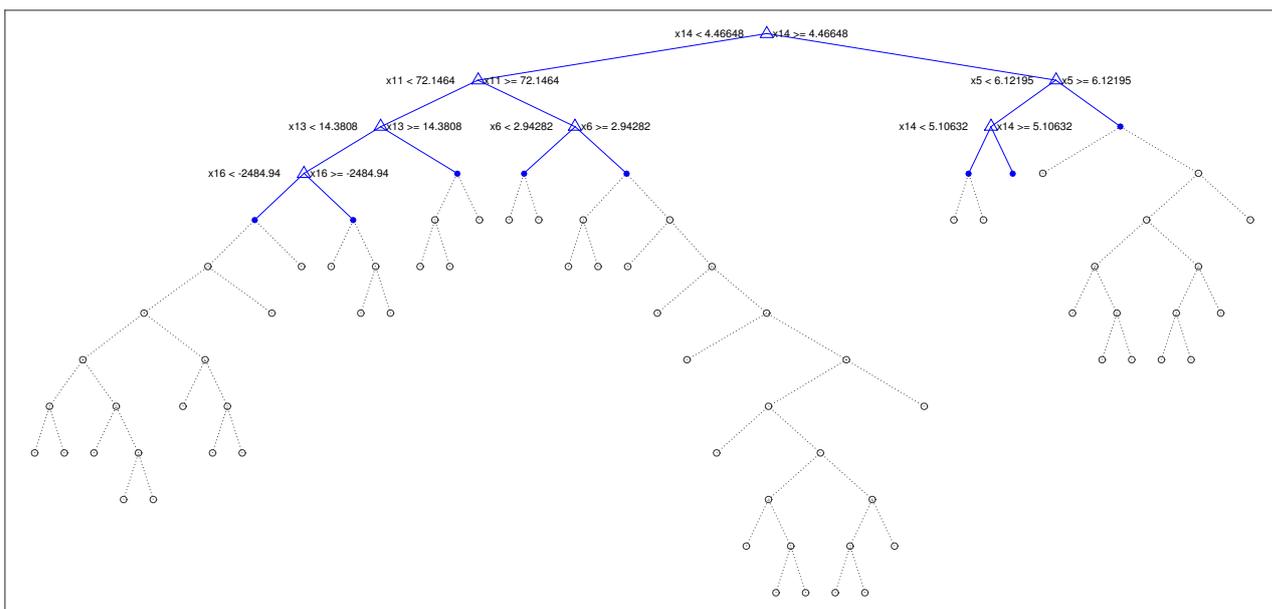
Figura 23: Projeção sobre os eixos Kurtosis e Skew das instâncias de treinamento e dos vetores de suporte

O classificador baseado em árvore de decisão, conforme descrito no capítulo anterior calcula limiares e testes sequenciais para classificar as instâncias. A árvore gerada pode ser vista na Figura 24.

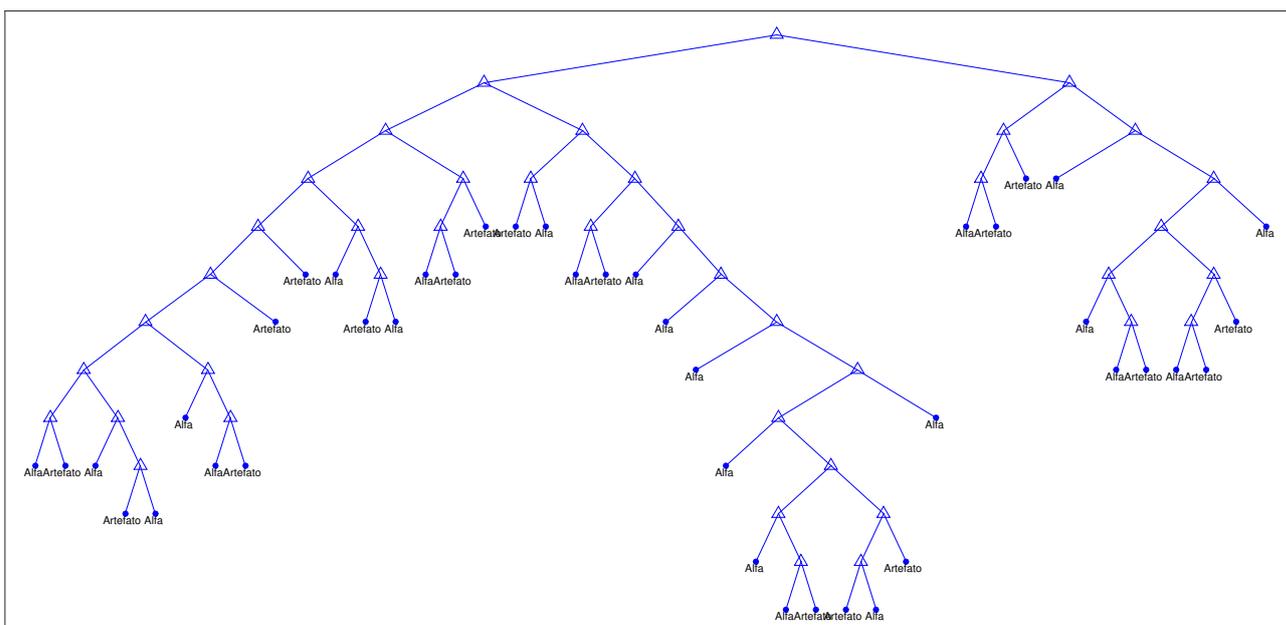
O classificador baseado em K vizinhos mais próximos, foi testado com várias medidas de distância: distância euclidiana, distância de Minkowski, distância de Chebchev, distância de Mahalanobis, distância de Spearman. A que apresentou melhor resultado foi a distância euclidiana pois apresentou melhor sensitivity e specificity. Também foram testados diferentes números de vizinhos: 3,5,7,10 e 15. O número que apresentou melhor desempenho foram 5 vizinhos. Os resultados apresentados a seguir são referentes à distância euclidiana com 5 vizinhos mais próximos.

A Figura 25 mostra os cinco vizinhos mais próximos para três medidas de distâncias diferentes. Pode-se perceber que os resultados são diferentes dependendo de qual medida de distância for adotada.

O único classificador não-supervisionado, Kmeans, conforme visto no capítulo anterior, busca os centroides de cada classe. Na Figura 26 são representados os dois centroides referentes a cada uma das classes, em uma projeção em duas dimensões.



Detalhe dos limiares de decisão



Detalhe das folhas classificadas

Figura 24: Parte da árvore de decisão gerada a partir dos dados de treinamento.

3.3 Remoção de Artefatos utilizando Decomposição de Sinais

A decomposição de sinais é o primeiro estágio da arquitetura proposta para a remoção de artefatos. A ideia principal deste bloco é decompor cada um dos sinais vitais em um conjunto de sinais no tempo, que possam ser facilmente rearranjados por operadores lineares.

Neste trabalho foram implementados dois métodos de decomposição distintos: os algoritmos EMD e EEMD, que baseiam-se em características morfológicas do sinal, e a decomposição Wavelet estacionária, que baseia-se em características espectrais dos si-

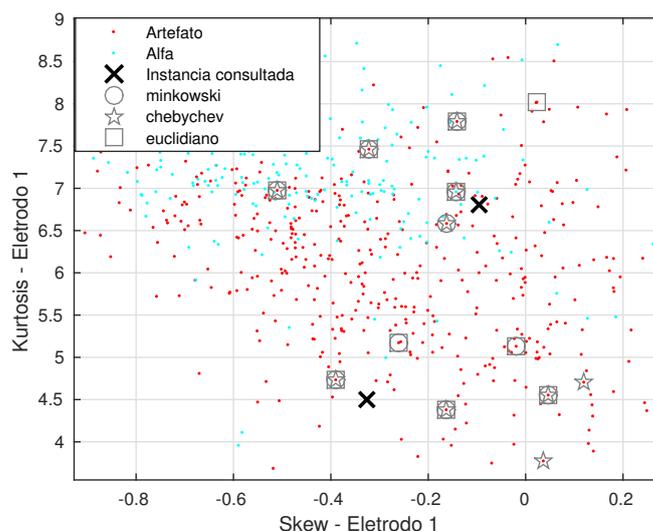


Figura 25: Distâncias testadas para dois exemplos, um alfa e um com artefato.

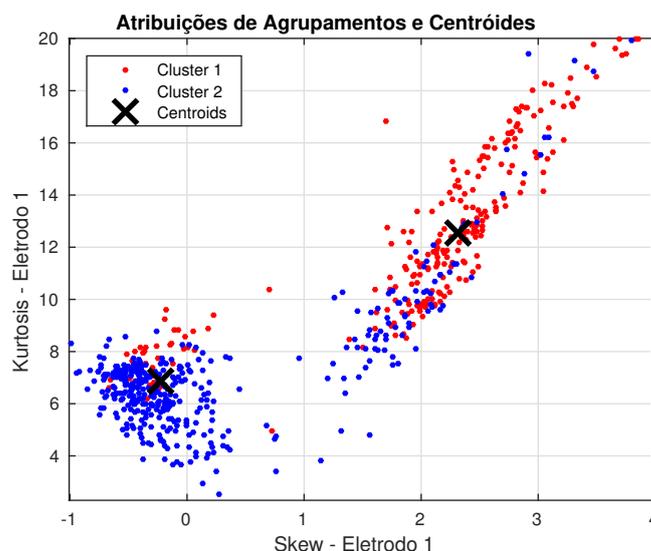


Figura 26: centroides de cada uma das classes

nais. Trabalhos como (LEE et al., 2012; BHOWMIK; DEY; TIWARI, 2017; TAN et al., 2014; RAGHURAM; SIVANI; REDDY, 2014; WENG; BLANCO-VELASCO; BARNER, 2006) utilizam metodologia semelhante para remover artefatos de biosinais, classificando e excluindo os componentes relacionados a artefatos. O sinal é então, reconstruído apenas com os componentes relacionados ao sinal de interesse.

Cada componente é constituída por características específicas do sinal original (no caso EEMD e EMD características morfológicas e, no caso Wavelet, características espectrais). Dessa forma, é possível identificar componentes relacionados a artefatos. Cada componente é classificada em duas classes distintas: "artefato" ou "não artefato". Esta classificação baseia-se em parâmetros estatísticos de cada componente e serve para remover somente artefatos. No caso de classificação incorreta, ocorre em perda de qualidade de sinal.

A Figura 27 mostra a metodologia de remoção de artefatos por decomposição de si-

nais implementada nesse trabalho. A etapa de treinamento dos classificadores está representada em azul e etapa de teste dos classificadores em vermelho. As duas etapas são constituídas de bloco de decomposição e extração de métricas estatísticas, as quais serão detalhadas a seguir. A Figura 27 ainda mostra que apenas as componentes 6, 7 e 8 são testados. O bloco foi implementado dessa forma porque os testes preliminares mostraram que os artefatos se concentram nas últimas componentes.

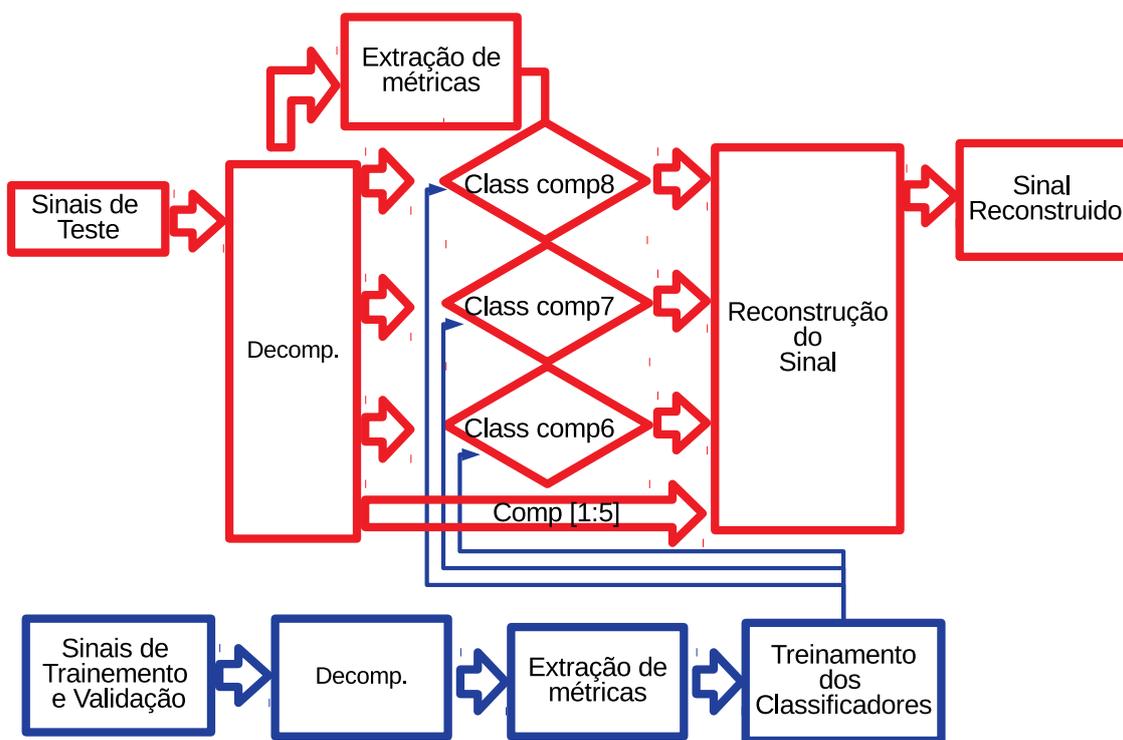


Figura 27: Diagrama em blocos do sistema proposto

Testes preliminares de blocos dessa implementação, possibilitaram a avaliação de parâmetros de decomposição como tamanho do frame e número de componentes, bem como o efeito da remoção de componentes na remoção de artefatos. A seguir serão detalhados os blocos do sistema.

3.3.1 Decomposição de sinais

Para a etapa de decomposição de sinais foram testados três metodologias, a EEMD, EEMD e a Transformada de Wavelet Estacionária. Dois parâmetros são determinantes nessa etapa: o tamanho de cada frame, e o número de componentes utilizados na decomposição. A escolha desses parâmetros foi feita empiricamente, por meio da avaliação de resultados de testes preliminares com sinais com e sem artefatos.

3.3.1.1 Testes preliminares Decomposição de sinais

Nos procedimentos preliminares, foram testados frames de tamanho 1024, 2048 e 4096 e decomposições em 6, 8 e 10 componentes. Os parâmetros de desempenho analisados foram: custo computacional da decomposição e capacidade das métricas estatísticas de discriminar componentes com e sem artefatos.

Quando fazemos a comparação entre as componentes de um sinal com artefato e um sinal sem artefato, como mostrado nas Figuras 29, 30 e 31, podemos perceber que as primeiras componentes com artefato são bastante parecidas das componentes do sinal sem artefato. As maiores diferenças acontecem nas últimas componentes. Essa observação levou a conclusão de que os artefatos se concentram nas últimas componentes.

Quanto mais componentes maiores as possibilidades de remoção de artefatos sem remover sinal de interesse, pois um grande número de componentes significa que o sinal está mais segmentado e maiores as chances de encontrar componentes que contenham apenas artefatos. Um aspecto interessante é que os algoritmos EEMD e EMD são processos iterativos de decomposição, assim, comparando a decomposição de um sinal A em 10 componentes com a decomposição do mesmo sinal A em 6 componentes, a soma das componentes 6, 7, 8, 9 e 10 do primeiro caso é igual a componente 6 do segundo caso. Isso ocorre porque o processo iterativo encontra a próxima componente a partir do resto da decomposição da iteração anterior. Genericamente, nos processos de decomposição EMD ou EEMD, uma decomposição em N componentes chamada de $decompN$ e o mesmo sinal decomposto em M componentes chamada $decompM$, com $M > N$, a N_{esima} componente de $decompN$ é igual ao somatório das componentes $N, N + 1, \dots, M$ de $decompM$.

Um importante aspecto percebido nos testes é que as métricas tem melhores resultados com pequenos números de componentes. Assim, em uma decomposição com 6 componentes, as métricas da componente 6, são mais capazes de discriminar os artefatos do que as componentes 6, 7, 8, 9 e 10 do mesmo sinal decompostos em 10 componentes. Este fenômeno ocorre porque todos os artefatos estão somados na componente 6, ou existe mais energia relacionada ao artefato do que no caso de 10 componentes. Por um lado, se deseja mais componentes para aumentar as chances de encontrar uma componente que possua apenas artefato, por outro lado isto torna mais difícil de detectar uma componente com artefato. Por esse motivo optou-se por utilizar decomposições em um número intermediário de **8 componentes**, que nos testes permitiu razoável capacidade discriminação e separação de artefatos.

Outro aspecto importante para a implementação do projeto em tempo real é o custo computacional. Todo o processamento feito nos testes foi *off-line*, pois foram baseados em sinais de banco de dados. Um parâmetro que afeta muito o custo computacional é o tamanho do frame, conforme mostrado por (LEE et al., 2012). A Figura 28 mostra o tempo de processamento da decomposição EEMD, o qual é o algoritmo mais custoso. Foram testados diferentes tamanhos de frame e escolhidos empiricamente (com referência na literatura) os tamanhos de 1024, 2048 e 4096 amostra.

O ponto central na Figura 28 representa o tempo médio, e a barra representa o desvio padrão do tempo de decomposição de 424 frames para cada tamanho testado. O *script* Matlab foi executado em um computador *Intel - Core I3*. Decompor um frame de tamanho 4096 requer tempo de processamento. Um frame de 4096 amostras, com frequência de amostragem de 360 Hz, representa cerca de 11 segundos de sinal, e a decomposição *EEMD* por vezes demora mais de 18 segundos, por isso foi tirada da análise. Conforme descrito em (CHEN et al., 2017), os algoritmos da classe *EMD* estão sendo bastante pesquisados atualmente, e existe a expectativa de, no futuro, serem desenvolvidos algoritmos mais rápidos para esta metodologia de decomposição. Este teste confirma a literatura (LEE et al., 2012), que mostra que o tamanho de frames muito grandes tornam-se inviáveis pelo tempo de processamento.

