

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE AUTOMAÇÃO E SISTEMAS**

Renan Goulart Heinzen

**Classificação de estados de estresse mental
através da variabilidade cardíaca**

Florianópolis
2018

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE AUTOMAÇÃO E SISTEMAS**

Renan Goulart Heinzen

**Classificação de estados de estresse mental através
da variabilidade cardíaca**

Dissertação submetida ao Programa de Pós-Graduação em Automação e Sistemas da Universidade Federal de Santa Catarina para a obtenção do grau de Mestre em Engenharia de Automação e Sistemas.

Orientador:

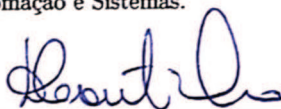
Prof. Dr. Alexandre Trofino Neto

Florianópolis
2018

Renan Goulart Heinzen

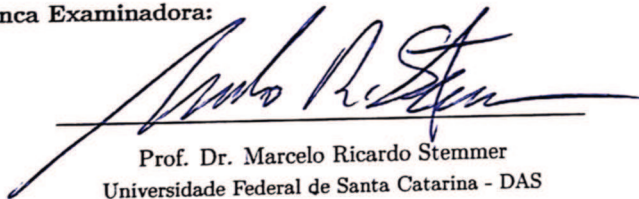
**Classificação de estados de estresse mental através
da variabilidade cardíaca**

Essa Dissertação foi julgada aprovada para a obtenção do Título de 'Mestre', e aprovada em sua forma final pelo Programa de Pós-Graduação em Automação e Sistemas.

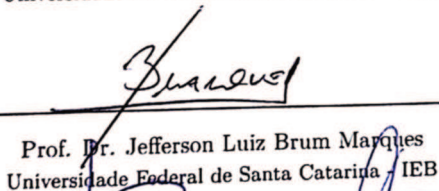


Prof. Dr. Daniel Ferreira Coutinho
Coordenador do Programa de Pós-Graduação

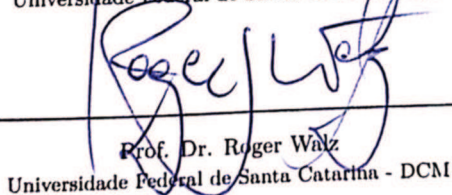
Banca Examinadora:



Prof. Dr. Marcelo Ricardo Stemmer
Universidade Federal de Santa Catarina - DAS



Prof. Dr. Jefferson Luiz Brum Marques
Universidade Federal de Santa Catarina - IEB



Prof. Dr. Roger Walz
Universidade Federal de Santa Catarina - DCM

AGRADECIMENTOS

Gostaria de agradecer primeiramente as pessoas que mais importam na minha vida, minha irmã Cássia, meu pai Eder e minha mãe Kátia, sem os quais nada disso teria sido possível.

Gostaria também de agradecer em especial ao meu orientador Alexandre pelas incontáveis horas de orientação, discussões e reflexões, e pela oportunidade de realizar este trabalho. Um muito obrigado ao meu amigo e informalmente co-orientador Cleison pelos incontáveis conselhos ao longo desses dois anos.

Não poderia deixar de agradecer ao meu colega e amigo Jonatas pelo apoio, pelos conselhos, pelas intermináveis conversas madrugada adentro e pela contribuição direta neste trabalho.

Junto do meu amigo Jonatas, um agradecimento aos meus amigos da InPulse, Lucas e Gabriel, que tiveram um papel fundamental na minha vida profissional.

Um muito obrigado também a CAPES pelo auxílio financeiro ao longo de dois anos, a Universidade Federal de Santa Catarina e ao Departamento de Automação e Sistemas pela estrutura fornecida.

Um agradecimento também aos meus queridos amigos Daniel, Dean, Eduardo, Luccas, Mateus, Rafael, Rigotti, Rodrigo, Saynovich, Thiele e tantos outros que vem me apoiando ao longo desses últimos anos.

Finalmente, a todas as pessoas que, além dessas, também contribuíram, mesmo que minimamente, muito obrigado.

RESUMO

Considerado pela OMS como uma epidemia, o estresse mental é definido como uma resposta natural do corpo a estímulos externos, sendo benéfico até certos níveis. No entanto, períodos prolongados de altos níveis desse estado estão associados ao desenvolvimento de doenças, como um aumento no risco de infarto, impotência ou depressão. Por ter um aumento constante de casos desse estresse prejudicial ao longo dos últimos anos, a informação de nível de estresse em tempo real é valiosíssima, podendo ser utilizada pelo usuário como uma forma de prevenção ou redução do nível alto de estresse. Dentro desse contexto, este trabalho apresenta uma metodologia para a identificação de níveis de estresse através da variabilidade cardíaca (HRV), justificado pela interação entre sistema nervoso autônomo (SNA) e atividade elétrica cardíaca. Através de análises temporais, frequenciais e não-lineares, essa metodologia proposta considera a dinâmica dos parâmetros extraídos para construir uma matriz de parâmetros evoluindo temporalmente e a seguir fornecer essa informação a um classificador. Neste trabalho foram utilizadas duas abordagens de classificadores, o clássico SVM (*Support Vector Machine*) e métricas de Riemann aplicadas a matrizes de covariância construídas a partir da dinâmica das análises. Testes foram realizados em cima de uma base de dados aberta, da qual foram selecionados 54 eventos em 9 sujeitos, que foram expostos a um experimento padronizado de níveis de estresse, classificados entre baixo, médio e alto. O resultado final dessa metodologia é comparado com a abordagem que não leva em consideração a dinâmica dos parâmetros, através da acurácia, métrica utilizada por trabalhos com o mesmo fim. As melhores configurações obtiveram acurácias de 86% e 82% através de métricas de Riemann e SVM, respectivamente, comparado com a abordagem mencionada que obteve uma acurácia de 75% para o mesmo conjunto de dados. Esses resultados demonstram que a dinâmica das análises de variabilidade pode ser utilizada como mais informação para a tomada de decisão dos classificadores ao identificar níveis de estresse mental a partir de sinais de HRV.