Outro teste preliminar avaliou o comportamento das métricas de acordo com o ta-

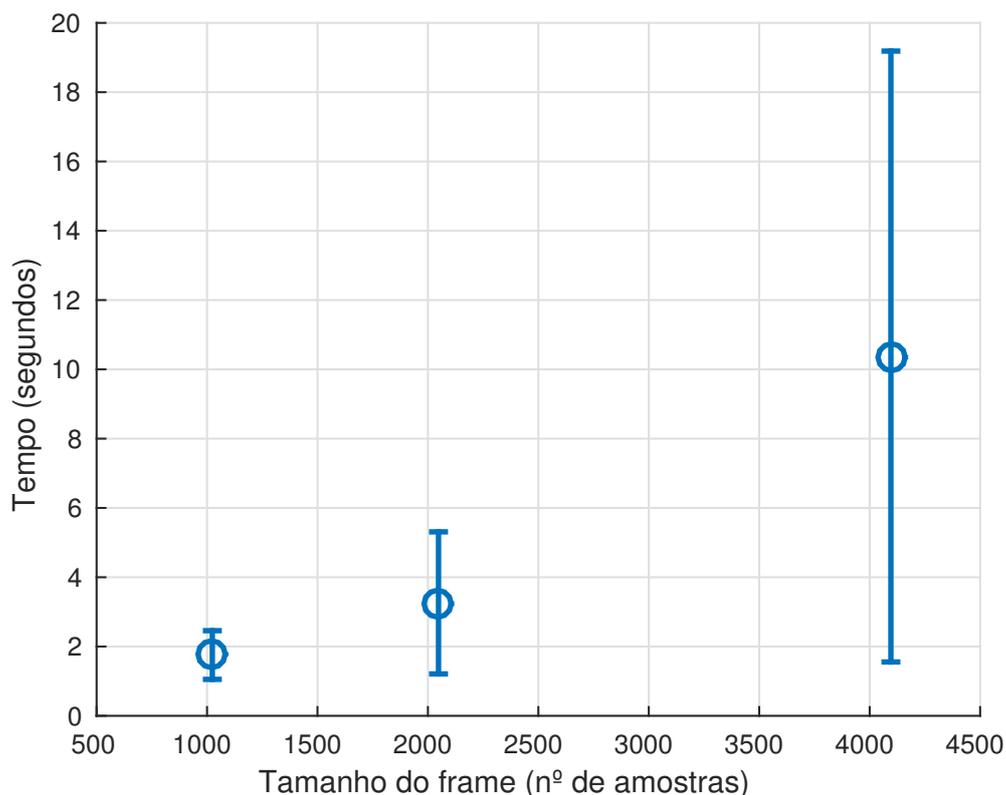


Figura 28: Tempo de processamento de decomposição versus tamanho dos frames

manho do frame e sua capacidade de discriminar entre frames com e sem artefatos. Observou-se que quanto maior o tamanho do frame mais discriminantes eram as métricas. As métricas estatísticas usadas para discriminar componentes com artefatos em frames com tamanho 4096 amostras apresentaram bons resultados. Porém, devido ao tempo de processamento foram preteridos da escolha final.

As análises das decomposições com tamanhos de 1024 e 2048 amostras mostraram que as medidas estatísticas de detecção de artefatos funcionam melhor em frames de 2048 amostras. Isto significa que são melhores para discriminar componentes com artefatos de componentes sem artefatos. Assim, foi escolhido um **tamanho de frame de 2048 amostras** para todo o trabalho.

3.3.1.2 EEMD

Na Figura 29 são apresentados, em laranja, os 8 componentes EEMD de um frame com artefatos (neste exemplo com SNR igual a 12dB), e sobrepostos os componentes EEMD do mesmo trecho sem artefato (em azul), isto é, do sinal de referência sem a mistura de artefatos. Esta decomposição, como explicado no capítulo anterior, apesar de não ser frequencial, apresenta nos componentes de menor índice, as maiores variações e nos componentes de maior índice as menores variações. Assim, é possível perceber que os componentes 6, 7 e 8 apresentam os sinais de artefatos enquanto os componentes 1, 2, 3, 4 e 5 apresentam os componentes mais relacionados com os sinais cardíacos.

É interessante notar que as componentes 1,2,3,4 e 5 dos sinais contaminados possuem formas muito semelhantes com menores magnitudes das primeiras componentes. No sinal limpo, as magnitudes destas componentes são maiores, representando que a energia do

o sinal cardíaco é maior que no sinal com artefato. As componentes 6, 7 e 8 possuem a maior parte do sinal de artefato, por isso são as mais importantes para os classificadores.

A componente 1 não necessariamente apresenta componente de artefato, ela apenas apresenta a porção mais oscilatória, ou com frequências mais altas. Com base nos testes preliminares, esta componente pode ser removida sem prejuízo ao sinal reconstruído. Como explicado no capítulo anterior, a decomposição EEMD é a média de um conjunto de decomposições EMD, cada uma com um ruído gaussiano aditivo. Assim, a tendência é que quanto maior o número de decomposições EMD usadas no processo de EEMD, mais a média do ruído tende a se anular. Com isso, o EEMD consegue agrupar melhor as oscilações semelhantes em uma mesma componente e consegue operar melhor mesmo na presença de ruído. Os testes preliminares mostraram que a média dos ruídos gaussianos adicionados em cada decomposição EMD tende a se acumular na primeira componente, e assim quanto maior o conjunto de EMD, menor a amplitude do sinal da primeira componente EEMD.

O processo de reconstrução do sinal a partir das componentes EEMD consiste em uma simples operação de soma. Assim as componentes classificadas como artefato são transformadas em vetor de zeros antes da reconstrução. Está é uma grande facilidade desse algoritmo, visto a simplicidade na manipulação das componentes.

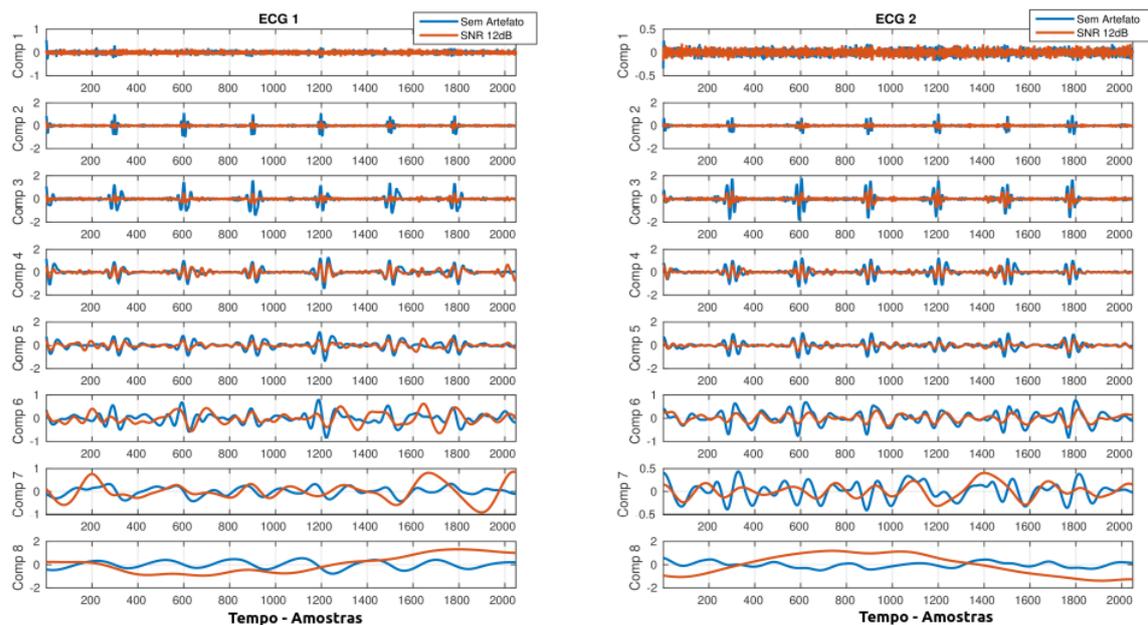


Figura 29: Exemplo de decomposição por EEMD de segmento com e sem artefato

3.3.1.3 EMD

A Decomposição EMD é bem menos complexa que a EEMD, como descrito no capítulo anterior, e ela tem dificuldade de decompor sinais que possuam ruídos, porque na presença de ruído a decomposição EMD não consegue agrupar as oscilações semelhantes na mesma IMF. Isso pode ser observado na Figura 30.

No caso da decomposição EMD existe um "espalhamento" maior do artefato sobre as componentes 4 e 5. Porém optou-se por não classificar essas componentes, pois nelas existe parte significativa do sinal cardíaco. Este fenômeno é conhecido como *mode mixing* ou "mistura de módulos", neste caso a informação do artefato vaza em outras

componentes.

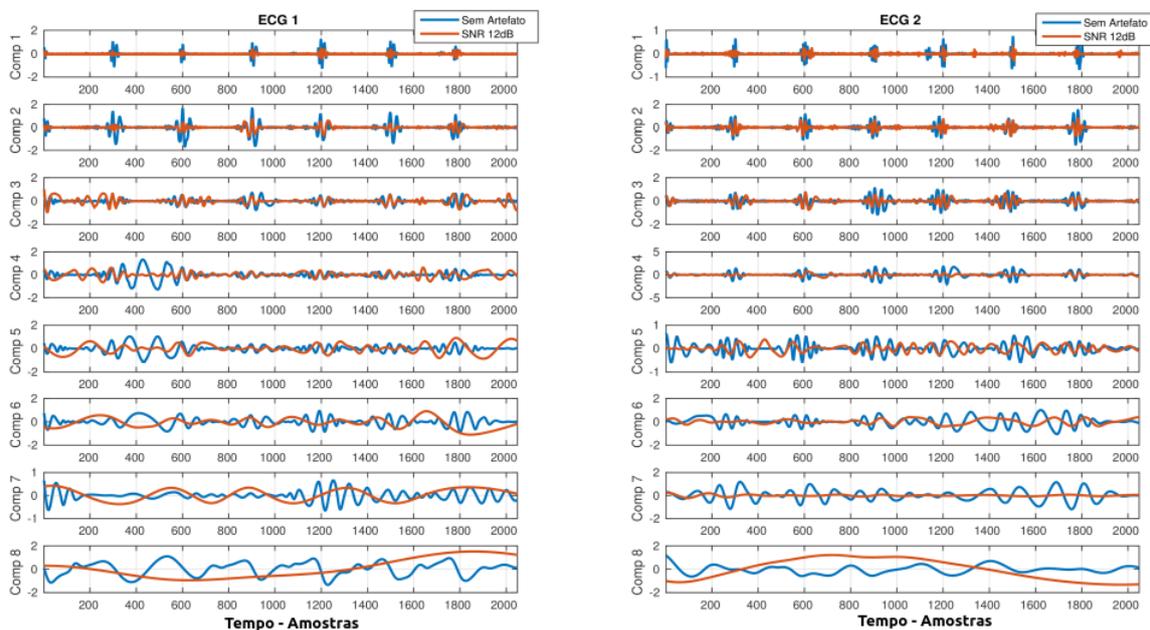


Figura 30: Exemplo de decomposição por EMD de segmento com e sem artefato

3.3.1.4 Transformada de Wavelet Estacionária - TWE

A decomposição por TWE é a mais eficiente computacionalmente. Enquanto as decomposições EMD e EEMD demoram alguns segundos para decompor um segmento de 2048 amostras, a TWE demora 2 3 milissegundos. A Figura 31 mostra uma TWE, e pode-se perceber que, da mesma forma das decomposições EMD e EEMD, os artefatos estão concentrados nas últimas componentes. A função *daubechies 4* foi utilizada como função mãe.

Na TWE, assim como ocorreu com a decomposição EEMD, as componentes 1, 2, 3, 4 e 5 do sinal com artefato são semelhantes às respectivas componentes sem artefato. As maiores diferenças ocorrem nas últimas componentes, indicando a presença de artefato.

A reconstrução do sinal decomposto por TWE consiste na transformada inversa de Wavelet das componentes. Neste processo, a última componente tem um papel importante na transformada inversa, e não pode ser eliminada. Assim, o processo de reconstrução do sinal decomposto pela TWE reconstrói o sinal de artefato com as componentes [6 8], zerando as demais [1 5]. E o sinal cardíaco é obtido subtraindo o sinal original do sinal de artefato reconstruído. Este processo é um pouco mais complexo que o processo do EMD e EEMD, mas ainda assim consideravelmente mais rápido.

3.3.2 Extração das métricas estatísticas

Os testes preliminares mostraram que nos sinais que apresentam pequena quantidade de artefatos, estes aparecem apenas na última componente (componente 8). Quanto mais artefato o sinal possui, mais as componentes de menor índice são também afetadas. Baseado nisso foram projetados classificadores para as componentes 6, 7 e 8 de cada sinal de ECG.

A classificação dos componentes em componentes relacionadas a artefatos e componentes relacionadas a sinal de interesse, deve ser feita por características estatísticas dos

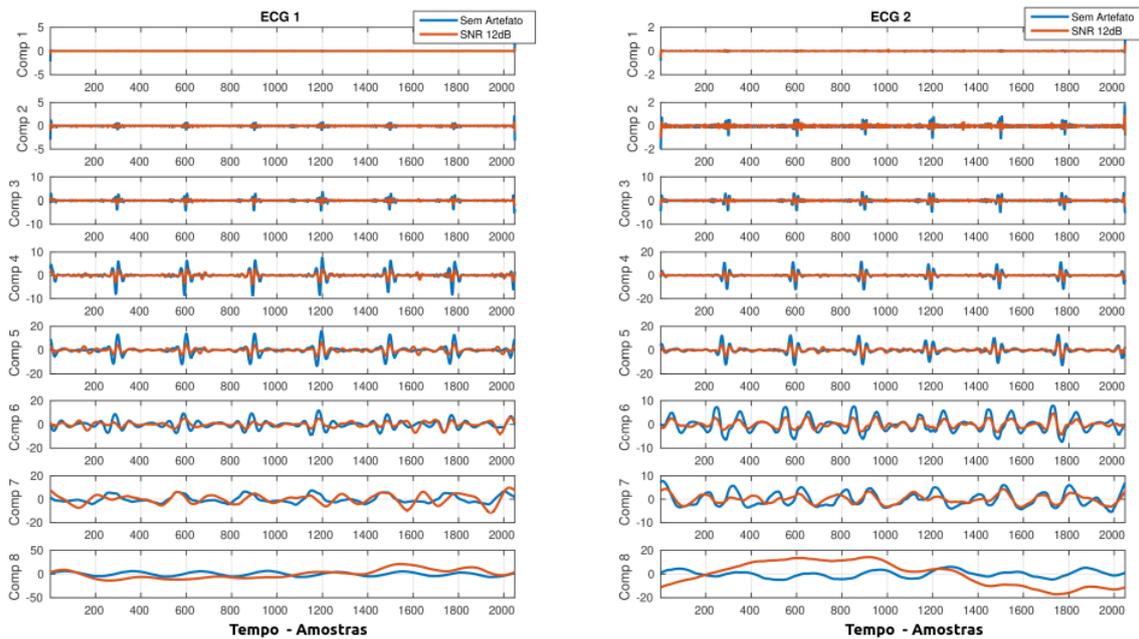


Figura 31: Exemplo de decomposição por Wavelet Estacionária de segmento com e sem artefato

sinais. Esta classificação não pode ser feita por componentes de frequência, pois como já visto, o espectro frequencial dos artefatos se sobrepõe ao espectro do sinal desejado. Existem métricas de avaliação de qualidade de sinal cardíaco, tais como angulo das ondas R e S, inclinação do segmento RS, simetria das ondas R e S, entre outros (ZHANG; ZHOU; ZENG, 2016). Porém estas métricas não podem ser usadas, pois se aplicam para avaliar o sinal cardíaco em si, e não para avaliar as componentes dos sinais cardíacos.

Nesta etapa de escolha de métricas para classificação das componentes, dois critérios foram empregados. Inicialmente, buscou-se quais métricas apresentavam valores mais discrepantes nos trechos com artefatos em comparação com o trecho sem artefato. Posteriormente, analisou-se em quais componentes estas métricas apresentavam tais valores discrepantes, que as tornem marcadores de artefatos.

Cada decomposição testada, EEMD, EMD e TWE gera componentes com características diferentes. Assim, uma métrica que consiga detectar uma componente com artefato em uma decomposição pode não funcionar em outra decomposição. Por isso optou-se por usar todas as 10 métricas para treinar classificadores para as três metodologias de decomposição.

3.3.3 Classificadores de componentes

Neste trabalho utilizaremos a etapa de decomposição para remover artefatos, isto é, remover componentes que estão relacionados a artefatos. Esta remoção deve ser feita com cuidado pois cada componente pode conter parte significativa de sinal cardíaco. Na etapa de detecção de artefatos foram testados 4 classificadores da literatura de *Machine Learning*, destes o SVM apresentou o melhor resultado. Assim este é o único classificador utilizado nesta etapa. Nesta etapa, a única variável analisada é o método de decomposição de sinais e sua capacidade de separar em componentes diferentes artefatos e sinais cardíacos.

Conforme pode ser visto na Figura 27, foram projetados 3 classificadores, um para

cada uma das componentes mais ruidosas, ou seja, componentes 6, 7 e 8. Vale ressaltar que o diagrama mostrado é aplicado para cada sinal. Assim, existem 3 classificadores para cada sinal processado. E cada classificador foi treinado com um conjunto de treinamento referente somente ao sinal que ele irá classificar. Como as componentes 6, 7 e ou 8 possuem artefatos ou não, de acordo com a quantidade de artefato presente no sinal, o classificador de cada componente foi treinado com um conjunto diferente de sinais.

Os classificadores foram treinados com as métricas estatísticas das respectivas componentes as quais irão classificar. Assim, os classificadores da componente 6 foram treinados com as componentes 6 dos sinais com SNR -6dB e -12dB como representantes da classe "Artefato" e as componentes 6 dos sinais com SNR 0dB e 6dB como representantes da classe "Sem Artefato". Os classificadores da componente 7 foram treinados com sinais com SNR 0dB e -6dB como representantes da classe "Artefato" e sinais com SNR 6dB e 12dB como representantes da classe "Sem Artefato". Os classificadores da componente 8 foram treinados com as métricas da componente 8 dos sinais com SNR 6dB e 0dB como representantes da classe "Artefato" e métricas das componentes 8 com SNR 12dB e 18dB como representantes da classe "Sem Artefato". Conforme mostrado na Figura 32.



Figura 32: Conjunto de treinamento e teste dos classificadores

Foram treinados 6 classificadores SVM, 1 para cada componente [6, 7, 8] de cada um dos dois sinais ECG. Cada um com um conjunto de treinamento e teste mostrado na Figura 32. A seguir serão detalhados os resultados dos classificadores pertinentes a cada metodologia de decomposição. Os classificadores foram avaliados por sua accuracy, sensitivity (capacidade de detectar Artefato), specificity (capacidade de detectar não-artefato).