Palavras-chave: Estresse 1. Variabilidade Cardíaca 2. Aprendizado de Máquina 3. Riemann. 4

ABSTRACT

Considered by the WHO as an epidemic, mental stress is defined as a natural response by the body to external stimuli, being beneficial until certain levels. However, prolonged periods of high levels of stress can lead to serious conditions, such as heart attack, elevated blood pressure and even depression. Considering that this state has increased in case numbers during recent years, the result of real time stress level identification is a significant piece of information that can be used as an alarm so that the user can act in response to it. This work presents a methodology for stress level identification using Heart Rate Variability (HRV). From the HRV signal, temporal, frequencial and nonlinear parameters are computed several times to consider the dynamic of each parameter. Two types of classifiers were used, SVM (Support Vector Machine) and Riemannian metrics applied to covariance matrices built from the dynamical parameters. Simulations were performed applying the methodology to an open database comprising of 9 subjects, with a total of 54 epochs, split into low, medium and high stress levels. The final result is compared with the classical approach for identifying stress levels, where the HRV parameters dynamics is ignored. The best configurations provided accuracies of 86% and 82% for Riemann metrics and SVM classifiers respectively, compared to the mentioned approach with an accuracy of 75% for the same dataset. These results show that, by using the parameters dynamics, this methodology has the potential of working better than the classical approach when identifying mental stress levels from HRV.

Keywords: Stress 1. Heart Rate Variability 2. Machine Learning 3. Riemann. 4

Sumário

1	Introdução	1
1.1	Motivação	1
1.2	Trabalhos Relacionados	2
1.3	Contribuição	4
1.4	Organização do Documento	5
2	Neurofisiologia e Stress	7
2.1	Estresse	7
2.2	Sistema Nervoso Autônomo	9
2.3	Sistema Cardiovascular	12
2.3.1	Fisiologia	12
2.3.2	Condução elétrica	13
2.3.3	Ciclo Cardíaco	16
2.3.4	Influência do Sistema Nervoso Autônomo	16
2.4	Eletrocardiograma	18
2.5	Comentários	22
3	Variabilidade Cardíaca	23
3.1	Construção do sinal de Variabilidade, Detecção, Extração	23
3.1.1	Detecção com Transformada Wavelet	24

3.1.2	Extração do sinal de Variabilidade Cardíaca (HRV) a partir da detecção	27
3.2	Parâmetros de Variabilidade Cardíaca	27
3.2.1	Parâmetros Temporais	28
3.2.1.1	Parâmetros Temporais Estatísticos	28
3.2.2	Parâmetros Freqüenciais	29
3.2.3	Parâmetros Não-lineares	30
3.2.3.1	Gráfico de Poincaré	30
3.2.3.2	Maior Expoente de Lyapunov	32
3.2.3.3	Dimensão Fractal de Higuchi	32
3.2.3.4	Parâmetros de Hjorth	33
3.2.3.5	Entropia Amostral	34
3.3	Comentários	35
4	Algoritmos de Classificação	37
4.1	Máquinas de Vetores Suporte (SVM)	37
4.1.1	SVMs com Margens Rígidas	38
4.1.2	SVMs com Margens Suaves	41
4.1.3	SVMs Não-Lineares	41
4.1.4	Comentários	43
4.2	Geometria de Riemann e Matrizes de Covariância	43
4.2.1	Símbolos	44
4.2.2	Matrizes de Covariância	44
4.2.3	Notações e Definições	45
4.2.4	Geometria de Riemann	46
4.2.5	Classificação através da Distância	48
4.3	Comentários	48
5	Resultados	51
5.1	Base de dados usada	52
5.2	Metodologia utilizada	53
5.2.1	Pré-processamento e Extração da HRV	53
5.2.2	Pré-Seleção Manual e divisão em épocas	55
5.2.3	Construção da matriz de parâmetros para análise dinâmica	59
5.3	Análises de resultados	63
5.3.1	Correlação entre parâmetros de HRV	63
5.3.2	Quartis dos parâmetros de HRV e estresse	65

5.3.3	Quartis dos parâmetros de HRV e estresse por motorista	74
5.3.4	Classificação entre três níveis de estresse	80
6	Considerações Finais	87
6.1	Trabalhos Futuros	89

Lista de Figuras

2.1	Sistema Nervoso	9
2.2	Ramificações do Sistema Nervoso Autônomo	11
2.3	Sistema Cardiovascular	13
2.4	Potencial das Células Autoexcitáveis	14
2.5	Sistema de Condução Elétrica no Coração	15
2.6	Efeito da Estimulação Simpática na Despolarização	17
2.7	Efeito da Estimulação Parassimpática na Despolarização	18
2.8	Triângulo de Einthoven	19
2.9	Eletrocardiograma	20
2.10	Eletrocardiograma (ECG) no ciclo cardíaco	21
3.1	Wavelet Mãe Primeira Derivada Da Gaussiana	26
3.2	Sinais para Detecção da onda R	27
3.3	Densidade Espectral de Potência (PSD) das principais frequências do sinal de HRV	29
3.4	Gráfico de Poincaré	31
4.1	Separação por hiperplano	38
4.2	Separação por hiperplano com <i>outlier</i>	39
4.3	Espaços transformados	42
4.4	Variedade de Riemann ((<i>Riemann Manifold</i>))	46

5.1	Montagem do Experimento	52
5.2	Fluxo da Metodologia	54
5.3	Sinal de ECG com HRV	56
5.4	ECG com HRV na ausência de um ponto R	58
5.5	Janela Wo deslizante	61
5.6	Quartis de SDNN	66
5.7	Quartis da Média	67
5.8	Quartis de PNN50	68
5.9	Quartis de RMSSD	68
5.10	Quartis de LF	69
5.11	Quartis de HF	69
5.12	Quartis de SVI	70
5.13	Quartis de CSI	71
5.14	Quartis de CVI	71
5.15	Quartis de MH	72
5.16	Quartis de CH	73
5.17	Quartis de λ	73
5.18	Quartis de DFH	74
5.19	Quartis de SampEn	75
5.20	Quartis de pnn50 por Motorista	76
5.21	Quartis de RMSSD por Motorista	76
5.22	Quartis de HF por Motorista	77
5.23	Quartis de SVI por Motorista	78
5.24	Quartis de CSI por Motorista	79
5.25	Quartis de DFH por Motorista	79

Lista de Tabelas

4.1	Funções Kernel mais comuns	43
4.2	Algoritmo da Média de Riemann	48
5.1	Tabela de Eventos	59
5.2	Correlação entre parâmetros de HRV	64
5.3	Acurácia em marcações manuais	82
5.4	Número de passos e passos em segundos	82
5.5	Acurácia em marcações fornecidas	84
5.6	Acurácia em marcações fornecidas com extração de motoristas	85

Ca^{2+}	cálcio.
K^+	potássio.
Na^+	sódio.
ACh	acetilcolina.
AV	atrioventricular.
CSI	Índice Cardiosimpático.
CVI	Índice Cardiovagal.
DF	Dimensão Fractal.
DFH	Dimensão Fractal de Higuchi.
ECG	Eletrocardiograma.
EEG	Eletroencefalograma.
EMG	Eletromiograma.
HF	Alta Frequência.
HRV	Variabilidade Cardíaca.
LF	Baixa Frequência.
PCA	Análise de Componentes Principais.
PSD	Densidade Espectral de Potência.

SA	sinoatrial.
SampEn	Entropia Amostral.
SNA	Sistema Nervoso Autônomo.
SNC	Sistema Nervoso Central.
SNP	Sistema Nervoso Periférico.
SPD	Simétrica Positiva e Definida.
SVI	Índice Simpatovagal.
SVM	Máquina de Vetor Suporte.
ULF	Ultra Baixa Frequência.
VLF	Muito Baixa Frequência.

CAPÍTULO 1

Introdução

Pesquisas demonstram que um grande número de pessoas tem apresentado altos níveis de estresse mental prolongado ao longo dos últimos anos [45]. Esse estado prolongado está relacionado a diversas doenças como doenças cardíacas, pressão alta, diabete, depressão, infertilidade e principalmente falhas no sistema imunológico [4, 65].

Paralelamente, a tecnologia tem cada vez mais proporcionado melhoras na qualidade de vida, não só pelo fácil e rápido acesso a informação com o uso de dispositivos portáteis, mas também pela, cada vez mais presente, utilização de sensores que avaliam sinais vitais em tempo real, como, por exemplo, o sinal cardíaco.

Com a união desses dispositivos, processamento dos sinais adquiridos e aprendizado de máquina é possível identificar níveis de estresse para que o sujeito tenha essa informação em tempo real e consiga atuar em relação a isso.

1.1 Motivação

Diversos trabalhos tem demonstrado as mais variadas aplicações na análise do sinal cardíaco, tais como a classificação de emoções, predição

de crise epiléptica, identificação de níveis de estresse [36, 40, 70].

A maioria dos trabalhos que envolvem a identificação de níveis de estresse não detalha toda a metodologia aplicada e utiliza basicamente a mesma abordagem, de extrair um parâmetro de variabilidade de cada natureza possível para cada janela de evento de estresse para realizar a inferência daquele estado. Ao realizar uma revisão de trabalhos na área de engenharia biomédica, não foi encontrado nenhum trabalho que use a dinâmica dos parâmetros de variabilidade cardíaca para realizar essa inferência.

Este trabalho detalha toda a metodologia utilizada, desde a breve explicação para entendimento de conceitos fisiológicos, até a comparação entre a consideração ou não da dinâmica dos parâmetros de variabilidade. Esses parâmetros são fornecidos a dois classificadores distintos, a Máquina de Vetor Suporte (SVM) e uma abordagem de classificação que vem sendo utilizada em matrizes de covariância construídas a partir de sinais de Eletroencefalograma (EEG).

1.2 Trabalhos Relacionados

Diversos trabalhos recentes tem utilizado sinais de ECG para identificar estados mentais, como, por exemplo, o estresse mental [19, 36, 65, 67, 69, 70]. Em geral, são realizados experimentos controlados para mapear situações onde sujeitos estão em situações mentais conhecidas, para, a seguir, usar o sinal de ECG referente aquele instante de tempo onde a situação estava ocorrendo para treinar e validar modelos que consigam identificar esses estados mentais de forma automática.

Em [69] a análise de variabilidade cardíaca é usada para identificar quatro estados possíveis, neutro, feliz, estressado ou triste, utilizando uma combinação de SVM com algoritmo genético. Usando 10 sujeitos nesses quatro estados citados, a combinação no trabalho [69] obteve uma acurácia de 90%.

Já no trabalho apresentado em [70], o sinal de ECG com extração de características de HRV foi usado para medir níveis de estresse relacionados a tarefas de seguir orientações de um GPS enquanto dirige. Um número de 10 sujeitos foi usado para verificar a relevância estatística de parâmetros temporais e frequenciais do sinal de HRV, concluindo que os parâmetros frequenciais não oferecem muita informação relacionadas

ao estresse proveniente da tarefa citada.

No entanto, o trabalho [65] utiliza parâmetros frequenciais e temporais para atingir uma acurácia de 92% ao classificar entre quatro níveis de estresse, zero, baixo, médio e alto. Essa acurácia é obtida ao aplicar SVM com esses parâmetros de HRV em uma base de dados disponível online [24], também utilizada por este trabalho, mas com uma abordagem diferente. Além disso, em [65] os autores não deixam claro como foi feita a separação entre os níveis de estresse já que a base de dados fornece apenas eventos separados em três níveis, baixo, médio e alto. Para obter esse resultado com a base de dados mencionada, em [65] os autores usaram um software chamado Kubios [58] para fazer a extração dos parâmetros de HRV, 16 sujeitos para analisar e janelas de 10 minutos como épocas de análise. Ainda no trabalho apresentado em [65], os autores usam uma abordagem de estágios de classificação, começando pela separação entre sem estresse e com estresse e finalizando com a separação entre estresse nível médio e estresse nível alto.

A base de dados mencionada anteriormente é apresentada em [24], onde são utilizados outros sinais para classificação de níveis de estresse em motoristas realizando tarefas específicas, relacionadas a níveis de estresse respectivos. Dentre esses outros sinais estão o Eletromiograma (EMG) (Atividade Elétrica Muscular), respiração e condutividade da pele. Através da combinação de características extraídas desses sinais, o trabalho [24] obteve uma acurácia de 97,4%, usando intervalos de 5 minutos. Além dessa acurácia, foi mostrado que dados provenientes do batimento cardíaco e da condutividade da pele possuem a maior correlação com níveis de estresse [24].

Outro trabalho recente onde os autores também utilizam a base de dados disponível online [24] é o trabalho [36]. Nesse trabalho, foi obtido uma acurácia de 83,33% através de parâmetros temporais e não-lineares aplicados a um classificador SVM com base radial.

Uma combinação de Análise de Componentes Principais (PCA) com SVM foi usada em [20] para, através de HRV, identificar 5 estados de emoção em 25 sujeitos saudáveis. Foi obtido uma acurácia de 71,4% para a distinção entre 2 classes e 56,9% para a distinção entre as 5 classes.

Em [40], os autores também utilizam a combinação de HRV e SVM, onde é feita a detecção de crises epiléticas com sensibilidade de 94,1%.