3.3.3.1 Classificador de componentes - EEMD

A Tabela 2 mostra os resultados do classificador de cada componente na decomposição EEMD. Todos os classificadores treinados para identificar artefatos na componente 6 apresentaram os piores resultados. Conforme explicado anteriormente, esta componente apresenta pouco artefato, pois os artefatos aparecem mais fortemente nas últimas componentes. Assim todo o erro em não remover esta componente impacta fracamente na qualidade do sinal.

3.3.3.2 Classificador de componentes - EMD

A Tabela 3 mostra os resultados do classificador de cada componente na decomposição EMD. Neste caso os classificadores apresentam índices piores que o EEMD, isto se deve à mistura de modos. A mistura de modos faz com que oscilações referentes à ECG apareçam nas últimas componentes e oscilações referentes à artefatos apareçam nas componentes onde deveriam predominar oscilações de ECG. Esta mistura de oscilações dificulta a classificação, pois as métricas em cada componente não apresentam boa capacidade de discriminação entre sinais com de componentes de ECG e componentes de artefatos.

Tabela 2: Avaliação dos classificadores das componentes EEMD

| Classificador | accuracy | sensitivity | specificity |
|---------------|----------|-------------|-------------|
| Comp.6 ECG1 | 0.7996 | 0.7841 | 0.8172 |
| Comp.6 ECG2 | 0.8890 | 0.8639 | 0.9153 |
| Comp.7 ECG1 | 0.9440 | 0.9512 | 0.9368 |
| Comp.7 ECG2 | 0.8910 | 0.8770 | 0.9051 |
| Comp.8 ECG1 | 0.9126 | 0.9238 | 0.9012 |
| Comp.8 ECG2 | 0.9283 | 0.9082 | 0.9486 |

Tabela 3: Avaliação dos classificadores das componentes EMD

| Classificador | accuracy | sensitivity | specificity |
|---------------|----------|-------------|-------------|
| Comp.6 ECG1 | 0.6974 | 0.6570 | 0.7535 |
| Comp.6 ECG2 | 0.7534 | 0.7077 | 0.8152 |
| Comp.7 ECG1 | 0.7269 | 0.7077 | 0.7470 |
| Comp.7 ECG2 | 0.7269 | 0.7085 | 0.7460 |
| Comp.8 ECG1 | 0.6414 | 0.6032 | 0.7023 |
| Comp.8 ECG2 | 0.6228 | 0.5787 | 0.7187 |

3.3.3.3 Classificador de componentes - TWE

A Tabela 4 mostra os resultados do classificador de cada componente com decomposição TWE. Neste caso algo semelhante a classificação também fica prejudicada, mas agora por outro motivo. A decomposição TWE é fortemente dependente das componentes de frequência que compõem o sinal. As métricas funcionam melhor na decomposição morfológica EEMD do que em uma decomposição com base frequencial.

Tabela 4: Avaliação dos classificadores das componentes TWE

| Classificador | accuracy | sensitivity | specificity |
|---------------|----------|-------------|-------------|
| Comp.6 ECG1 | 0.7278 | 0.7448 | 0.7152 |
| Comp.6 ECG2 | 0.6640 | 0.6412 | 0.6883 |
| Comp.7 ECG1 | 0.9125 | 0.9067 | 0.9180 |
| Comp.7 ECG2 | 0.9076 | 0.8898 | 0.9255 |
| Comp.8 ECG1 | 0.8438 | 0.8499 | 0.8385 |
| Comp.8 ECG2 | 0.7976 | 0.7958 | 0.7992 |

3.4 Remoção de Artefatos com Separação Cega de Fontes

A estrutura de processamento de sinais desta etapa do processo está mostrada na Figura 33. Nessa imagem estão representados os blocos referentes às etapas anteriores de decomposição e classificação de componentes. A etapa adicionada inicia com a separação

cega de fontes, das componentes consideradas sem artefatos. Estas fontes são analisadas como um sinal bi-dimensional, de forma semelhante a uma imagem. Assim, são usados métodos de segmentação e classificação de imagens para detectar segmentos considerados artefato.

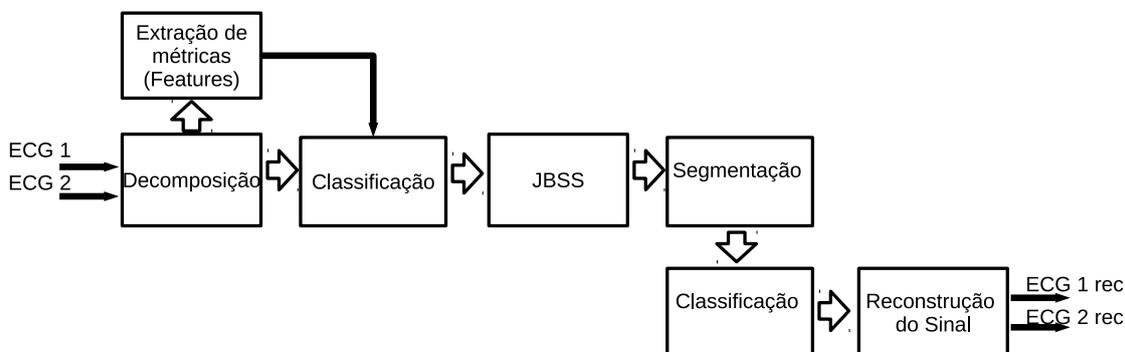


Figura 33: Diagrama em blocos da metodologia proposta

3.4.1 Estudo Preliminar

Esta abordagem foi desenvolvida a partir de um estudo preliminar, semelhante ao descrito em (CHEN; HE; PENG, 2014) (CHEN et al., 2017) (ZENG et al., 2016) (MAHAJAN; MORSHED, 2015). O intuito deste estudo era aplicar um algoritmo de *Joint Blind Source Separation* - JBSS no conjunto de componentes dos sinais, e buscar quais as fontes de artefato e as fontes relacionadas a ECG, então substituir as fontes de artefato por zero, processo conhecido por *zeroing*, e reconstruir as componentes sem as fontes de artefato. Esta estratégia até apresentou bons resultados, porém quando estes foram confrontados com os resultados obtidos utilizando apenas a remoção de componentes, constatou-se que os resultados eram muito semelhantes com relação ao NRMSE, algumas vezes piores.

Como visto anteriormente, os artefatos de movimento possuem morfologia semelhante aos sinais cardíacos, por esse motivo os algoritmos de separação cega de fontes tem dificuldade de colocar artefatos e sinais cardíacos em fontes diferentes. Mesmo que o sinal de ECG venha de uma "fonte" cardíaca e o artefato venha de uma "fonte" externa, por exemplo o movimento do eletrodo na pele, ou movimento do paciente.

A partir da análise dos resultados deste estudo preliminar, ficou evidente a necessidade de sub-segmentar o sinal para poder alcançar maior discriminação entre o que é sinal de batimento cardíaco e o que é artefato. Assim, surgiu a estratégia de tratar a matriz de fontes como uma imagem e usar uma segmentação de imagem, como será mostrado no decorrer do capítulo.

A separação cega de fontes explicita as fontes das componentes e agrupa as fontes semelhantes, isto permite fazer uma segmentação bi-dimensional no espaço das fontes e assim identificar as porções relacionadas a artefato e as porções relacionadas a sinal cardíaco. Nessa abordagem foram utilizados dois algoritmos de separação cega de fontes conjuntas (*Joint Blind Source Separation* - JBSS) MCCA e IVA-G. Os algoritmos MCCA e IVA-G foram escolhidos porque resolvem o problema da permutação, apresentando, na saída, as fontes ordenadas pela sua autocorrelação. Assim, analisando o conjunto de fontes resultantes deste algoritmos, é possível perceber que oscilações semelhantes estão em fontes sequenciais, isto é, fontes com oscilações semelhantes são ordenadas próximas umas das outras, conforme mostra a Figura 34. Na Figura é possível ver que as oscilações

referentes aos sinais cardíacos, marcados em verde, estão em sequência, e também os sinais referentes aos artefatos, marcados em vermelho, então em sequência.

As fontes mostradas na Figura 34 são o resultado da aplicação do método MCCA nas componentes consideradas como sinal ECG da etapa anterior. A Figura 35 mostra o sinal reconstruído na etapa anterior com estas fontes.

Interessante notar o caráter de fusão de informação destes algoritmos, pois cada fonte é uma combinação linear das componentes que foram aplicadas na entrada do algoritmo. No caso do MCCA, por exemplo, é a combinação linear que torna cada fontes mais auto correlacionada e menos correlacionada com as outras fontes. Sob este ponto de vista a separação cega de fontes está sendo usada como um método de fusão de informações, uma vez que reúne na mesma fonte os sinais semelhantes dos dois sinais.

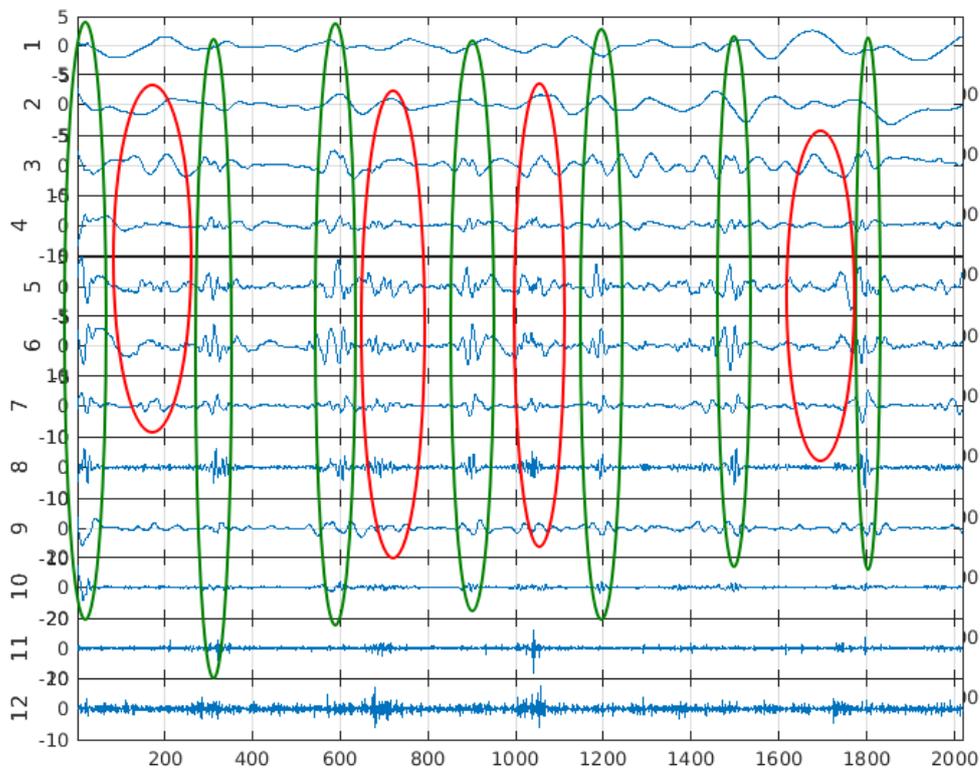


Figura 34: Fontes referentes às componentes de um sinal de ECG com SNR de 0dB de artefato

3.4.2 Análise no espaço das fontes

Foram testados dois algoritmos de separação cega de fontes conjunta, o MCCA, e o IVA-G. Estes foram escolhidos por apresentarem uma solução para o problema da permutação ambígua das fontes. Isto é, estes algoritmos apresentam as fontes ordenadas segundo o critério de autocorrelação (ANDERSON; ADAL₁; LI, 2012; CHEN et al., 2017, 2014; LI et al., 2009). No decorrer do capítulo serão mostradas as imagens referentes ao MCCA, pois ambos os algoritmos (IVA-G e MCCA) são bastante semelhantes e não apresentaram diferenças significativas nos seus resultados.

A separação cega de fontes é usada com dois objetivos: o primeiro é fazer a fusão dos sinais correlacionados e o segundo é ordená-los de acordo com sua autocorrelação. Nem todos os algoritmos de JBSS ordenam as fontes na saída. O algoritmo IVA-Laplaciano se-

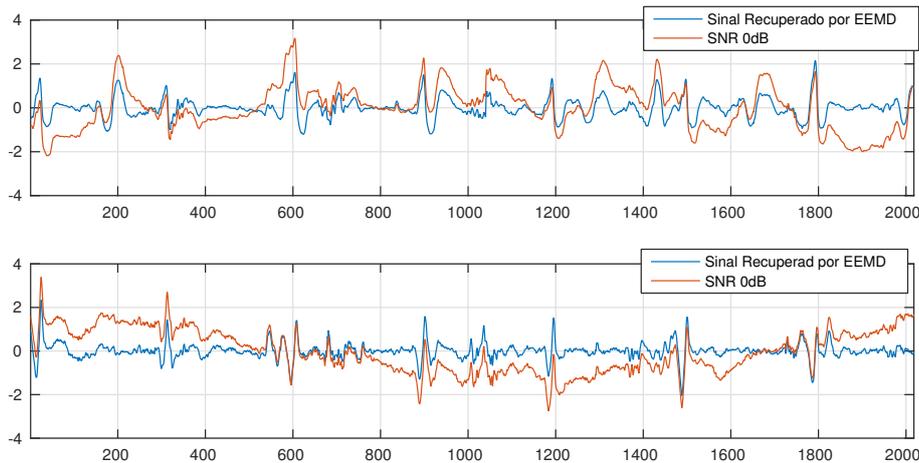


Figura 35: Sinal reconstruído na etapa de remoção de artefatos com EEMD

quer apresenta as fontes de forma repetitiva, ou seja, cada vez que executa-se o algoritmo as fontes podem estar em ordem diferente. Tanto o MCCA quanto IVA-G apresentam na saída fontes ordenadas em termos da autocorrelação do maior para o menor (CHEN; HE; PENG, 2014) (LI et al., 2009) (HAO et al., 2010).

Os algoritmos de separação cega de fontes conjunta processam um tensor em 3 dimensões. Pode-se entender esse tensor com um conjunto de matrizes, e cada matriz é o conjunto de sinais medidos. Como explicado na metodologia, o JBSS separa as fontes em cada conjunto de fontes e relaciona as fontes encontradas por meio dos conjuntos, ou seja, relaciona cada fonte encontrada em um conjunto com as respectivas fontes encontradas nos outros conjuntos.

Foram testados três modos de montar o tensor de entrada do JBSS. No primeiro, cada conjunto de componentes de um sensor constitui um conjunto de misturas. Este tensor é formado por 2 conjuntos de misturas (componentes de ECG1 e ECG2), cada um contendo 8 sinais (8 componentes) cada um com 2048 amostras, no formato $[8 \times 2048 \times 2]$. No segundo formato testado as 8 componentes de cada sinal ECG são "empilhadas", formando um único conjunto de componentes, e como segundo conjunto de componentes são usados os sinais do segmento anterior no mesmo arranjo, formando um tensor no formato $[16 \times 2048 \times 2]$. O terceiro formato de tensor foi baseado em (CHEN et al., 2017) e também utiliza os dois conjuntos de componentes "empilhados" em uma única matriz, e os outros t conjuntos de componentes são versões atrasadas de n amostras. Foram testados empiricamente valores de t e n , chegando a valores de $t=4$ e $n=10$, semelhantes à (CHEN et al., 2017). O formato do terceiro vetor é $[16 \times 2018 \times 4]$.

3.4.3 Segmentação no espaço das fontes

Interessante notar que embora o nome do algoritmo seja "Separação Cega de Fontes" não existe garantia que ele apresente na saída as mesmas fontes inicialmente misturadas. Apenas existe a garantia que as fontes encontradas serão independentes (no caso do ICA e IVA) ou decorrelacionadas (no caso do MCCA).

O processo de segmentação desenvolvido para esta etapa do projeto consiste em tomar o conjunto de fontes como uma imagem como mostrado na Figura 36. Nesse ponto não é possível distinguir entre zonas com mais energia e zonas com pouca energia.

As regiões de interesse são as áreas com maior amplitude, não importando se positivas

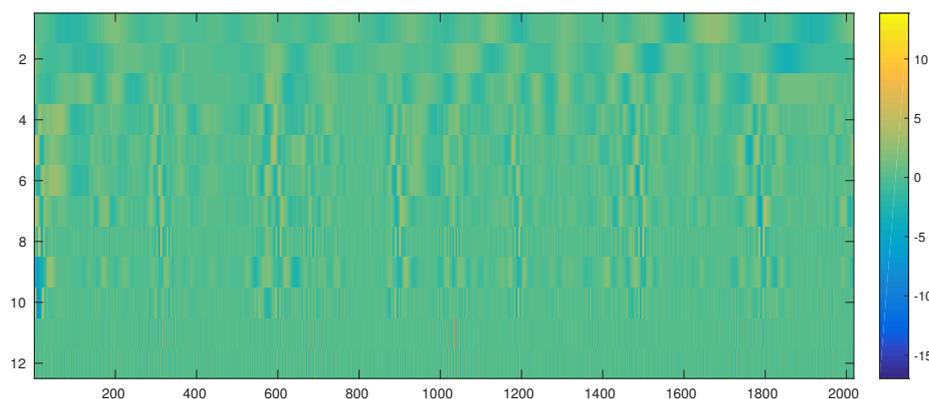


Figura 36: Imagem referente ao conjunto de fontes calculadas a partir das componentes.

ou negativas. Então é tomado o valor absoluto de toda a imagem. A imagem resultante é filtrada por um filtro gaussiano, com sigma 2, a fim de remover o cruzamento por zero, e por fim é feita uma equalização de histograma para ressaltar as regiões com sinais. O processo de realce de segmentos está mostrado na Figura 37. O resultado é mostrado na Figura 39.



Figura 37: Processo para realçar segmentos com maior energia.

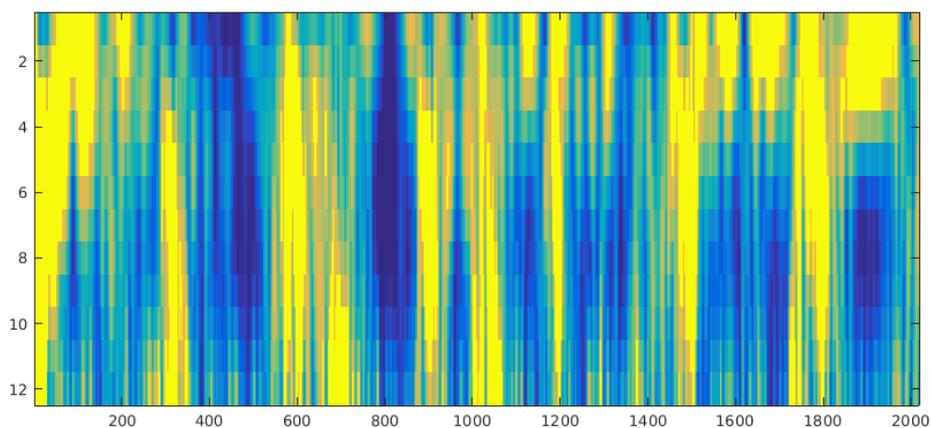


Figura 38: Realce da imagem para evidenciar os segmentos com maior energia.