Nesse trabalho, a partir dos parâmetros do sinal de HRV, é gerada uma matriz de covariância, decomposta em autovalores e autovetores que são posteriormente fornecidos como entrada ao SVM.

Em geral, os trabalhos que utilizam a base de dados [24] fazem análises das janelas inteiras dos eventos, não levando em conta que o estresse pode variar ao longo dessa janela de um nível de estresse zero a um nível de estresse alto.

Outro ponto a destacar é que nenhum desses trabalhos que faz análise de estados mentais leva em consideração a evolução de cada parâmetro temporalmente e entre parâmetros ao longo da janela do evento de interesse. Além disso, nenhum desses trabalhos deixa claro o instante usado para realizar a análise, considerando que existem pedaços de sinal inutilizáveis dentro dos períodos utilizados, o que é ilustrado por este trabalho, alguns longos trechos de sinal deveriam ser descartados.

1.3 Contribuição

Diferentemente de outros trabalhos, que tem como foco apenas a etapa final de classificação de estados mentais através da variabilidade cardíaca, com uma breve explicação das outras etapas, este trabalho descreve detalhadamente todo o processo utilizado para realizar a classificação de níveis de estresse.

Esse processo inicia na justificativa da utilização do sinal de Variabilidade Cardíaca, envolvendo questões fisiológicas, para, a seguir, abordar brevemente as possíveis análises que podem ser feitas com um sinal dessa natureza, bem como a sua construção.

Finalmente, o resultado presente na literatura é reproduzido e comparado com a metodologia apresentada neste trabalho, levando em consideração a dinâmica dos parâmetros de variabilidade, com um classificador baseado em métricas de Riemann, muito utilizadas em análises de EEG.

Ao longo da elaboração deste trabalho, houveram duas participações em publicações de artigos. O primeiro [54], uma das referências usadas para a analogia citada acima, está relacionado com este trabalho no capítulo de classificadores, onde é abordada a geometria não-euclidiana para distinguir matrizes de covariância. Já o trabalho [40], faz parte

de uma colaboração entre a tese de Doutorado citada anteriormente e esta dissertação. Conforme mencionado anteriormente, a metodologia aplicada neste trabalho para a identificação de níveis de estresse mental usando a dinâmica de parâmetros de Variabilidade Cardíaca é proposta e usada por [40] para a detecção e predição de crises epiléticas.

Para finalizar, uma interface gráfica foi desenvolvida através da biblioteca aberta Kivy, baseada na linguagem Python com intuito de facilitar as análises dos sinais de ECG. Essa interface conta com as etapas de pré-processamento padrões de um sinal de ECG, identificação de pedaços de sinal contaminados com ruído através de análises simples, mas que podem ser aprimoradas, algoritmo de detecção dos picos R abordado neste trabalho e o cálculo dos parâmetros usados também por este trabalho. Futuramente o código dessa interface será liberado para que a comunidade possa contribuir com a melhora contínua, facilitando a implementação de soluções envolvendo análises de sinais de ECG através da Variabilidade Cardíaca.

Este trabalho fez parte de uma contribuição com a tese de Doutorado do doutorando Jonatas Pavei, pelo departamento de Engenharia Elétrica da Universidade Federal de Santa Catarina, com o uso da mesma metodologia com algumas diferenças e aplicada na predição de crises epiléticas.

1.4 Organização do Documento

Este trabalho é organizado seguindo a seguinte estrutura:

- **Capítulo 2 - Neurofisiologia e Estresse** - Esse capítulo descreve de forma superficial o que é o estresse mental e a sua relação com o Sistema Nervoso Autônomo (SNA). A seguir, é feita a conexão do SNA com o Sistema Cardiovascular bem como uma breve revisão teórica do seu funcionamento, para finalmente abordar o ECG.
- **Capítulo 3 - Variabilidade Cardíaca** - Nesse capítulo é apresentada a série temporal de HRV e o algoritmo utilizado por este trabalho para a sua extração. Posteriormente, são abordados todos os parâmetros temporais, frequenciais e não-lineares utilizados para realizar as análises apresentadas no capítulo de resultados.

- Capítulo 4 - **Algoritmos de Classificação** - Esse capítulo aborda dois classificadores utilizados neste trabalho. O primeiro deles é o clássico SVM, com vetores de entrada padrões, seguido da geometria de Riemann em Matrizes de Covariância como classificador.
- Capítulo 5 - **Resultados** - Finalmente, esse capítulo apresenta a base de dados usada, o fluxo e metodologia utilizados para obter os resultados, análises e comparações de parâmetros de HRV com níveis de estresse e resultados de classificação usando os dois classificadores abordados.
- Capítulo 6 - **Considerações Finais** - Para concluir, algumas considerações relativas aos resultados obtidos são apresentadas, assim como sugestões de continuidade do trabalho apresentado.

CAPÍTULO 2

Neurofisiologia e Stress

Neste capítulo serão abordados aspectos biológicos básicos da neurofisiologia que diz respeito ao SNA, ao sistema cardíaco, dando um enfoque maior a propagação elétrica, e à relação entre eles.

Ainda no que se refere ao sistema cardíaco, será definido o sinal de ECG, desde a sua aquisição, até a relação das ondas presentes com eventos descritos também neste capítulo.

Além disso, será abordada a definição de estresse e como essa condição mental, através do SNA, afeta o sistema cardíaco, usado futuramente para extrair informações que possam estabelecer níveis dessa condição.

Para detalhes mais aprofundados relacionados a fisiologia do sistema nervoso ou do sistema cardiovascular consultar [55].

2.1 Estresse

Estresse é definido como um estado de ameaça a homeostase do corpo pela soma de respostas físicas e mentais causadas por determinados estímulos externos, conhecidos como estressores[11].

Em certo grau, níveis de stress são considerados normais, e até

benéficos para a performance do ser humano, como é apontado em [65]. No entanto, elevados níveis por um período prolongado podem ser bastante prejudiciais.

Pesquisas demonstram que um grande número de pessoas tem experienciado altos níveis de stress ao longo dos últimos anos [45], sendo que esse estado está relacionado a diversas doenças como doenças cardíacas, pressão alta, diabete, infertilidade e principalmente falhas no sistema imunológico.

Um dos principais caminhos ativados no corpo pelos estressores é o do SNA [68]. Em resposta aos estressores, através dos principais hormônios do stress, cortisol, adrenalina e noradrenalina [66], o sistema nervoso simpático tem sua atividade aumentada, enquanto que o sistema nervoso parassimpático reduzida [68].