As regiões em amarelo correspondem às regiões com maior energia de sinal nas fontes. Vale ressaltar que os segmentos detectados nessa etapa podem conter sinais cardíacos e/ou artefatos. A classificação dos segmentos será apresentada mais adiante.

Tomando cada região em amarelo como um segmento em separado, o resultado pode ser visto na Figura 39. Nessa figura, cada segmento está em uma cor diferente. Nesse

ponto do processo pode-se observar que existem regiões que são muito mais largas do que se esperaria de um sinal de ECG. Também existem segmentos muito pequenos, que não representam um segmento de ECG. Para separar as regiões que possivelmente representam artefatos de regiões de ECG, é aplicada uma transformação morfológica de abertura, a qual consiste em uma erosão seguida de uma dilatação, usando o mesmo elemento estruturante (GONZALES, 2010). O elemento foi escolhido pensando que um sinal cardíaco deve aparecer em pelo menos 6 fontes (critério arbitrário). O resultado pode ser visto na Figura 40.

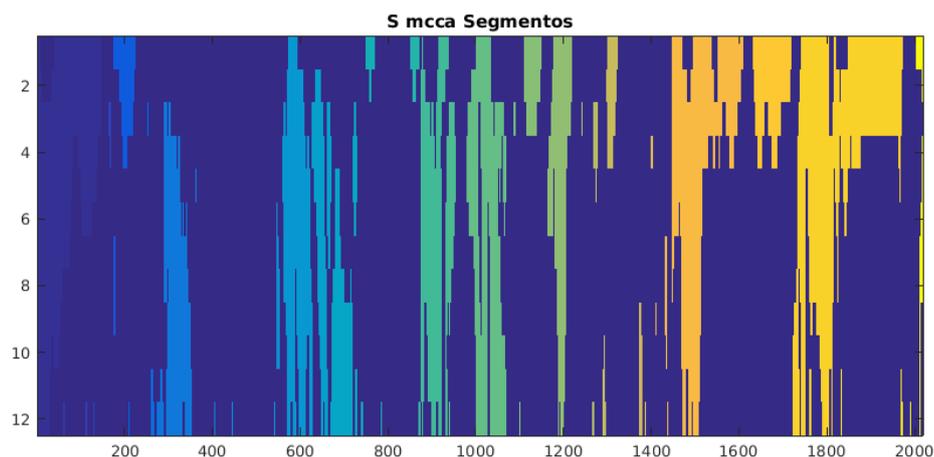


Figura 39: Separação em segmentos diferentes.

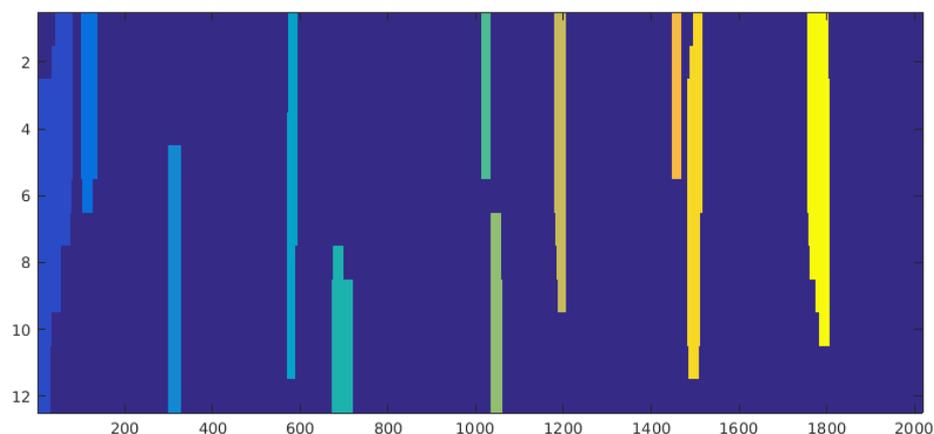


Figura 40: Segmentos após processo morfológico de fechamento

3.4.4 Classificador

Deseja-se criar um classificador supervisionado para esta tarefa, visto que a experiência com classificador não supervisionado na etapa de detecção mostrou desempenho acanhado. Porém a formação do conjunto de dados de treinamento do classificador de segmentos não pôde ser feita como no caso do classificador de componentes.

Nos classificadores anteriores era simples agrupar o conjunto com artefato e o conjunto sem artefato, pois no primeiro caso, os dados de treinamento referentes a sinais com

artefato vieram dos sinais com artefatos, e os dados de treinamento dos sinais sem artefato vieram dos sinais sem artefato. No segundo caso, partiu-se do pressuposto que os artefatos residem nas últimas componentes. Assim, cada um dos 6 classificadores foi treinado usando um conjunto de dados (métricas estatísticas) referentes ao respectivo sinal. Para treinar o detector de artefatos na componente 7 do ECG 1, foram usados os dados da componente 7 do ECG 1 com e sem artefatos. Todos os dados utilizados eram facilmente rotuláveis. Porém, no caso da classificação dos segmentos os dados não são facilmente rotuláveis, pois os segmentos relacionados aos artefatos co-existem com os segmentos relacionados a ECG.

Para gerar os dados do conjunto de treinamento do classificador é necessário separar segmentos referentes a **sinal cardíaco** e segmentos referentes a **artefato**. Porém, nesta etapa os segmentos com artefatos e os segmentos de ECG não estão em arquivos separados, nem em fontes diferentes. Os sinais com artefatos possuem segmentos com artefatos e segmentos sem artefatos e em posições aleatórias na imagem.

Para contornar esse problema foi necessário identificar os segmentos de artefato e os segmentos de ECG. Para isso foi utilizada uma imagem de referência construída pelo mesmo processo de segmentação utilizando o sinal sem artefato. Então aplicou-se a seguinte regra de identificação: se um segmento na imagem do sinal não estiver presente também na imagem de referência, então é considerado um sinal de artefato. Dessa forma, foram rotulados os segmentos de Artefato. Os segmentos com rótulo ECG vieram apenas do sinal sem artefato.

3.4.4.1 Métricas estatísticas com marcadores de artefatos

Para classificar os segmentos obtidos no espaço das fontes, foram usadas métricas estatísticas das fontes para discriminar um segmento de artefato de um segmento de sinal cardíaco. Foram usadas as métricas:

- Tamanho do segmento, medido pelo número de amostras pertencentes ao segmento;
- Altura, medido pelo número de fontes que participam no segmento;
- Número da primeira e última fonte que participam do segmento;
- Somatório dos valores das amostras dentro do segmento;
- Média;
- Desvio Padrão;
- Número de cruzamentos por zero em cada fonte que participa do segmento;
- Obliquidade - *Skewness*;
- Curtose - *Kurtosis*;
- Entropia;
- Entropia de permutação;
- Entropia de Shannon;
- Auto correlação - coeficiente 1;

- Área abaixo do sinal de autocorrelação.

Vale ressaltar as métricas que mais se destacaram na discriminação entre as classes.

- Entropia de Shannon: Interessante notar que a entropia de Shannon mede a quantidade de informação nos dados. Quanto mais negativo, mais informação os dados possuem. A Figura 41 mostra o valor da entropia de Shannon para cada instância de treinamento.

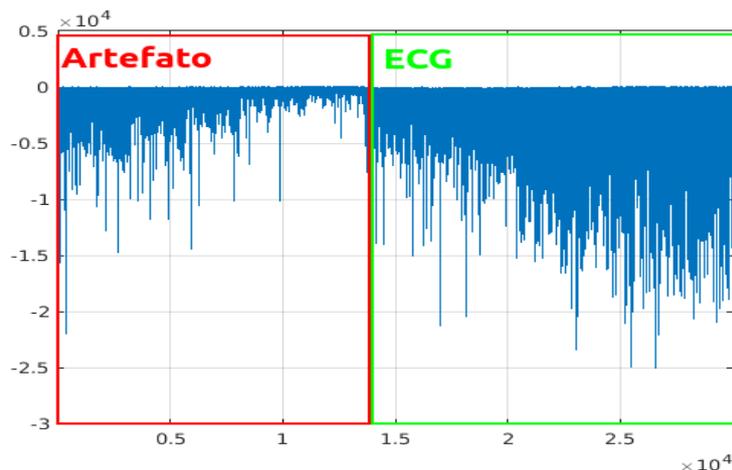


Figura 41: Comparação da Entropia de Shannon das instâncias de **Artefato e ECG**

- Altura: O processo de separação cega de fontes aglomera oscilações semelhantes em fontes sequenciais. Os artefatos conseguem ser aglutinados em poucas fontes, enquanto os sinais de ECG costumam ocupar muitas fontes. A Figura 42 mostra que somente segmentos de Artefatos ocupam menos de 5 fontes, até podem ocupar mais, mas segmentos de ECG não ocupam menos de 5 fontes.

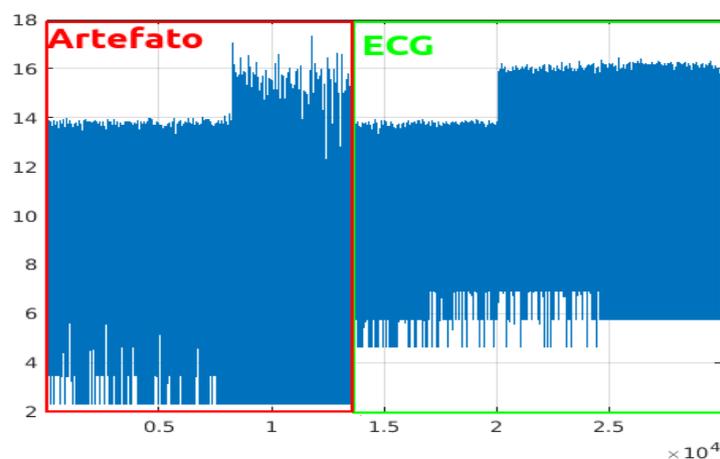


Figura 42: Comparação da Entropia de Shannon das instâncias de **Artefato e ECG**

- Tamanho: Em consequência do número de fontes menor, os segmentos de artefato também tem área menor. Na Figura 43 pode ser visto o número de amostras de cada segmento de treinamento.

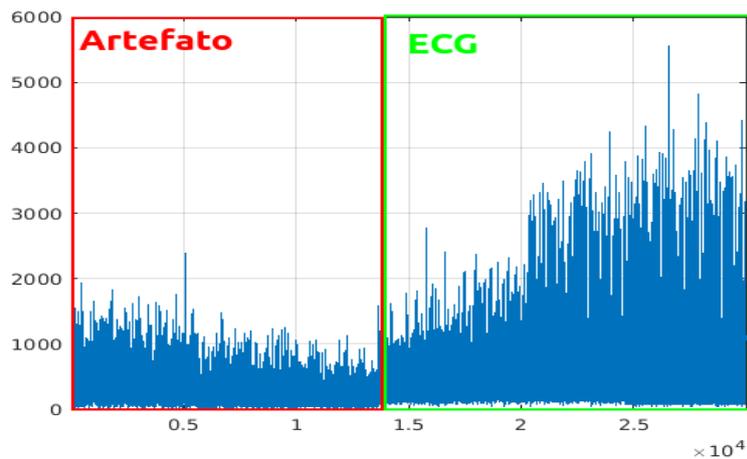


Figura 43: Comparação da Entropia de Shannon das instâncias de **Artefato** e **ECG**

3.4.4.2 Processo de Aprendizagem do Classificador

A partir dos conjuntos de treinamento e teste montados, foi treinado um classificador SVM. Foram testadas duas funções de Kernel, linear e gaussiana. Diferentemente do classificador de componentes, o kernel gaussiano obteve melhores resultados, conforme pode ser visto nas matrizes de confusão 5 e 6.

Tabela 5: Matriz de confusão do classificador SVM com kernel linear

| | | Classes Preditas | |
|---------------------|----------|------------------|------|
| | | Artefato | ECG |
| Classes Verdadeiras | Artefato | 13370 | 268 |
| | ECG | 827 | 1628 |

Tabela 6: Matriz de confusão do classificador SVM com kernel Gaussiano

| | | Classes Preditas | |
|---------------------|----------|------------------|------|
| | | Artefato | ECG |
| Classes Verdadeiras | Artefato | 13616 | 22 |
| | ECG | 831 | 1622 |

Embora a matriz de confusão deste classificador SVM com kernel gaussiano mostre uma accuracy de mais de 90% e sensitivity de mais 99%, ele falha nos piores casos, specificity de 66%, isto é, falha em classificar como artefato um segmento que contém um batimento cardíaco. A atenuação dos segmentos considerados Artefatos nesse caso causaria uma perda de sinais de batimento cardíaco.

Para contornar esse problema duas estratégias foram aplicadas. A primeira foi treinar um classificador com um algoritmo diferente. A segunda foi utilizar na etapa de treinamento mais instâncias da classe **ECG**, pois se ele não está sendo capaz de identificar os segmentos dessa classe, aumentar as instâncias de treinamento pode melhorar sua performance nesse sentido.

Um classificador formado pelo conjunto de árvores de decisão (*bag of decision trees*) (BREIMAN, 2001) foi proposto para realizar esta tarefa com maior specificity. Este classificador é formado pelo conjunto de árvores de decisão. Árvores de decisão individuais

tendem a criar modelos com sobre-ajuste dos dados. Isto significa que o modelo se ajusta muito bem ao conjunto de treinamento, mas é ineficaz para prever os dados novos de teste (HAYKIN, 2009).

As árvores de decisão agregadas (em conjunto) combinam os resultados de muitas árvores de decisão, o que reduz os efeitos do sobre-ajuste e melhora a generalização. O aprendizado por *bag of decision trees* cresce as árvores de decisão no conjunto usando dados de pequenos conjuntos de amostras do conjunto de treinamento (LOH, 2002; MEINSHAUSEN, 2006).

Para aumentar o número de instâncias de classe **ECG**, foi necessário utilizar os segmentos de ECG dos sinais contaminados, e não apenas os segmentos da referência. Assim, foi aplicada uma nova regra de rotulação nos segmentos dos sinais, da seguinte forma: se um segmento na imagem do sinal estiver presente também na imagem de referência, então é considerada um sinal de **ECG**, caso contrário, ele é considerado **Artefato**. Com essa abordagem, o número de instâncias de treinamento da classe **ECG** aumentou significativamente.

O resultado dessa estratégia está mostrado na matriz de confusão na Tabela 7, apesar de haver mais falsos negativos, a relação entre falsos negativos e verdadeiros negativo é bem menor. Alcançando accuracy de 94%, sensitivity 95% e specificity de 93%. Apesar deste valor ser maior que o anterior, os erros de classificação são os pontos mais fracos do sistema. Pois em cada erro de classificação, ou um artefato deixa de ser removido, ou, em pior caso, um sinal de ECG é removido.

Tabela 7: Matriz de confusão do classificador Conjunto de árvores de decisão

| | | Classes Preditas | |
|---------------------|----------|------------------|-------|
| | | Artefato | ECG |
| Classes Verdadeiras | Artefato | 12955 | 683 |
| | ECG | 1073 | 15286 |

3.4.5 Remoção de segmentos com artefato e Reconstrução do sinal ECG

A remoção dos artefatos consiste na atenuação de 10dB o sinal das fontes nestes segmentos classificados como artefatos. Esta metodologia de remoção de artefatos por atenuação foi escolhida pois, em testes preliminares, apresentou uma NRMSE um pouco melhor do que zerar o sinal das fontes nessas região. Além disso, zerar os segmentos de artefato que ocorrem muito próximos do sinal de ECG pode deformar muito o sinal de interesse.

A reconstrução do sinal consiste no processo inverso da análise do sinal. Então as fontes, com os segmentos de artefatos atenuados são transformados de volta para o espaço de componentes, pela multiplicação da matriz inversa de transformação de JBSS. No espaço das componentes EEMD, as componentes referentes a cada sinal são somadas para formar os dois sinais de ECG. Como o processo atenua partes do sinal, de forma discreta, o sinal é filtrado para remover marcas da atenuação de algumas partes do sinal. Foi utilizado um filtro tipo *butterworth* de ordem 3 passa baixas, com frequência de corte em $0.5\omega_n$. Todo o processo de remoção de artefatos removeu energia dos sinais, então antes da saída, o sistema normaliza o desvio padrão do sinal, dividindo todo o vetor de saída pelo desvio padrão deste vetor. Isto amplifica o sinal. A Figura 44 mostra o sinal reconstruído na etapa de remoção de artefatos com JBSS em comparação com o Sinal de entrada SNR 0dB. A Figura 45 mostra o sinal reconstruído na etapa de remoção de

artefatos com JBSS em comparação com o Sinal reconstruído usando EEMD e a Figura 46 mostra o sinal reconstruído na etapa de remoção de artefatos com JBSS em comparação com o Sinal sem artefatos.