Por se tratar de uma situação recorrente com alta possibilidade de consequências sérias, é importante conseguir medir níveis de stress, para que o sujeito em questão consiga atuar sobre o estado e tentar reduzir o nível de stress. Métodos tradicionais utilizam avaliações psicológicas através de questionários e entrevistas, incluindo questionários padrões usados em prática clínica e pesquisas psiquiátricas.

Dentre esses questionários padrões está a Escala de Estresse Percebido (PSS - *Perceived Stress Scale*), traduzida para uma escala brasileira em [30], com base na escala original [13]. Outros questionários muito utilizados para avaliar subjetivamente níveis de stress são o *Life Events and Coping Inventory* (LECI) [16] e o *Stress Response Inventory* (SRI) [28].

Outros métodos que não envolvem resposta do sujeito são estudos de comportamentos, por exemplo com o reconhecimento facial, ou análise de respostas bioquímicas de mudanças no sistema imunológico ou endócrino [68].

Mais recentemente métodos mais objetivos que fazem análise de respostas fisiológicas tem surgido como outra alternativa através de hardware que fazem a medição de sinais do corpo e softwares que processam esses sinais, podendo inclusive dar uma resposta de níveis de stress em tempo real [68]. Dentre esses sinais alguns exemplos que podem ser citados são a resposta galvânica da pele, temperatura da pele, eletroencefalograma (EEG), eletromiograma (EMG) e eletrocardiograma (ECG) [68], foco deste trabalho e descrito no capítulo seguinte.

2.2 Sistema Nervoso Autônomo

O sistema nervoso humano pode ser dividido em duas partes, o Sistema Nervoso Central (SNC), composto pelo encéfalo e a medula espinal, e o Sistema Nervoso Periférico (SNP) que consiste nos neurônios aferentes (ou sensoriais) e eferentes. Todo esse sistema é integrado por uma rede de trilhões de células nervosas que se ligam umas as outras através de sinais elétricos e sinais químicos [55]. A Figura 2.1 ilustra bem as divisões mencionadas e como cada uma se ramifica para ao final fechar um ciclo de retroalimentação.

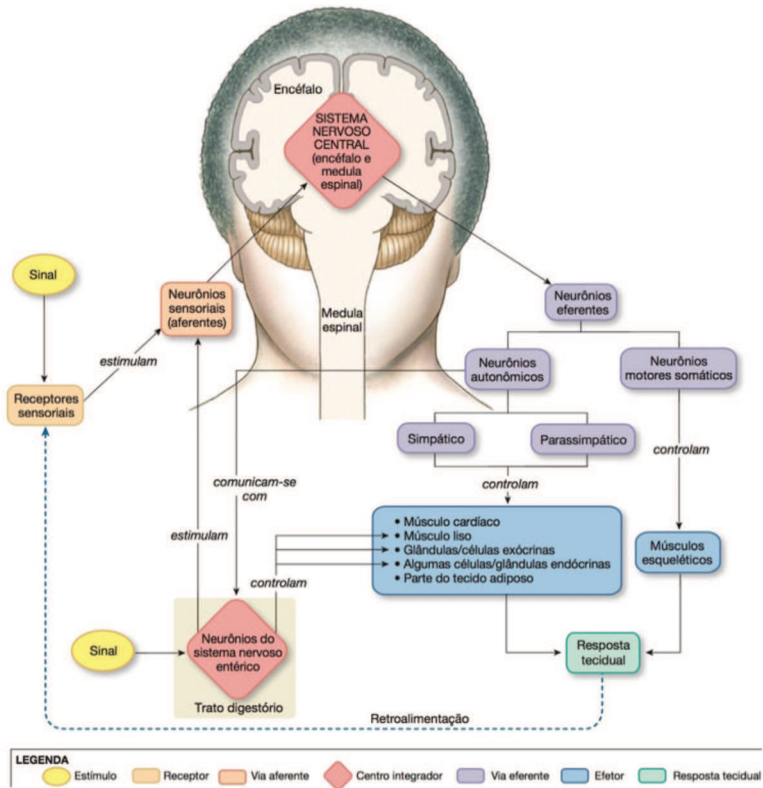


Figura 2.1: **Sistema Nervoso**. As informações fluem do SNC para as células alvo via neurônios eferentes, enquanto que o caminho inverso é via neurônios aferentes, formando um sistema retroalimentado.

Extraído de [55]

O SNC integra as informações provenientes do ramo aferente do SNP e atua através do ramo eferente. Como pode ser observado na Figura 2.1, o ramo eferente do SNP pode ser dividido em neurônios motores somáticos, que controlam músculos esqueléticos, e neurônios autonômicos, que por sua vez controlam os músculos liso e cardíaco, glândulas exócrinas, algumas glândulas endócrinas e alguns tipos de tecido adiposo [55].

Os neurônios autonômicos são subdivididos em simpático e parassimpático, comumente chamados de sistema nervoso simpático e parassimpático. Essas subdivisões possuem atuações antagônicas, onde o parassimpático é responsável por funções relacionadas a descanso e digestão, enquanto que o simpático é responsável por situações de stress, conhecida também como luta-ou-fuga, dilatando vasos de músculos, aumentando o batimento cardíaco e fazendo com que o fígado produza glicose para gerar energia. Ambos esses sistemas antagônicos trabalham em conjunto para manter a homeostase do corpo, monitorando e regulando funções importantes como a pressão sanguínea, temperatura corporal e balanço hídrico [55].

As subdivisões simpática e parassimpática partem de diferentes regiões da medula espinal. A simpática origina-se em maior parte das regiões torácicas e lombar da medula espinal. Já a parassimpática tem como origem o tronco encefálico e a região sacral, tendo como o principal nervo o chamado nervo vago, o qual contém cerca de 75% de todas as fibras parassimpáticas [12, 55]. Devido a importância do nervo vago para a atividade parassimpática, essa atividade também é conhecida como atividade do nervo vagal [12]. A Figura 2.2 ilustra as ramificações mencionadas das subdivisões simpática e parassimpática.

Os sistemas nervoso simpático e parassimpático atuam de forma antagônica na frequência cardíaca. Se não houvesse essa influência, a frequência seria apenas proveniente da despolarização espontânea do nó sinoatrial (SA), descrito na próxima seção, assumindo valores de 90 a 100 vezes por minuto. No entanto, com a atuação do SNA através das subdivisões simpática e parassimpática, essa frequência pode atingir valores fora dessa faixa, aumentando com a atividade simpática e reduzindo com a atividade parassimpática [55].

A divisão autônoma do SNP é de fundamental importância para este trabalho, dada a sua atuação direta sobre o sistema cardíaco, descrito




Figura 2.2: **Ramificações do Sistema Nervoso Autônomo.** Vias autonômicas da resposta simpática em vermelho e da resposta parassimpática em azul. Em amarelo está representado por onde corre a cadeia simpática, que tem sua concentração nas regiões torácica e lombar da medula espinal.

Extraído de [55]

a seguir.

2.3 Sistema Cardiovascular

2.3.1 Fisiologia

O sistema cardiovascular tem como principal função transportar materiais para e de todas as partes do corpo para manter a homeostase. Dentre esses materiais estão nutrientes, água, gases, resíduos eliminados pelas células e materiais que se movem de célula para célula. Em termos simples, esse sistema é composto por vasos sanguíneos cheios de líquido (sangue), bombeado pelo coração, que gera uma pressão que mantém o sangue fluindo pelo corpo continuamente [55].

Os vasos sanguíneos que deixam o coração são chamados de artérias, enquanto que os que chegam ao coração são chamados de veias. Ambos esses vasos e o coração possuem um sistema de válvula que garante que o sangue flua em apenas um sentido[55].

Já dentro do coração, existe uma divisão entre metades esquerda e direita, onde cada uma funciona como uma bomba independente e é constituída em um átrio e um ventrículo. Os átrios recebem sangue que retorna ao coração dos vasos sanguíneos, enquanto que os ventrículos bombeiam o sangue para fora do coração [55]. A Figura 2.3 ilustra o fluxo realizado pelo sistema cardiovascular.




Figura 2.3: **Sistema Cardiovascular.** Fluxo cardiovascular, com o coração como uma bomba central que bombeia sangue para o resto do corpo.

Extraído de [55]

2.3.2 Condução elétrica

A maioria das células musculares cardíacas, que compõe a maior parte do coração, é contrátil [55]. No entanto, aproximadamente 1% dessas células não contribuem para a força contrátil do coração, mas realizam outra tarefa muito importante, geram potenciais de ação espontanea-

mente. Essas células autoexcitáveis são conhecidas como células marcapasso pois determinam a frequência dos batimentos cardíacos [55].

As células autoexcitáveis possuem um potencial de membrana instável, como pode ser observado na Figura 2.4, potencial chamado de potencial marcapasso, atingindo um valor de limiar que dispara um potencial de ação [55].




Figura 2.4: **Potencial das Células Autoexcitáveis.** Essa Figura demonstra o funcionamento das células autoexcitáveis com o seu potencial de marcapasso, que vai aumentando com canais de sódio (Na^+) e cálcio (Ca^{2+}) abertos até atingir um limiar, como pode ser observado. Ao atingir o limiar, é disparado o potencial de ação e mais canais de Ca^{2+} se abrem, aumentando o seu influxo e consequentemente o potencial. Finalmente, ao atingir o pico, os canais de Ca^{2+} se fecham e canais de potássio (K^+) se abrem para repolarizar a célula com a fluxo de K^+ para fora, até iniciar outro ciclo.

Extraído e adaptado de [55]

Diferentemente de células excitáveis, onde o processo de despolarização inicia com a abertura de canais de Na^+ controlados por tensão elétrica, as células autoexcitáveis, ao atingirem o limiar de despolarização abrem canais adicionais de Ca^{2+} , já que alguns já estavam se abrindo para gradualmente chegar ao potencial de limiar [55]. Como pode ser observado na Figura 2.4, ao atingir o pico da despolarização, os canais de Ca^{2+} se fecham e os canais lentos de K^+ se abrem, dando início a fase de repolarização com o efluxo de K^+ , similar a células excitáveis [55].

Para que o coração funcione corretamente, é necessário que diversas células miocárdicas despolarizem e contraiam de forma coordenada para produzir força o suficiente para bombear o sangue [55]. Como pode ser observado na Figura 2.5 esse processo coordenado inicia nas células

autoexcitáveis localizadas no átrio direito, local conhecido como nó SA, propagando-se rapidamente por um sistema de condução constituído de fibras autoexcitáveis não contráteis.




Figura 2.5: **Sistema de Condução Elétrica no Coração.**
Extraído de [55]

Essa condução continua através de uma via internodal que conecta o nó SA ao nó atrioventricular (AV), grupo de células autoexcitáveis localizadas na parte de baixo do átrio direito, como pode ser observado também na Figura 2.5.

A partir do nó AV a despolarização segue para os ventrículos, chegando ao fascículo atrioventricular, localizado no septo entre os ventrículos, ramificando-se entre ramo esquerdo e ramo direito [55]. Cada ramo desloca-se para o ápice do coração, dividindo-se em vários ramos menores chamados de fibras de Purkinje, que se espalham lateralmente entre as células contráteis, que contraem quase que ao mesmo tempo

com a chegada da despolarização propagada desde o nó SA [55].

2.3.3 Ciclo Cardíaco

O processo de contração descrito anteriormente, seguido de relaxamento do coração constitui o ciclo cardíaco, onde contração e relaxamento são chamados de sístole e diástole respectivamente [55].

Iniciando um ciclo logo após a sístole ventricular, período chamado de diástole atrial e ventricular, os átrios enchem-se com sangue das veias, que flui para os ventrículos, à medida que eles relaxam [55].

A seguir, empurrando o restante de sangue dos átrios para os ventrículos, ocorre a sístole atrial que é seguida da sístole ventricular, fase que ocorre no ápice do coração, proveniente da despolarização pelas fibras de Purkinje. Com a sístole ventricular, o sangue é empurrado contra a parte inferior das válvulas atrioventricular (AV), que separam o átrio de ventrículo, fazendo com que elas se fechem, gerando o primeiro som cardíaco [55].

Com a pressão gerada pela contração ventricular e fechamento das válvulas AV, as válvulas semilunares, que separam ventrículos de artérias se abrem permitindo fluxo sanguíneo para as artérias. Paralelamente a esse aumento de pressão ventricular, os átrios relaxam e começam a se encher novamente [55].

Com a repolarização dos ventrículos e sua diástole, a pressão ventricular é reduzida, tornando-se menor do que a pressão arterial. Com essa diferença de pressão, sangue das artérias retorna ao coração, fazendo com que as válvulas semilunares se fechem [55].