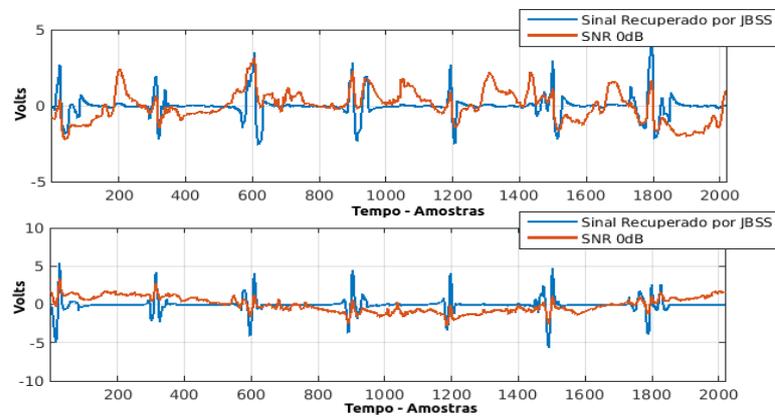


Figura 44: Sinal reconstruído na etapa de remoção de artefatos com JBSS em comparação com o Sinal de entrada SNR 0dB

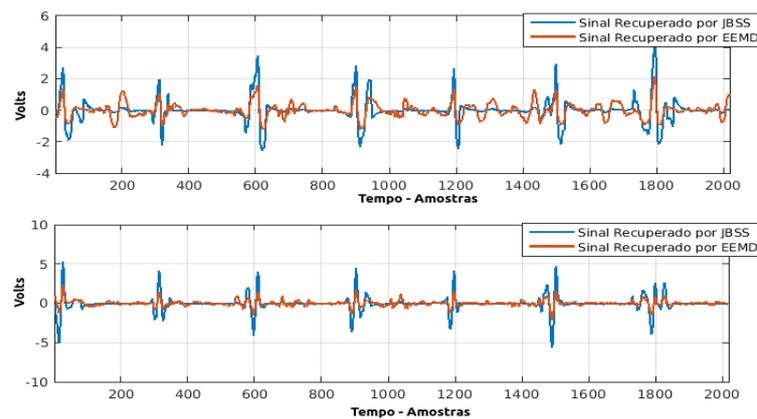


Figura 45: Sinal reconstruído na etapa de remoção de artefatos com JBSS em comparação com o Sinal reconstruído usando EEMD

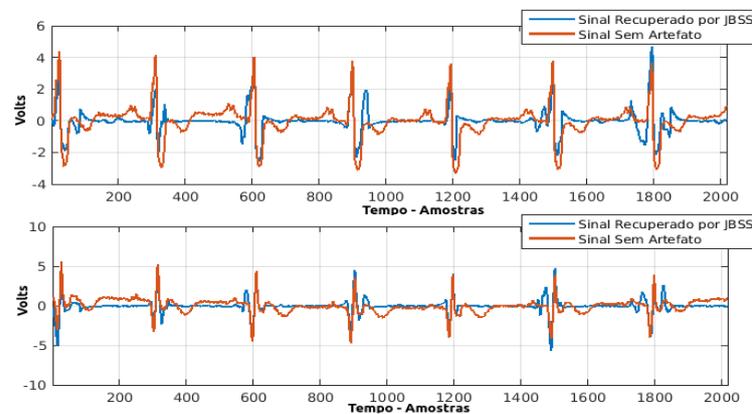


Figura 46: Sinal reconstruído na etapa de remoção de artefatos com JBSS em comparação com o Sinal sem artefatos

4 RESULTADOS

4.1 Resultados da Detecção de Artefatos

A seguir são listados os resultados de cada classificador, mostrando a matriz de confusão. A máquina de vetores de suporte apresentou o melhor desempenho, conforme pode ser observado na tabela 8:

Tabela 8: Matriz de Confusão do Classificador SVM

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 523 | 3 |
| | Não Artefato | 17 | 220 |

O resultado do classificador baseado em árvores de decisões pode ser visto na Tabela 9:

Tabela 9: Matriz de Confusão do Classificador Árvore de decisões

Tabela 10: Matriz de Confusão do Classificador Árvore de decisões

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 504 | 22 |
| | Não Artefato | 18 | 218 |

O resultado do classificador baseado em K vizinhos mais próximos pode ser visto na Tabela 11.

Tabela 11: Matriz de Confusão do Classificador K vizinhos mais próximos

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 520 | 6 |
| | Não Artefato | 24 | 213 |

Os resultados do classificador baseado em K médio pode ser visto na Tabela 12

Tabela 12: Matriz de Confusão do Classificador K médio

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 359 | 167 |
| | Não Artefato | 104 | 133 |

Por fim, a tabela 13 mostra uma análise comparativa entre os classificadores utilizados nesse trabalho.

Tabela 13: Comparação de desempenho entre os classificadores

| Classificador | accuracy | sensitivity | specificity |
|-------------------|----------|-------------|-------------|
| SVM | 0,9738 | 0,9943 | 0,9283 |
| Árvore de Decisão | 0,9476 | 0,9582 | 0,9241 |
| KNN | 0,9607 | 0,9886 | 0,8987 |
| K médio | 0,6448 | 0,6825 | 0,5612 |

Em outro ensaio os sinais de ECG foram somados com ruído de artefatos de diferentes intensidades, caracterizando SNR de -6db, 0dB, +6dB e +24db. Assim, todos os segmentos são artefatos, porém com diferentes dosagens de artefato. Cada sinal possui 726 segmentos, sendo 363 do paciente 118, e 363 do paciente 119.

Este teste executado apenas para os classificadores com melhor desempenho observado: SVM e KNN. A tabela 14 mostra o número de acertos de cada classificador para cada dosagem de artefato.

Tabela 14: Compação com outros trabalhos

| Classificador | SNR = -6dB | SNR = 0dB | SNR = +6dB | SNR = 24dB |
|---------------|------------|--------------|------------|--------------|
| SVM | 726 100% | 726 100% | 726 100% | 723 99,58% |
| KNN | 726 100% | 725 99,86% | 726 100% | 717 98,76% |

4.1.1 Comparações

A tabela 15 mostra a comparação dos resultados obtidos nesta classificação com outros trabalho de detecção de artefato em sinais ECG. Embora os resultados deste trabalho sejam melhores que os alcançados pelas outras metodologias, esta comparação não é totalmente honesta, visto que os outros trabalhos não usaram os mesmos banco de dados.

Tabela 15: Comparação entre metodologias

| | Método Proposto | Metodologia A | Metodologia B |
|-------------|-----------------|---------------|---------------|
| accuracy | 0,9738 | 0,9549 | 0,868 |
| sensitivity | 0,9943 | 0,9688 | 0,875 |
| specificity | 0,9283 | 0,9792 | 0,868 |

Onde: Metodologia A = (LEE et al., 2012) Metodologia B = (VAZ et al., 2014)

4.2 Resultado da remoção de artefato utilizando Decomposição de Sinais

Na seção anterior foi analisada a capacidade dos classificadores em discriminar entre um componente considerado artefato ou não. Nesta seção é feita a remoção das componentes classificadas como artefatos na reconstrução do sinal. Assim, cada segmento de sinal recuperado é comparado com o segmento de referência ao qual não foram adicionados artefatos.

A melhoria na qualidade do sinal reconstruído é avaliada por meio do *Normalized Root Mean-Square Error* - (*NRMSE*). Esta medida de erro entre dois sinais apresenta nível máximo igual a 1 quando ambos os sinais são iguais, e valores menores de 1 até ∞ , quanto mais diferentes os sinais forem. O *NRMSE* é expresso pela equação 35, onde $x_{ref}(\cdot)$ representa o sinal de referência e $x(\cdot)$ representa o sinal testado, e $\|\cdot\|$ representa a norma-2 do vetor.

$$NRMSE = 1 - \frac{\|x_{ref}(\cdot) - x(\cdot)\|}{\|x_{ref}(\cdot) - mean(x_{ref}(\cdot))\|} \quad (35)$$

O principal foco desta análise é avaliar a melhoria no sinal recuperado em comparação com o sinal sem artefato. Assim, medir o quanto o sinal recuperado está melhor em relação ao sinal de entrada.

4.2.1 Resultados do classificador EEMD

A Figura 47 mostra o *NRMSE* para cada frame do sinal do paciente 118 e a Figura 48 o *NRMSE* do sinal do paciente 119. O sinal completo do paciente tem 30 minutos, e cada frame possui 2048 amostras, a frequência de amostragem do sinal é 360 Hz, cada frame representa cerca de 5,7 segundos. No total são 424 frames. Cada ponto no gráfico representa um segmento de sinal, e cada cor representa uma dosagem de artefato. Para cada frame foi calculado o *NRMSE* do sinal de entrada e do sinal de saída do processo. A Figura 49 mostra o valor do *NRMSE* para cada frame dos sinais com diferentes níveis de SNR do paciente 118, e na Figura 50 o mesmo gráfico com os sinais do paciente 119.

Para comparação foram traçados os gráficos com o *NRMSE* médio do sinal de entrada versus o *NRMSE* do sinal de saída usando a decomposição EEMD e os classificadores. O ponto central representa o valor médio do *NRMSE* de saída e as barras verticais representam o desvio padrão do *NRMSE*. A Figura 49 mostra a melhora do parâmetro *NRMSE* para os sinais do paciente 118, e a Figura 50 para o paciente 119.

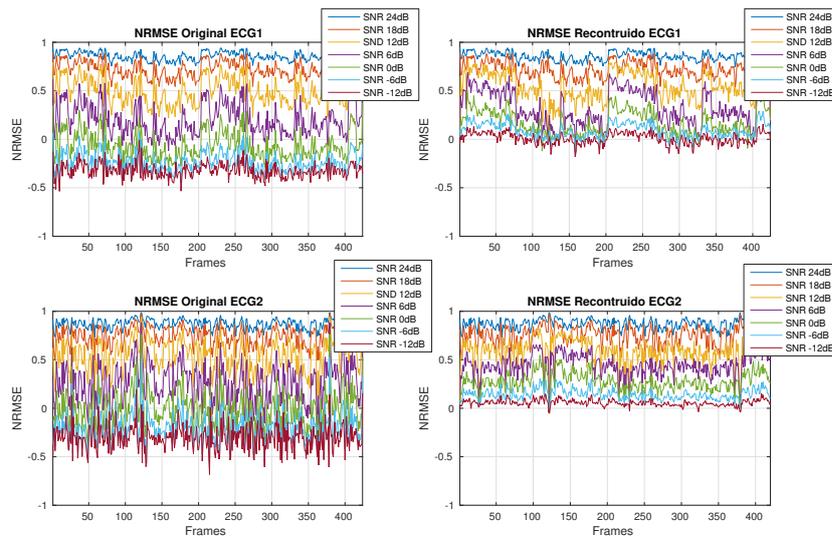


Figura 47: NRMSE do Recuperação utilizando EEMD do sinal do paciente 118

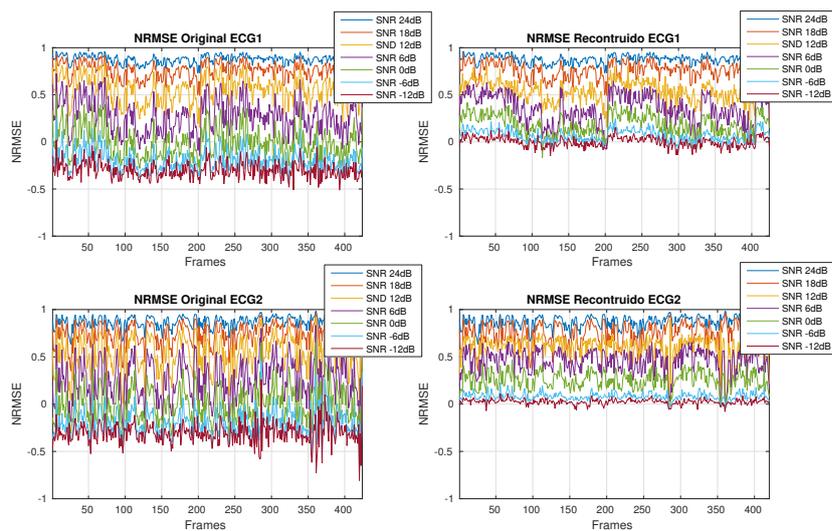


Figura 48: NRMSE do Recuperação utilizando EEMD do sinal do paciente 119

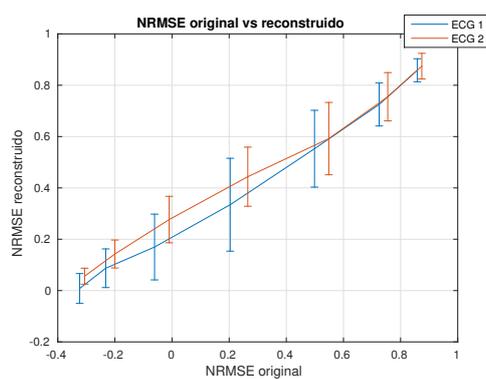


Figura 49: NRMSE de entrada versus NRMSE de saída do sinal do paciente 118

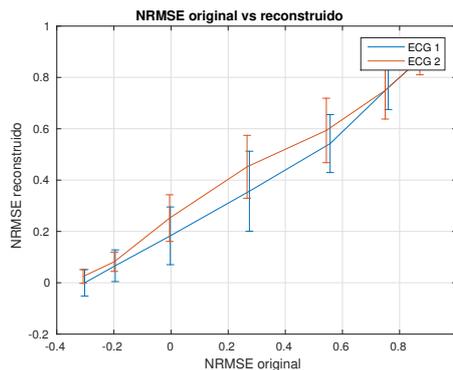


Figura 50: NRMSE de entrada versus NRMSE de saída do sinal do paciente 119

Pode-se perceber que sistema funciona bem para sinais com muito artefato, e nos caso em que possui pouco artefato o sistema teve pouco efeito no sinal reconstruído. Um exemplo da remoção das componentes para remoção de artefatos pode ser visto na Figura 51. O sinal original com artefato foi plotado em laranja e o sinal recuperado sem as componentes 6, 7 e 8 em azul.

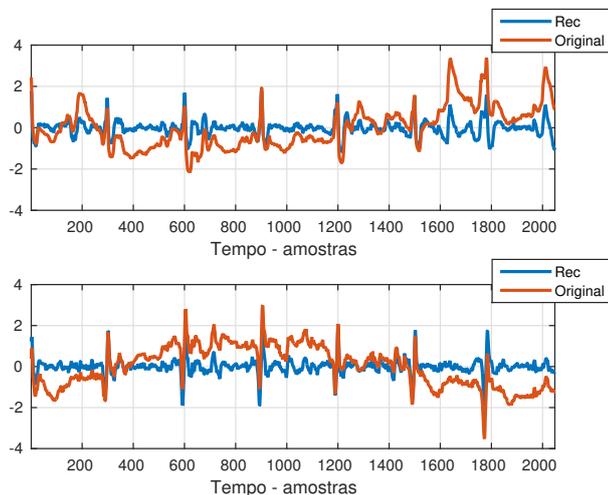


Figura 51: Exemplo de decomposição por EEMD de segmento com e sem artefato

Na Figura 52 tem-se um exemplo da estimativa do sinal do artefato, reconstruído a partir das componentes 6, 7 e 8.

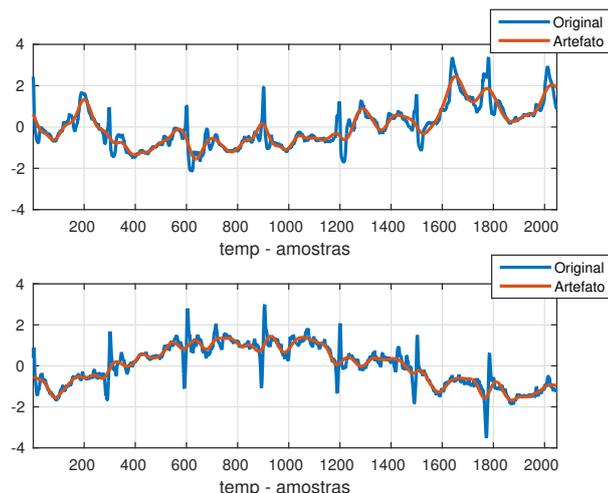


Figura 52: Exemplo da reconstrução do artefato usando EEMD

4.2.2 Resultados do classificador EMD

A Figura 53 mostra o resultado da reconstrução do sinal do paciente 118, em termos do valor do NRMSE para cada segmento de entrada e saída do sistema. Nesta imagem fica claro que o EMD funciona pior para o EEMD tanto para sinais com pouco artefato quanto para sinais com muito artefato. Enquanto o EEMD atua muito pouco nos sinais com pouco artefato, aqui os classificadores atuam e removem componentes degradando a qualidade do sinal em sinais com pouco artefato, como é o caso de sinais com SNR 18dB e 24dB.

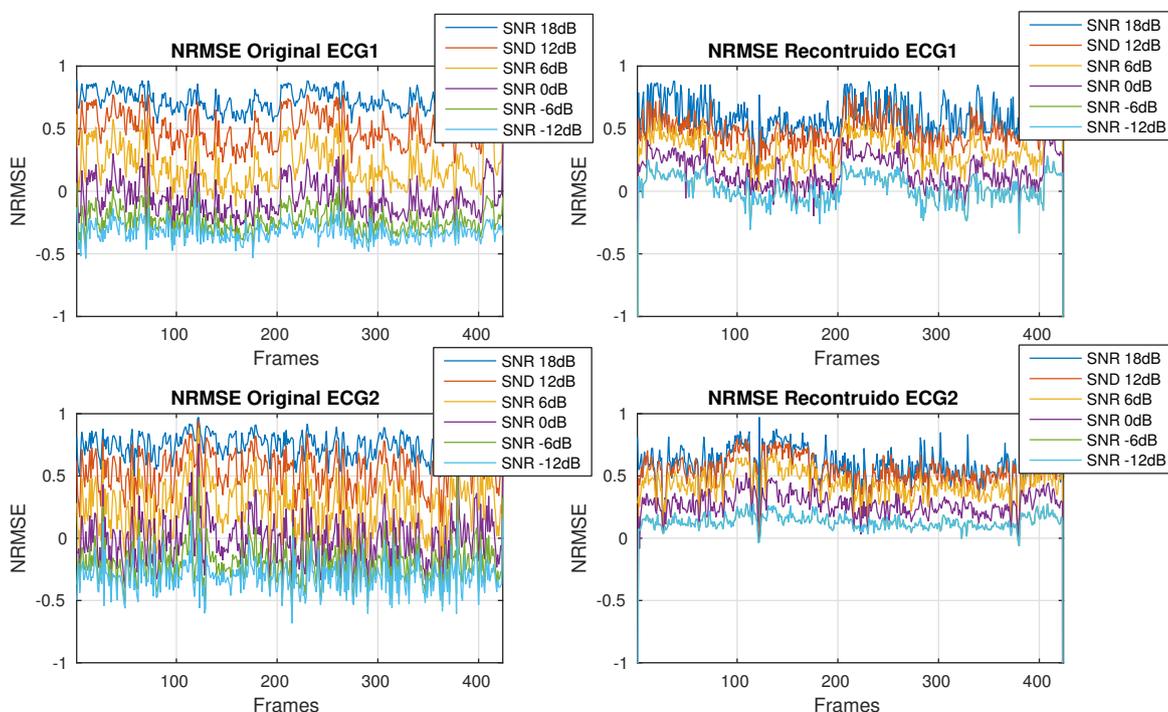


Figura 53: NMSE do Recuperação utilizando EMD do sinal do paciente 118

A Figura 54 mostra o mesmo resultado da reconstrução do sinal do paciente 119.