Finalmente, a pressão nos ventrículos atinge um nível menor do que nos átrios, fazendo com que as válvulas AV se abram, dando início a um novo ciclo [55].

2.3.4 Influência do Sistema Nervoso Autônomo

Como descrito na seção anterior, os sistemas nervoso simpático e parassimpático atuam de forma antagônica na frequência cardíaca.

A atuação do ramo simpático acontece pelo aumento do fluxo de cátions para dentro da célula através da noradrenalina (de neurônios simpáticos). Esse aumento de fluxo faz com que a célula alcance mais rapidamente o limiar de disparo, aumentando a frequência do potencial

de ação e conseqüentemente a frequência cardíaca [55]. Esse aumento das despolarizações influenciadas pelo ramo simpático pode ser observado na Figura 2.6

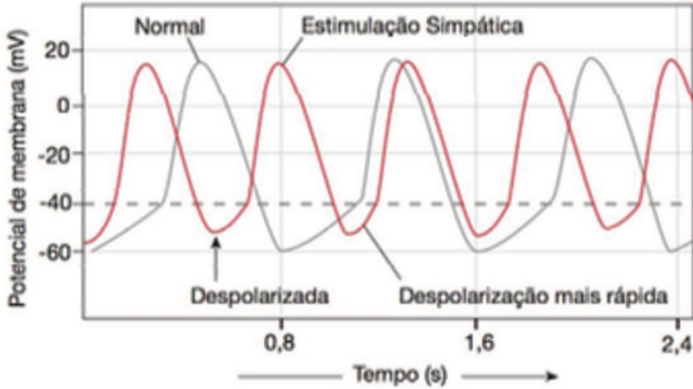


Figura 2.6: **Efeito da Estimulação Simpática na Despolarização.**

Essa Figura compara uma situação de despolarização real, proveniente apenas do marcapasso e uma situação de despolarização estimulada pelo sistema simpático. Com a estimulação do sistema simpático, ocorre o influxo de cátions para a célula, fazendo com que o limiar de disparo seja atingido mais rapidamente e, conseqüentemente, gerando um aumento da frequência cardíaca.

Extraído de [55]

Diferentemente do simpático, o ramo parassimpático atua através do neurotransmissor parassimpático acetilcolina (ACh), reduzindo a frequência cardíaca. Com a atuação da ACh, a permeabilidade a saída do K^+ aumenta, hiperpolarizando a célula e, conseqüentemente fazendo com que o potencial de marcapasso inicie em um valor mais negativo [55], como pode ser observado na Figura 2.7.

Além disso, a ACh influencia na redução da permeabilidade ao Ca^{2+} , fazendo com que a despolarização seja mais lenta, também observado na Figura 2.7, ocasionando em uma frequência cardíaca mais lenta [55].

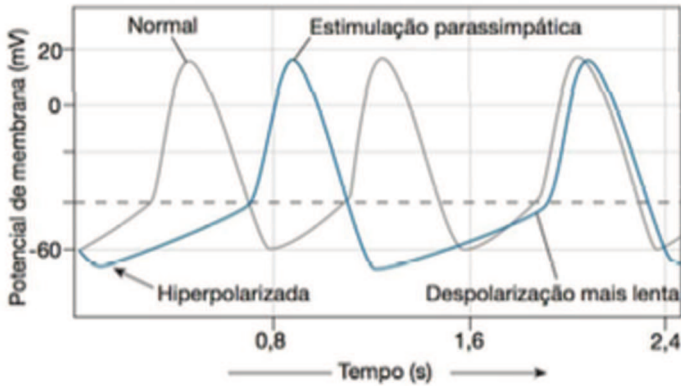


Figura 2.7: **Efeito da Estimulação Parassimpática na Despolarização.** Essa Figura compara uma situação de despolarização real, proveniente apenas do marcapasso e uma situação de despolarização estimulada pelo sistema parassimpático. Com a estimulação do sistema parassimpático, ocorre o efluxo de cátions de K^+ da célula, fazendo com que a célula se hiperpolarize, demorando mais para atingir o limiar de disparo do potencial de ação e, conseqüentemente, gerando uma redução da frequência cardíaca.

Extraído de [55]

2.4 Eletrocardiograma

O sinal de ECG é utilizado atualmente para verificar as condições cardíacas através da condução elétrica que controla o ciclo cardíaco [55].

O uso do ECG na clínica moderna teve seu início nos primeiros anos do século XX com Walter Einthoven, considerado o pai do ECG e que foi responsável pela definição do "triângulo de Einthoven", triângulo ao redor do coração que é usado para estabelecer as derivações utilizadas para a aquisição do sinal de ECG [55]. A Figura 2.8 exemplifica o triângulo citado anteriormente.




Figura 2.8: **Triângulo de Einthoven**. Cada par de eletrodos posicionados na perna esquerda e em um dos braços forma uma derivação. A derivação utilizada neste trabalho é a derivação II, onde a perna esquerda define o potencial positivo e o braço direito o potencial negativo.

Extraído de [55]

O ECG representa a soma extracelular de múltiplos potenciais de ação gerados em diversas células do músculo cardíaco [55]. Como trata-se de um somatório de diversos potenciais, é interessante destacar que a amplitude do potencial de um ECG, aproximadamente 1mV é muito diferente do potencial de ação, de aproximadamente 110mV.

Através do ECG é possível acompanhar o ciclo cardíaco através das ondas e segmentos, componentes característicos desse sinal e que podem ser observados na Figura 2.9 [55], que demonstra um trecho de um sinal de ECG de 1 segundo, com escala de 1mV. Com o ECG é possível realizar diagnósticos na medicina, de forma não invasiva e indolor

As ondas de um sinal de ECG são caracterizadas por deflexões positivas ou negativas e possuem intervalos entre uma e outra chamados de segmentos [55]. As principais ondas observadas em um sinal de ECG são: Onda P, correspondendo à despolarização atrial, seguida do complexo de ondas QRS, que corresponde à despolarização ventricular e incorpora a repolarização atrial e finalmente a onda T, que representa eletricamente a repolarização ventricular, finalizando o ciclo cardíaco [55].

A Figura 2.10 demonstra os eventos elétricos mencionados anterior-




Figura 2.9: **Eletrocardiograma**. Pedaco de um exame de ECG. O eixo horizontal total comporta 1 segundo e o eixo vertical total 1 mV. Extraído de [55]

mente e os seus respectivos impactos no ciclo cardíaco. Pode-se observar também que os segmentos entre as ondas representam os eventos mecânicos, onde a contração atrial tem seu início ao final da onda P e continua no segmento PR e a contração ventricular com seu início após a onda Q, continuando na onda T [55].