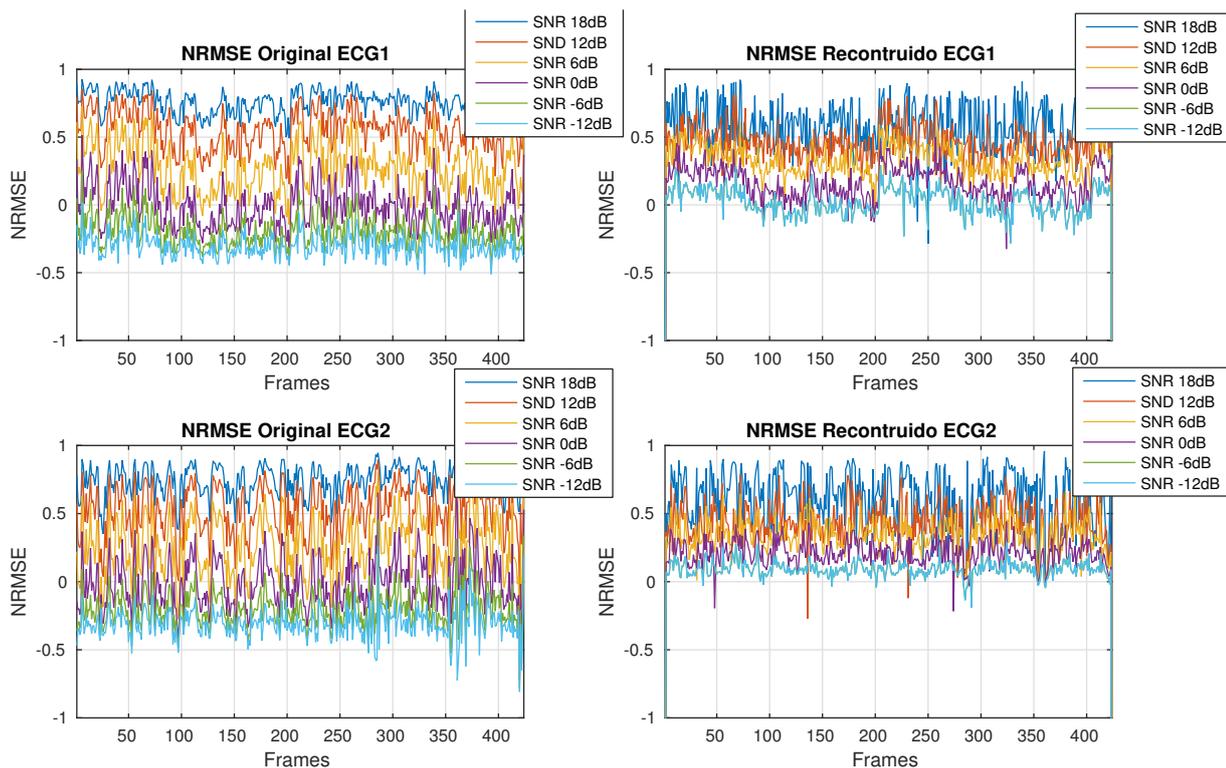


Figura 54: NMSE do Recuperação utilizando EMD do sinal do paciente 119

Para comparação na Figura 55 foram traçados os gráficos com o NRMSE médio do sinal de entrada versus o NRMSE do sinal de saída usando a decomposição EEMD e os classificadores. O ponto central representa o valor médio do NRMSE de saída e as barras verticais representam o desvio padrão do NRMSE.

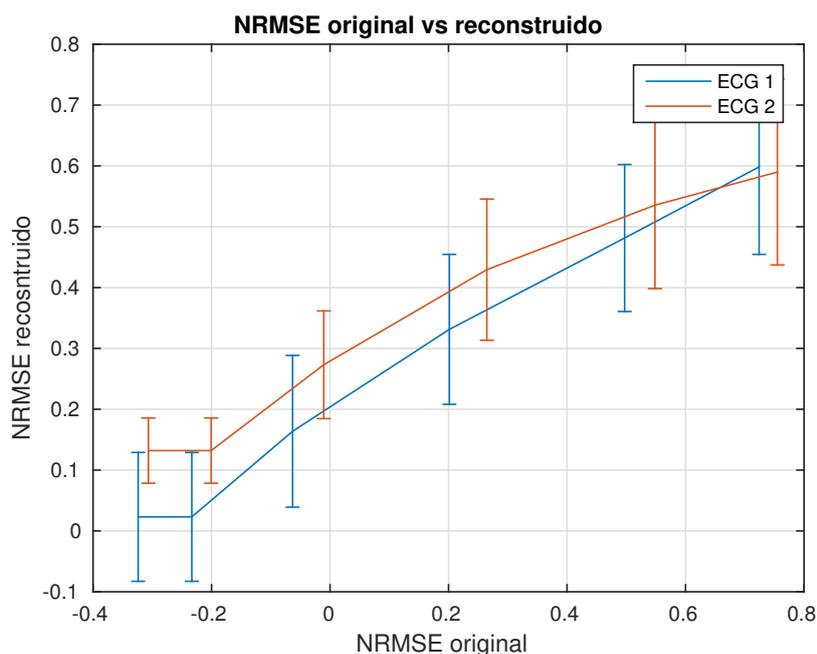


Figura 55: NRMSE de entrada versus NRMSE de saída utilizando EMD do paciente 118

Na Figura 56 é mostrado o resultado da reconstrução do sinal do paciente 119.

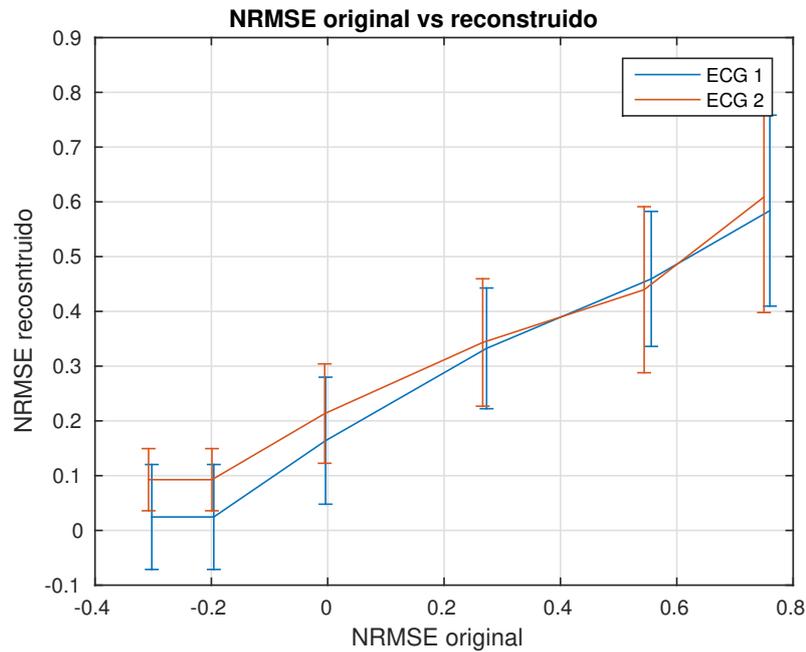


Figura 56: NRMSE de entrada versus NRMSE de saída utilizando EMD do paciente 119

Um exemplo da remoção dos componentes para remoção de artefatos pode ser visto na Figura 57. O sinal original com artefato em laranja e o sinal recuperado sem as componentes 6, 7 e 8 está em azul.

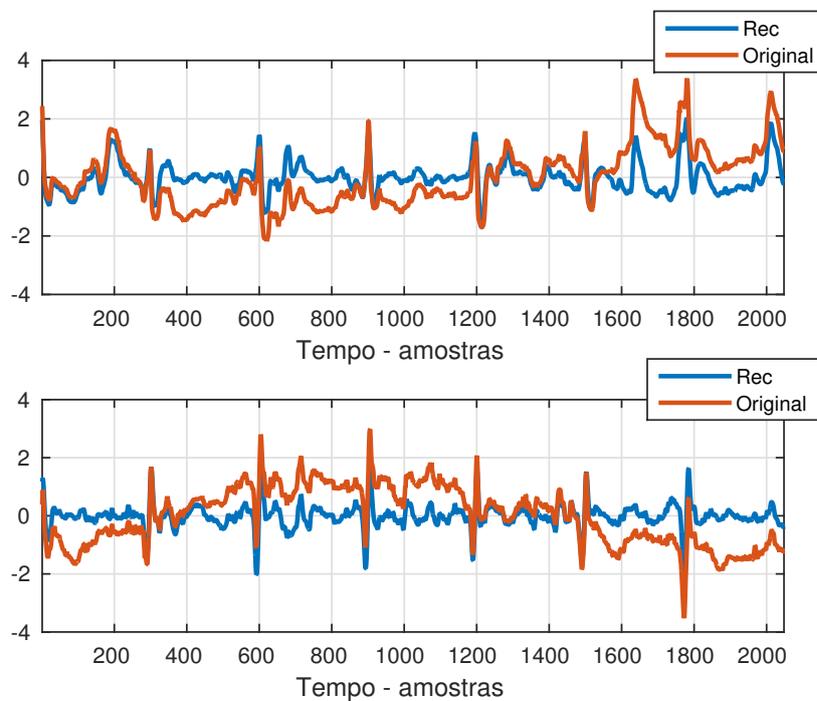


Figura 57: Exemplo de decomposição por EMD de segmento com e sem artefato

Na Figura 58 temos um exemplo da estimativa do sinal do artefato, reconstruído a partir das componentes 6, 7 e 8.

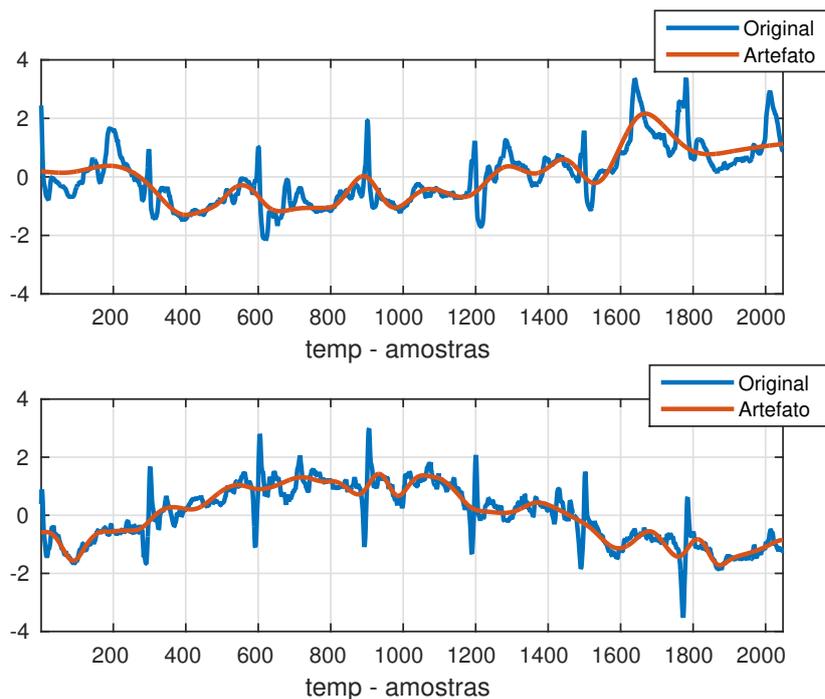


Figura 58: Exemplo da reconstrução do artefato usando EMD

4.2.3 Resultados do classificador Transformada Wavelet Estacionária - TWE

A Figura 59 mostra o resultado da reconstrução do sinal do paciente 118, em termos do valor do NRMSE para cada segmento de entrada e saída do sistema. Pode-se perceber que a TWE sofre do mesmo problema do EMD, os classificadores atuam em sinais onde não necessariamente deveriam atuar e acabam degradando o sinal com pouco artefato.

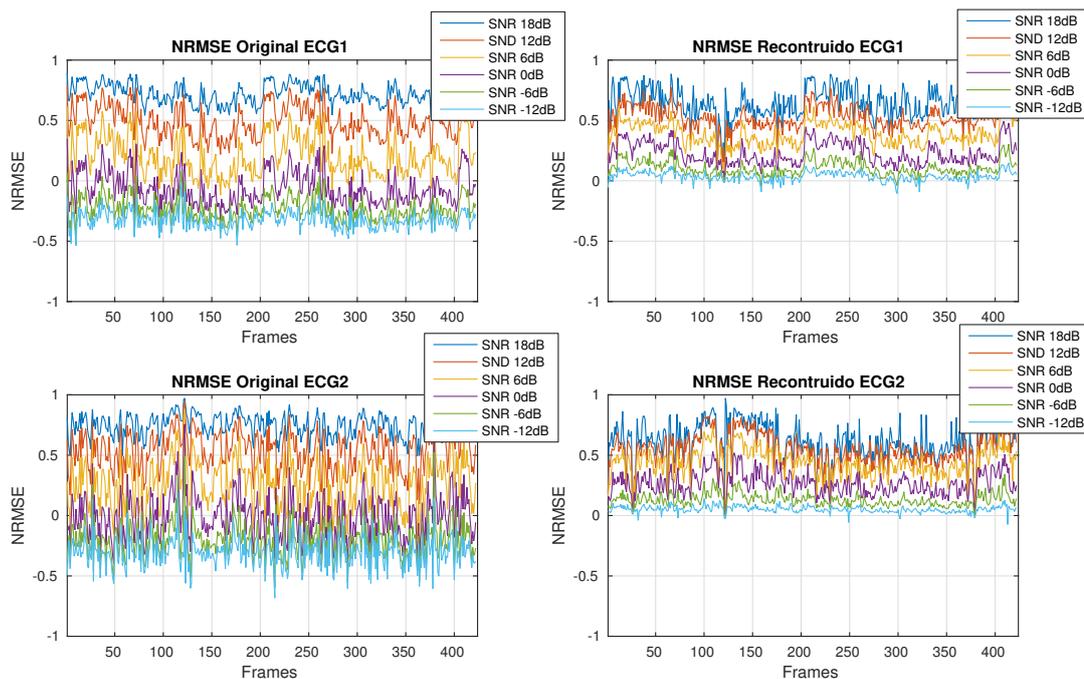


Figura 59: NRMSE do Recuperação utilizando TWE

A Figura 60 mostra o resultado da reconstrução do sinal do paciente 119, em termos do valor do NRMSE para cada segmento de entrada e saída do sistema.

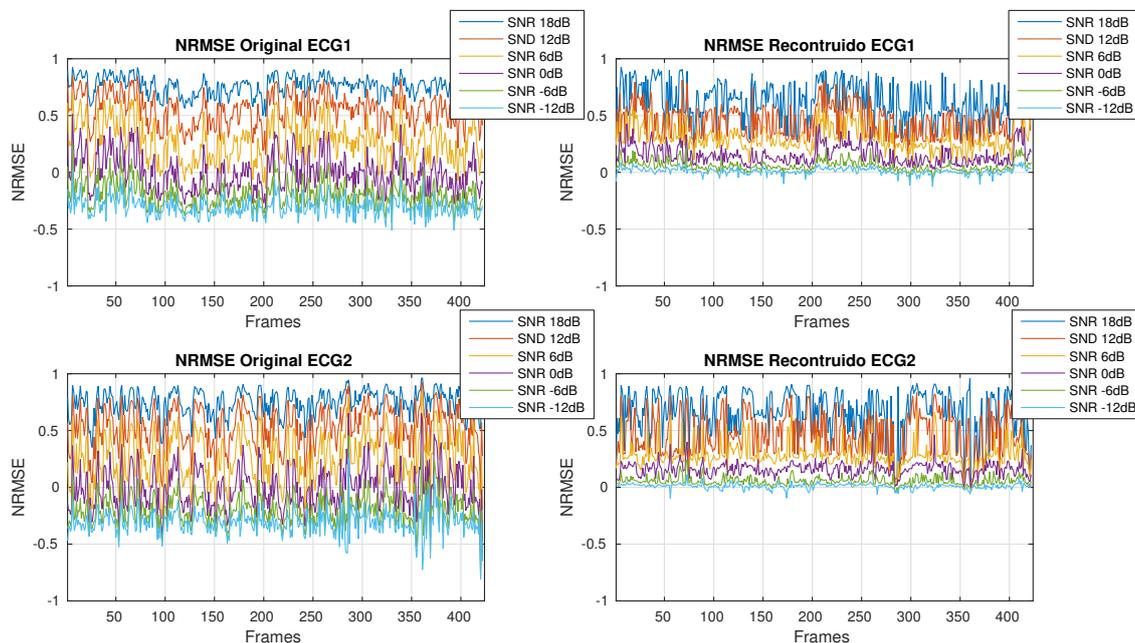


Figura 60: NRMSE do Recuperação utilizando SWL

Para melhor visualizar o resultado do processo de remoção de artefatos, a Figura 61 mostra a relação entre NRMSE na entrada e na saída para cada um dos dois sinais de ECG. do paciente 118.

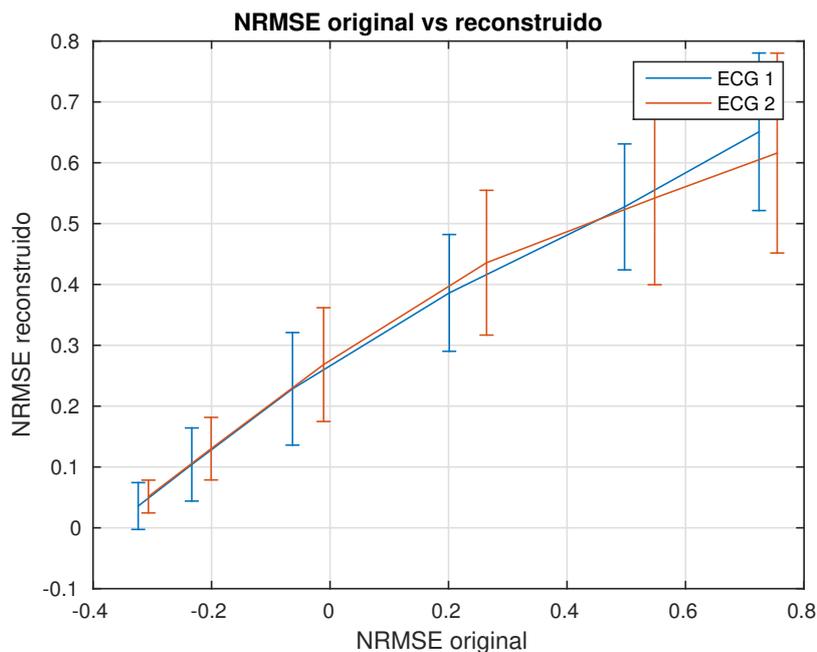


Figura 61: NRMSEin x NRMSE utilizando SWL do paciente 118

Para melhor visualizar o resultado do processo de remoção de artefatos, a Figura 62

mostra a relação entre NRMSE na entrada e na saída para cada um dos dois sinais de ECG, do paciente 119

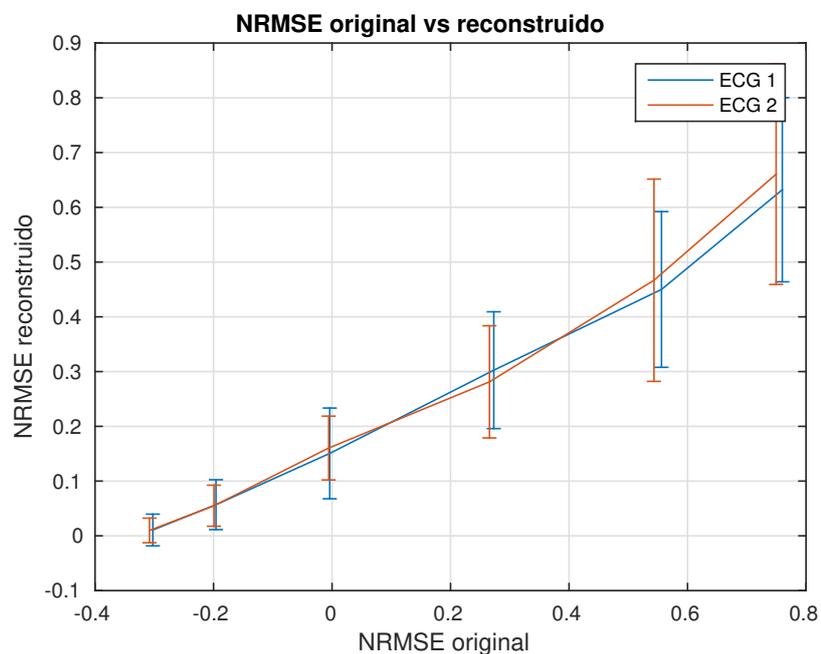


Figura 62: NRMSEin x NRMSE utilizando SWL do paciente 119

Um exemplo da remoção dos componentes para remoção de artefatos pode ser visto na Figura 63. O sinal original com artefato em laranja e o sinal recuperado sem as componentes 6, 7 e 8 esta em azul.

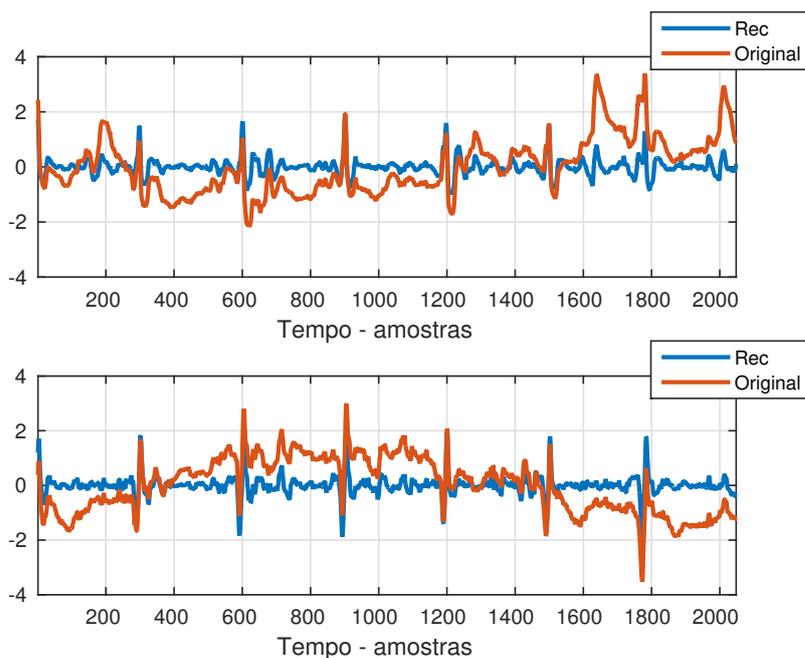


Figura 63: Exemplo de decomposição por Wavelet Estacionária de frame com e sem artefato

Na Figura 64 temos um exemplo da estimativa do sinal do artefato, reconstruído a partir das componentes 6, 7 e 8.

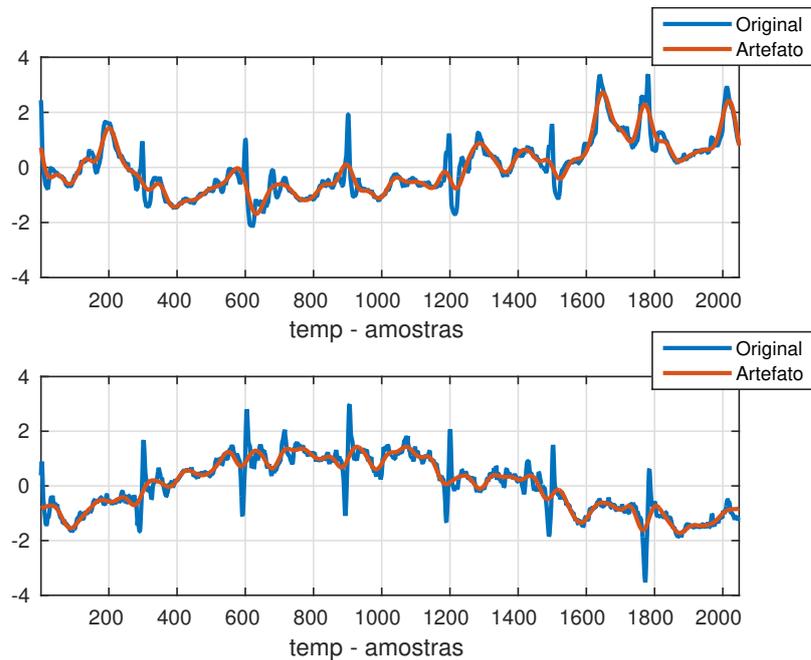


Figura 64: Exemplo da reconstrução do artefato usando TWE

4.2.4 Resultado do sistema usando a detecção e remoção de artefatos

Para testar o sistema completo, utilizando o detector de artefatos da seção anterior. Neste teste utilizamos o sinal gerado no caso do detector composto por 5 minutos sem artefato, seguido de 2 minutos com artefato, depois 2 minutos sem artefato e assim sucessivamente. Neste caso testamos conjuntamente o detector de artefatos e a remoção de artefatos com EEMD. Apenas os segmentos com artefatos foram tratados. A Figura 65 mostra o NRMSE do sinal de saída para cada dosagem de artefato. Cada ponto no gráfico representa o NRMSE de um segmento, e cada trecho representa uma dosagem de artefato. Os trechos com artefatos melhoraram o NRMSE (quanto mais perto de 1 melhor), e os trechos sem artefatos, em sua maioria, ficaram inalterados.

Interessante notar que alguns segmentos apresentam degradação do NRMSE. Isto ocorre devido à detecção de artefato em segmentos em que não foram adicionados artefatos, mas devido ao banco de dados original, e teoricamente "limpo", conter artefatos de movimentos, provavelmente movimentos do paciente no leito. Isto causou artefatos no sinal considerado "limpo". Porém esta característica já era sabida desde o início do projeto e não compromete as conclusões.

4.3 Resultados da remoção de artefatos usando Decomposição e JBSS

As métricas de avaliação da qualidade do sinal reconstruído foram o NRMSE descrito na etapa anterior e o coeficiente de correlação entre o sinal de saída e o sinal "limpo". O coeficiente de correlação é descrito pela equação 36.

$$\rho_{X,Y} = \text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y} \quad (36)$$

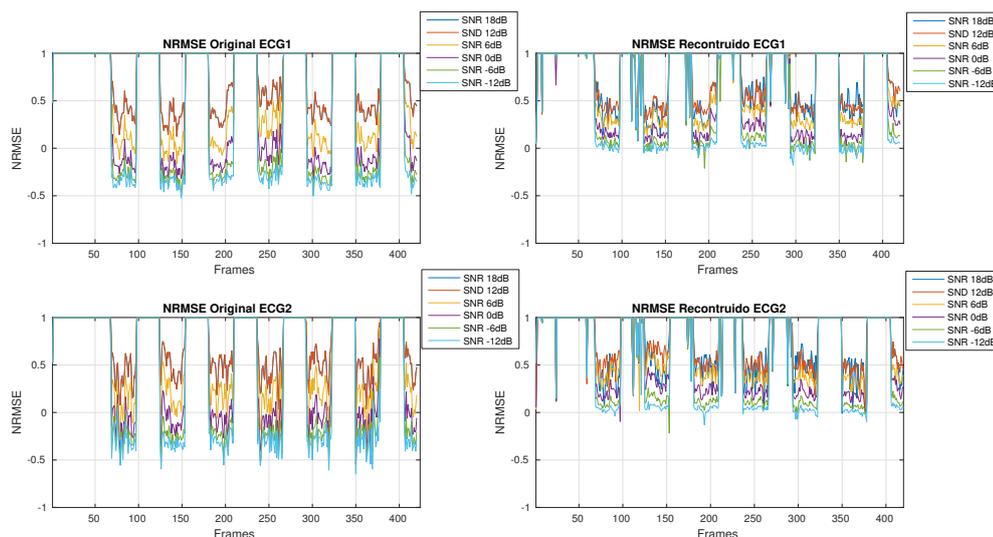


Figura 65: NMSE do Recuperação utilizando EEMD

O sistema desenvolvido foi testado com os sinais dos pacientes com as diferentes dosagens de ruído de artefato. A Tabela 17 apresenta a comparação entre o método utilizando a decomposição EEMD com o método utilizando decomposição +JBSS em termos do coeficiente de correlação e NRMSE entre o sinal de saída e o sinal de referência sem artefato. O método que utiliza JBSS apresentou melhoria na qualidade do sinal nas duas métricas em toda a faixa de artefatos. As Figuras 66 e 67 mostram os valores das Tabelas em forma de gráficos.

Tabela 16: Comparações do resultado de NRMSE entre métodos para cada dosagem de SNR

| NRMSE | Sinal | SNR -12dB | -6db | 0dB | 6dB | 12dB | 18dB |
|-----------------|-------|-----------|---------|---------|--------|--------|--------|
| Original | ECG1 | -0,3089 | -0,2052 | -0,0144 | 0,2662 | 0,5538 | 0,7595 |
| | ECG2 | -0,3010 | -0,2102 | -0,0409 | 0,2203 | 0,5095 | 0,7306 |
| Decomp. | ECG1 | 0,0434 | 0,1333 | 0,2672 | 0,4282 | 0,6365 | 0,7605 |
| | ECG2 | 0,0606 | 0,1403 | 0,2685 | 0,4386 | 0,5858 | 0,7345 |
| Decomp+ JBSS | ECG1 | 0,1177 | 0,2376 | 0,4136 | 0,5170 | 0,7097 | 0,7862 |
| | ECG2 | 0,1205 | 0,2563 | 0,4292 | 0,5250 | 0,6856 | 0,7712 |

Tabela 17: Comparações do resultado de correlação entre métodos para cada dosagem de SNR

| Correlação | Sinal | SNR -12dB | -6db | 0dB | 6dB | 12dB | 18dB |
|-----------------|-------|-----------|--------|--------|--------|--------|--------|
| Original | ECG1 | 0,1403 | 0,2688 | 0,4762 | 0,7186 | 0,8926 | 0,9682 |
| | ECG2 | 0,1461 | 0,2581 | 0,4447 | 0,6801 | 0,8691 | 0,9596 |
| Decomp | ECG1 | 0,3169 | 0,5176 | 0,7057 | 0,8213 | 0,9274 | 0,9693 |
| | ECG2 | 0,3835 | 0,5988 | 0,7689 | 0,8520 | 0,9063 | 0,9603 |
| Decomp+ JBSS | ECG1 | 0,4501 | 0,5896 | 0,8127 | 0,8886 | 0,9549 | 0,9837 |
| | ECG2 | 0,4899 | 0,6502 | 0,8283 | 0,8811 | 0,9434 | 0,9827 |

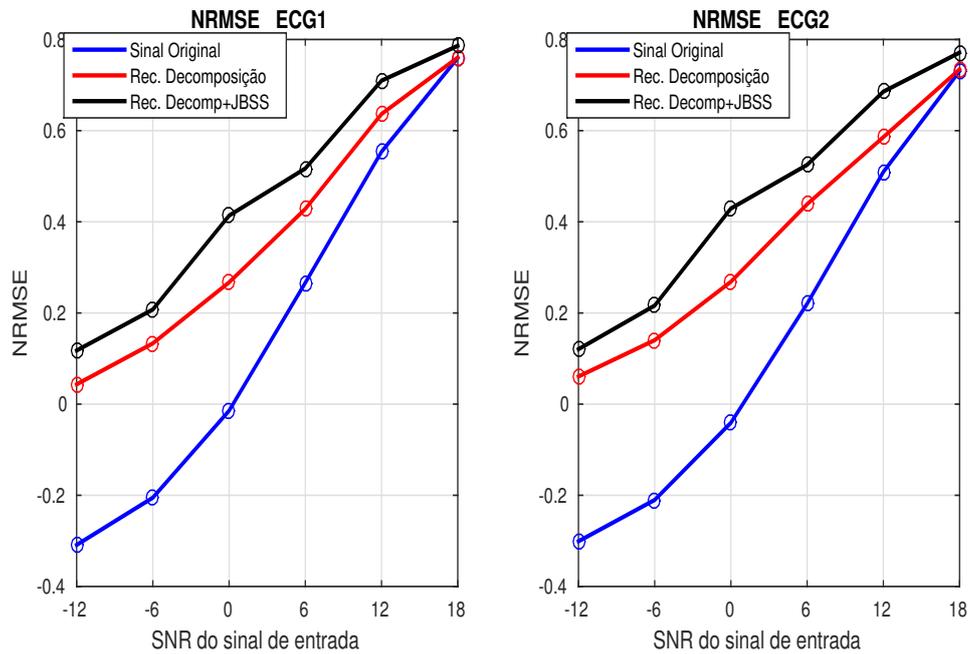


Figura 66: Comparação entre NRMSE do sinal Original, do sinal reconstruído por EEMD e do sinal reconstruído por EEMD+MCCA

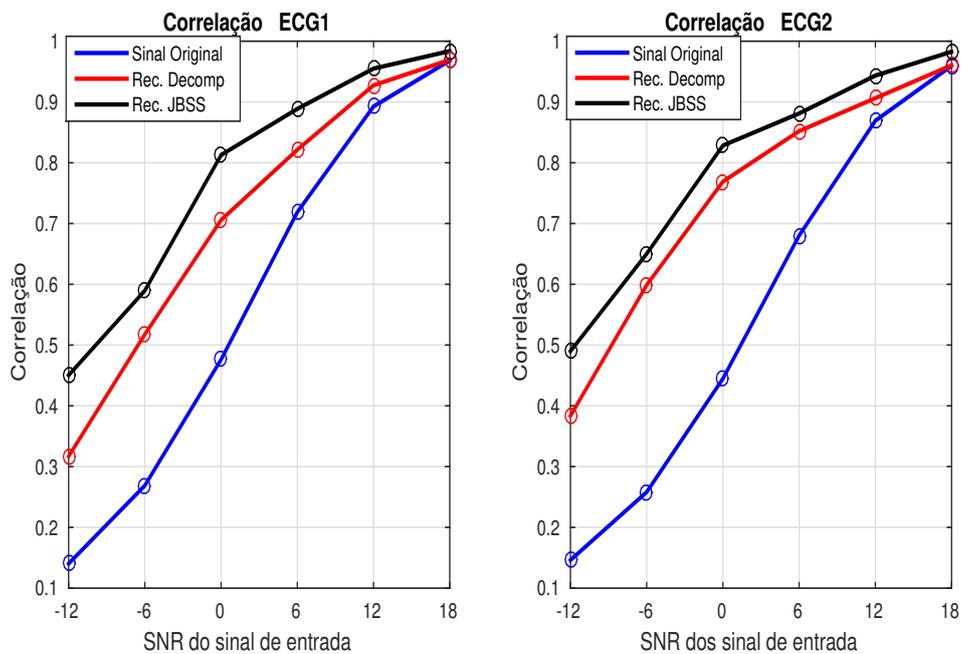


Figura 67: Comparação entre a correlação do sinal Original, do sinal reconstruído por EEMD e do sinal reconstruído por EEMD+MCCA

5 CONCLUSÃO

Nesse trabalho foi desenvolvido um sistema para detecção e remoção de artefatos de movimento de biosinais do tipo ECG. O bloco de detecção de artefatos tem seu funcionamento baseado em técnicas de *machine learning* com métricas estatísticas, podendo assim ser generalizado para outros tipos de sinais. Esse bloco foi implementado com uma máquina de vetores de suporte e obteve acurácia de 97% dos segmentos do conjunto de testes. Também são apresentados dois métodos de remoção de artefatos de movimento. O primeiro método apresentado é baseado na decomposição dos segmentos utilizando técnicas como EMD, EEMD e TWE. As componentes são então classificadas em artefato ou não artefato. As componentes classificadas como artefatos são então removidas e o sinal é reconstruído. A saída deste bloco mostra a remoção substancial do artefato de movimento, porém pode-se observar em vários segmentos que o sinal ainda apresenta o ruído.

O segundo método desenvolvido utiliza a etapa anterior de decomposição, e além disso adiciona um bloco de separação cega de fontes conjunta como método de fusão de informação das componentes para "aglutinar" os sinais de artefato em fontes sequenciais e, assim, encontrar as regiões correspondentes aos artefatos para remoção. O modelo do classificador utilizado neste método foi o Conjunto de árvore de decisões (*Random Forest*), por apresentar a maior especificidade, ou seja, capacidade de reconhecimento de sinal "Não artefatos". Embora as métricas de comparação quantitativas NRMSE e correlação não apresentem uma diferença substancial em relação ao método de decomposição apresentado nessa dissertação, o método com JBSS (MCCA e IVA-G) obteve grande melhora na qualidade da forma do sinal reconstruído.

6 TRABALHO FUTUROS

Com o intuito de melhorar a classificação de segmentos de imagem pretende-se aprimorar a metodologia de segmentação. Para tal objetivo acredita-se que a utilização de segmentação por K-means ou segmentação por *Watershed* possam resolver melhor a questão da segmentação de imagens.

Ainda na questão da classificação, outro ponto fraco do trabalho é o baixo desempenho dos classificadores. Para contornar esse problema acredita-se que a metodologias de *deep learning* possam apresentar resultados melhores. Nessa linha acredita-se que algoritmos de classificação como Redes Neurais Convolucionais e *Generative Adversarial Networks* - *GAN* apresentarão melhores resultados.

Uma outra linha interessante para estender o trabalho é desenvolver uma separação cega de fontes que consiga aglomerar os sinais de interesse e os sinais de artefatos em fontes distintas. Esta abordagem tornaria possível a remoção de artefatos de forma muito mais simples que a segmentação de imagens. Pois, como visto neste trabalho, o classificador de séries temporais funciona muito bem. E assim poderia remover fontes de artefatos de forma mais eficiente.

Outro ponto sensível deste trabalho é o pequeno numero de pacientes amostrados. Foram apenas 2 pacientes. Assim entende-se que testar o sistema em sinais de um numero maior de pacientes irá torna-lo mais flexível. Em um trabalho futuro pretende-se testar o sistema em todo o banco de dados com 47 pacientes.

REFERÊNCIAS

AHSAN H. KHANDOKER MARIMUTHU PALANISWAMI, C. K. K. Support Vector Machines for Automated Recognition of Obstructive Sleep Apnea Syndrome From ECG Recordings. **TRANSACTIONS ON INFORMATION TECHNOLOGY IN BIOMEDICINE**, New York, v.13, n.1, p.37–48, Jan 2009.

ANDERSON, M.; ADALI, T.; LI, X.-L. Joint Blind Source Separation With Multivariate Gaussian Model: algorithms and performance analysis. **IEEE TRANSACTIONS ON SIGNAL PROCESSING**, New York, v.60, n.4, p.1672–1683, April 2012.

BARHATTE, A. S.; GHONGADE, R.; TEKALE, S. V. Noise analysis of ECG signal using fast ICA. In: CONFERENCE ON ADVANCES IN SIGNAL PROCESSING (CASP), 1., 2016, Pune - India. **Proceedings...** IEEE: New York, 2016. p.118–122.

BHOWMIK, T.; DEY, J.; TIWARI, V. N. A novel method for accurate estimation of HRV from smartwatch PPG signals. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC), 39., 2017, Seogwipo - South Korea. **Proceedings...** IEEE: New York, 2017. p.109–112.

BISHOP, C. **Pattern Recognition and Machine Learning**. 1.ed. Berlin: Springer, 2006. 472p.

BREIMAN, L. Random Forests. **Machine Learning**, Hingham, MA, USA, v.45, n.1, p.5–32, Oct 2001.

CARDOSO, J.-F. Blind Signal Separation: statistical principles. **Proceedings of the IEEE**, New York, v.86, n.10, October 1998.

CHEN, X. et al. An EEMD-IVA Framework for Concurrent Multidimensional EEG and Unidimensional Kinematic Data Analysis. **IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING**, New York, v.61, n.7, p.2187–2198, July 2014.

CHEN, X. et al. The use of Multivariate EMD and CCA for Denoising Muscle Artifacts from Few-Channel EEG Recordings. **Transactions on Instrumentation and Measurement**, New York, v.PP, p.1–12, Nov 2017.

CHEN, X. et al. Independent Vector Analysis Applied to Remove Muscle Artifacts in EEG Data. **IEEE Transactions on Instrumentation and Measurement**, New York, v.66, n.7, p.1770–1779, July 2017.

CHEN, X.; HE, C.; PENG, H. Removal of muscle Artifacts from Single-Channel EEG Based on Ensemble Empirical Mode Decomposition and Multiset Canonical Correlation Analysis. **Journal of Applied Mathematics**, London, v.2014, n.Article ID 261347, p.1–10, June 2014.

CHEN, X.; WANG, Z. J.; MCKEOWN, M. Joint Blind Source Separation for Neurophysiological Data Analysis: multiset and multimodal methods. **IEEE Signal Processing Magazine**, Piscataway - USA, v.33, n.3, p.86–107, May 2016.

CHOI, S. et al. Blind Source Separation and Independent Component Analysis: a review. **Neural Information Processing - Letters and Reviews**, Cambridge - EUA, v.6, n.1, p.1–57, January 2005.

CLERCQ, W. D. et al. Canonical Correlation Analysis Applied to Remove Muscle Artifacts From the Electroencephalogram. **IEEE Transactions on Biomedical Engineering**, New York, v.53, n.12, p.2583–2587, Nov 2006.

GOLDBERGER, A. et al. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. **Circulation**, Dallas - USA, v.101, n.23, p.215–20, June 2000.

GONZALES, R. C. **Processamento Digital de Imagens**. 2.ed. New York: Pearson, 2010. 509p.

GÉRON, A. **Hand-On Machine Learning with Sckit-Learn and TensorFlow**: concepts, tools, and techniques to build intelligent systems. 1.ed. Sebastopol, CAa: O'Reilly Medi, 2017. 570p.

HAO, J. et al. Independent Vector Analysis for Source Separation Using a Mixture of Gaussians Prior. **Neural Computation**, Cambridge, v.22, n.6, p.1646–1673, June 2010.

HASSAN, M. et al. Combination of Canonical Correlation Analysis and Empirical Mode Decomposition Applied to Denoising the Labor Elettrohysterogram. **IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING**, New York, v.58, n.9, p.2441 – 2447, September 2011.

HAYKIN, S. **Neural Networks and Learning Machines**. 3.ed. New York: Prentice Hall, 2009. 938p.

HUANG, N. et al. The empirical mode decomposition and the Hilbert spectrum for non-linear and non-stationary time series analysis. **Proceedings of the Royal Society of London A**, London, v.454, n.1971, p.903–995, March 1998.

HYVÄRINEN, A.; OJA, E. A Fast Fixed-Point Algorithm for Independent Component Analysis. **Neural Computation**, Finland, v.9, n.7, p.1483–1492, July 1997.

HYVÄRINEN, A.; OJA, E. **Independent Component Analysis**: algorithms and applications. Finland, 2000.

KETTENRING, J. R. Canonical analysis of several sets of variables. **Biometrika**, Oxford, v.58, n.3, p.433–51, December 1971.

KHAN, E. et al. A Robust Heart Rate Monitoring Scheme Using Photoplethysmographic Signals Corrupted by Intense Motion Artifacts. **IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING**, Piscataway, NJ, USA, v.63, n.3, p.550–62, March 2015.

KRISHNAN, R.; NATARAJAN, B.; WARREN, S. Two-Stage Approach for Detection and Reduction of Motion Artifacts in Photoplethysmographic Data. **IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING**, New York, v.57, n.8, p.1867–76, August 2010.

LEE, J. et al. Automatic Motion and Noise Artifact Detection in Holter ECG Data Using Empirical Mode Decomposition and Statistical Approaches. **IEEE Transactions on Biomedical Engineering**, New York, v.59, n.6, p.1499–1506, June 2012.

LI, Y.-O. et al. Joint Blind Source Separation by Multiset Canonical Correlation Analysis. **IEEE Transactions on Signal Processing**, New York, v.57, n.10, p.3918–3929, Oct 2009.

LOH, W.-Y. Regression Trees with Unbiased Variable Selection and Interaction Detection. **Statistica Sinica**, Wisconsin–Madison, v.12, p.361–38, 2002.

MAHAJAN, R.; MORSHED, B. Unsupervised Eye Blink Artifact Denoising of EEG Data with Modified Multiscale Sample Entropy, Kurtosis and Wavelet-ICA. **IEEE Journal of Biomedical and Health Informatics**, New York, v.19, n.1, p.158–165, January 2015.

MAHAJAN, R.; MORSHED, B. I. Sample Entropy enhanced wavelet-ICA denoising technique for eye blink artifact removal from scalp EEG dataset. In: INTERNATIONAL IEEE/EMBS CONFERENCE ON NEURAL ENGINEERING (NER), 6, 2013, San Diego - USA. **Proceedings...** IEEE: New York, 2013. p.1394–1397.

MAIK RIEDL ANDREAS MÜLLER, N. W. Practical considerations of permutation entropy. **The European Physical Journal Special Topics**, Berlin, v.222, n.2, p.249–262, June 2013.

MALLAT, S. G. A Theory for Multiresolution Signal Decomposition: the wavelet representation. **Transaction on Pattern Analysis and Machine Intelligence**, New York, v.11, n.7, p.647–693, July 1989.

MEINSHAUSEN, N. Quantile Regression Forests. **Journal of Machine Learning Research**, Zurich - Switzerland, v.7, p.983–999, Dec 2006.

MILANESI, M. et al. Frequency domain approach to blind source separation in ECG monitoring by wearable system. In: COMPUTERS IN CARDIOLOGY, 32., 2005, Lyon, France. **Proceedings...** IEEE: New York, 2005. p.767–770.

MILANESI, M. et al. Multichannel Techniques for Motion Artifacts Removal from Electrocardiographic Signals. In: INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 28., 2006, New York. **Proceedings...** IEEE: New York, 2006. p.3391–3394.

MILANESI, M. et al. Independent component analysis applied to the removal of motion artifacts from electrocardiographic signals. **Medical & Biological Engineering & Computing**, Berlin, v.46, n.3, p.251–261, Mar 2008.

MOODY, G. B.; MARK, R. B. The impact of the MIT-BIH Arrhythmia Database. **IEEE Engineering in Medicine and Biology Magazine**, New York, v.20, p.45–50, 2001.

MOODY, G. B.; MULDROW, W. E.; MARK, R. B. A noise stress test for arrhythmia detectors. **Computers in Cardiology**, New York, v.11, p.381–384, 1984.

MOZAFFARIAN, D. et al. Heart Disease, Stroke and Research Statistics At-a-Glance. **Circulation**, Dallas, v.133, p.447–454, 2015.

NAGAI, S.; ANZAI, D.; WANG, J. Motion artifact removal for wearable ECG using stationary wavelet multi-resolution analysis. In: IEEE INTERNATIONAL SYMPOSIUM ON ELECTROMAGNETIC COMPATIBILITY (EMC), 5., 2017 Beijing. **Proceedings...** IEEE: New York, 2017. p.1–5.

NASON, G.; SILVERMAN, B. **The Stationary Wavelet Transform and some Statical Applications**. 1995.

RAGHURAM, M.; SIVANI, K.; REDDY, K. A. E2MD for reduction of motion artifacts from photoplethysmographic signals. In: INTERNATIONAL CONFERENCE ON ELECTRONICS AND COMMUNICATION SYSTEMS (ICECS), 2014, Coimbatore - India, New York. **Proceedings...** IEEE, 2014. p.1–6.

RAM, M. et al. ICA-Based Improved DTCWT Technique for MA Reduction in PPG Signals With Restored Respiratory Information. **IEEE Transactions on Instrumentation And Measurement**, New York, v.62, p.2639 – 2651, June 2013.

RAVELO-GARCÍA, A. et al. Application of the Permutation Entropy over the Heart Rate Variability for the Improvement of Electrocardiogram-based Sleep Breathing Pause Detection. **Entropy**, Basel - Switzerland, v.17, n.3, p.914–927, Feb 2015.

ROBLES-RUBIO, C.; BROWN, K. A.; KEARNEY, R. E. A new movement artifact detector for photoplethysmographic signals. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 35., 2013, Osaka - Japan. **Proceedings...** IEEE: New York, 2013. p.2295–2299.

SELVARAJ, N. et al. Statistical Approach for the Detection of Motion\Noise Artifacts in Photoplethysmogram. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE (EMBS), 33., 2011, Boston, Massachusetts USA. **Proceedings...** IEEE: New York, 2011. p.4972–4975.

SHOAIB, M. et al. A Close-loop System for Artifact Mitigation in Ambulatory Electrocardiogram Monitoring. In: DESIGN, AUTOMATION TEST IN EUROPE CONFERENCE EXHIBITION (DATE), 1., 2012, Dresden - Germany. **Proceedings...** IEEE: New York, 2012. p.431–436.

SWEENEY, K. T.; MCLOONE, S. F.; WARD, T. E. The Use of Ensemble Empirical Mode Decomposition With Canonical Correlation Analysis as a Novel Artifact Removal Technique. **IEEE Transactions on Biomedical Engineering**, New York, v.60, n.1, p.97 – 105, Jan 2013.

SWEENEY, K. T.; WARD, T. E. W.; MCLOONE, S. F. Artifact Removal in Physiological Signals - Practices and Possibilities. **Trans. Info. Tech. Biomed.**, Piscataway, NJ, USA, v.16, n.3, p.488–500, May 2012.

TAJI, B.; CHAN, A. D. C.; SHIRMOHAMMADI, S. Classifying measured electrocardiogram signal quality using deep belief networks. In: IEEE INTERNATIONAL INSTRUMENTATION AND MEASUREMENT TECHNOLOGY CONFERENCE (I2MTC), 31., 2017, Turin - Italy. **Proceedings...** IEEE: New York, 2017. p.1–6.

TAN, X. et al. EMD-Based Electrocardiogram Delineation for a Wearable Low-Power ECG Monitoring Device. **Canadian Journal of Electrical and Computer Engineering**, Ontario, v.37, n.4, p.212–221, September 2014.

VARON, C. et al. Robust artefact detection in long-term ECG recordings based on autocorrelation function similarity and percentile analysis. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 34., 2012, San Diego, CA, USA. **Proceedings...** IEEE: New York, 2012. p.3151–3154.

VAZ, P. et al. An automatic method for motion artifacts detection in photoplethysmographic signals referenced with electrocardiography data. In: INTERNATIONAL CONFERENCE ON BIOMEDICAL ENGINEERING AND INFORMATICS, 7., 2014, Dalian, China. **Proceedings...** IEEE: New York, 2014. p.704–708.

WENG, B.; BLANCO-VELASCO, M.; BARNER, K. E. ECG Denoising Based on the Empirical Mode Decomposition. In: INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 28., 2006, New York, USA. **Proceedings...** IEEE: New York, 2006. p.1–4.

ZENG, K. et al. An EEMD-ICA Approach to Enhancing Artifact Rejection for Noisy Multivariate Neural Data. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v.24, p.630–638, June 2016.

ZHANG, Q. et al. A Machine Learning-Empowered System for Long-Term Motion-Tolerant Wearable Monitoring of Blood Pressure and Heart Rate With Ear-ECG/PPG. **IEEE Access**, New York, v.5, p.10547–10561, June 2017.

ZHANG, Q.; ZHOU, D.; ZENG, X. A novel machine learning-enabled framework for instantaneous heart rate monitoring from motion-artifact-corrupted electrocardiogram signals. **Physiological Measurement**, Bristol - United Kingdom, v.37, n.11, p.1945, September 2016.

ZHANG, Q.; ZHOU, D.; ZENG, X. Machine Learning-Empowered Biometric Methods for Biomedicine Applications. **AIMS Medical Science**, Springfield - USA, v.4, n.3, p.274–290, July 2017.

ZHANG, Z.; LI, H.; MANDIC, D. P. Blind source separation and artefact cancellation for single channel bioelectrical signal. In: IEEE 13TH INTERNATIONAL CONFERENCE ON WEARABLE AND IMPLANTABLE BODY SENSOR NETWORKS (BSN), 13., 2016, San Francisco - USA. **Proceedings...** IEEE: New York, 2016. p.177–182.

ZHAOHUA WU, N. E. H. Ensemble Empirical Mode Decomposition: a noise assisted data analysis method. **Advances in Adaptive Data Analysis**, New York, v.1, n.1, p.1–41, 2009.

APÊNDICE A

A.1 Classificador de componentes - EEMD

A seguir estão plotados as matrizes de confusão de cada classificador treinado com as métricas das componentes 6, 7 e 8.

Tabela 18: Matriz de Confusão do Classificador SVM componente 6 do ECG 1

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 425 | 87 |
| | Não Artefato | 117 | 389 |

Tabela 19: Matriz de Confusão do Classificador SVM componente 6 do ECG 2

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 449 | 63 |
| | Não Artefato | 60 | 446 |

Tabela 20: Matriz de Confusão do Classificador SVM componente 7 do ECG 1

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 487 | 25 |
| | Não Artefato | 32 | 474 |

Tabela 21: Matriz de Confusão do Classificador SVM componente 7 do ECG 2

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 449 | 63 |
| | Não Artefato | 48 | 458 |

Tabela 22: Matriz de Confusão do Classificador SVM componente 8 do ECG 1

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 473 | 39 |
| | Não Artefato | 50 | 456 |

Tabela 23: Matriz de Confusão do Classificador SVM componente 8 do ECG 2

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 465 | 47 |
| | Não Artefato | 26 | 480 |

A.2 Classificador de componentes - EMD

Tabela 24: Matriz de Confusão do Classificador SVM componente 6 do ECG 1

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 389 | 105 |
| | Não Artefato | 203 | 321 |

Tabela 25: Matriz de Confusão do Classificador SVM componente 6 do ECG 2

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 414 | 80 |
| | Não Artefato | 171 | 358 |

Tabela 26: Matriz de Confusão do Classificador SVM componente 7 do ECG 1

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 360 | 126 |
| | Não Artefato | 152 | 372 |

Tabela 27: Matriz de Confusão do Classificador SVM componente 7 do ECG 2

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 367 | 127 |
| | Não Artefato | 151 | 373 |

Tabela 28: Matriz de Confusão do Classificador SVM componente 8 do ECG 1

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 377 | 117 |
| | Não Artefato | 248 | 276 |

Tabela 29: Matriz de Confusão do Classificador SVM componente 8 do ECG 2

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 404 | 90 |
| | Não Artefato | 294 | 230 |

A.3 Classificador de componentes - TWE

Tabela 30: Matriz de Confusão do Classificador SVM componente 6 do ECG 1

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 324 | 166 |
| | Não Artefato | 111 | 417 |

Tabela 31: Matriz de Confusão do Classificador SVM componente 6 do ECG 2

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 336 | 154 |
| | Não Artefato | 188 | 340 |

Tabela 32: Matriz de Confusão do Classificador SVM componente 7 do ECG 1

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 447 | 43 |
| | Não Artefato | 46 | 482 |

Tabela 33: Matriz de Confusão do Classificador SVM componente 7 do ECG 2

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 452 | 38 |
| | Não Artefato | 56 | 472 |

Tabela 34: Matriz de Confusão do Classificador SVM componente 8 do ECG 1

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 402 | 88 |
| | Não Artefato | 71 | 457 |

Tabela 35: Matriz de Confusão do Classificador SVM componente 8 do ECG 2

| | | Classes Previstas | |
|---------------------|--------------|-------------------|--------------|
| | | Artefato | Não artefato |
| Classes Verdadeiras | Artefatos | 382 | 108 |
| | Não Artefato | 98 | 430 |