Figura 2.10: **ECG no ciclo cardíaco.** Essa Figura demonstra todo o ciclo cardíaco, referenciando ondas do sinal de ECG com respectivos eventos mecânicos e elétricos, dando início do ciclo com a onda P na despolarização atrial e finalizando com a onda T na repolarização ventricular.

Extraído de [55]

Geralmente a análise de ECG para fins médicos utiliza 12 derivações, I, II, III e 9 eletrodos posicionados no peito e tronco, fornecendo informações detalhadas sobre a condução elétrica cardíaca [55]. Nessas análises, algumas perguntas são feitas, tais como qual a frequência cardíaca, medida entre intervalos de início de ondas P ou picos R, ou se todas as ondas P são seguidas de um complexo QRS, cuja ausência indica um bloqueio cardíaco [55].

O foco deste trabalho será na onda R, detectando a sua presença e calculando a variação entre intervalos subsequentes.

2.5 Comentários

Neste capítulo foram abordados aspectos fisiológicos dos sistemas cardiovascular e autônomo, com intuito de deixar clara a influência dos sistemas simpático e parassimpático na frequência cardíaca. Além disso, foi apresentado o sinal de ECG, utilizado neste trabalho para extração de parâmetros de entrada para realizar as inferências de níveis de stress.

Como foi mostrado, o stress afeta o sistema nervoso autônomo, ou seja, influencia de forma indireta na frequência cardíaca.

O próximo capítulo explicará como a variação do ciclo cardíaco pode ser usada como informação do sistema nervoso autônomo, que modula essa variação para finalmente inferir sobre níveis de stress.

Variabilidade Cardíaca

O sinal de variabilidade cardíaca tem sido utilizado em diversas aplicações devido a sua ligação com o sistema nervoso autônomo (SNA) [40, 60, 65].

Para extrai-lo, é necessário partir de um ECG, que é processado para detectar os seus picos, conhecidos como ondas R e finalmente extrair os intervalos temporais entre esses picos, gerando um novo sinal conhecido como variabilidade cardíaca. A partir dessa nova série temporal, é possível extrair diversos parâmetros. Esses parâmetros podem ser de natureza temporal, frequencial ou até mesmo não-lineares.

Neste capítulo, é descrita a metodologia utilizada para construir o sinal de HRV, para finalmente descrever os parâmetros temporais, frequenciais e não-lineares extraídos desse sinal.

3.1 Construção do sinal de Variabilidade, Detecção, Extração

Existem diversos métodos validados para realizar a detecção de picos das ondas R de ECG [15, 23, 31, 50]. No entanto, a grande maioria segue um padrão de fluxo, iniciando-se com a etapa de filtragem do

sinal na banda da onda R, seguido de limiares em sinais transformados a partir do sinal de ECG, para finalmente realizar a localização do pico exato dentro da janela detectada acima do limiar. A banda de interesse para detecção da onda R é tipicamente na faixa de 10 a 25 Hz [31, 39].

O trabalho [39] foi usado como base para a implementação do algoritmo de detecção da onda R utilizado neste trabalho. O trabalho mencionado foi usado como base pois nele foram obtidos resultados de acurácia de 99,94%, validado na base de dados aberta descrita em [35].

Em [39] é utilizada a transformada Wavelet Discreta através da decomposição do sinal em escalas, para reconstruí-lo apenas com as faixas de frequência de interesse para a detecção. Neste trabalho, diferentemente de [39], foi utilizada a Transformada Wavelet Contínua como um filtro para limitar o sinal na banda de interesse e obter o formato desejado para realizar a detecção através de um limiar adaptativo.

3.1.1 Detecção com Transformada Wavelet

A Transformada Wavelet é um método matemático desenvolvido em 1984 por Grossmann e Morlet, inicialmente proposto para melhorar a análise de sinais sísmicos, substituindo a transformada de Fourier de janela (STFT) e obtendo melhores algoritmos para detectar e analisar mudanças bruscas em sinais. Essa ferramenta tem sido utilizada recentemente em diversas áreas, como uma forma de solucionar difíceis problemas em matemática, física e engenharia. Aplicações desse método podem ser citadas nas mais variadas áreas, desde propagação de ondas, compressão de dados, processamento de sinais e imagens, reconhecimento de padrões, computação gráfica, detecção de aeronaves e submarinos até mesmo na área médica [53].

Também chamada de análise tempo-escala, a transformada Wavelet fornece uma boa localização de descontinuidades, presentes em sinais não-estacionários. Pode-se dizer que ela proporciona diferentes níveis de resolução, como por exemplo, um observador em um avião necessitaria de baixa resolução para caracterizar prédios, no entanto para caracterizar veículos seria necessária alta resolução [3].

A transformada Wavelet contínua de uma função $f(t)$ é definida pela Equação 3.1, onde $*$ representa a operação de complexo conjugado, a representa o parâmetro de escalonamento e b representa o parâmetro de translação. A função $\psi_{a,b}(t)$ é gerada a partir de uma função protótipo

$\psi(t) \in L_2(\mathbb{R})$, também chamada de wavelet-mãe. Trata-se de uma versão escalonada e transladada por a e b respectivamente.

$$CWT_f(a, b) = \int_{-\infty}^{\infty} \psi_{a,b}^*(t) f(t) dt = \langle \psi_{a,b}(t), f(t) \rangle \quad (3.1)$$

Essas operações na wavelet-mãe que geram as wavelets filhas são definidas pela Equação 3.2, para $a, b \in \mathbb{R}^+$.

$$\psi(a, b) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (3.2)$$

É importante salientar que para valores grandes de a , a wavelet-mãe gera versões esticadas, vantajosas para analisar componentes de baixa frequência. Já para valores pequenos de a , versões comprimidas são geradas, fazendo com que componentes de alta frequência sejam melhores analisadas.

Ao selecionar uma wavelet-mãe com um formato específico, combinado a um valor de escala próximo da escala da onda de interesse no sinal, é possível realizar a detecção do pico de uma forma mais fácil através do cruzamento do sinal transformado por zero. Em [39] foi utilizada a primeira derivada da função gaussiana, dada pela Equação 3.3, característica mantida neste trabalho e que pode ser observada na Figura 3.1.

$$G'_a = \frac{-2x}{a} \left(\frac{2}{\pi}\right)^{1/4} e^{\left(\frac{-x}{a}\right)^2} \quad (3.3)$$




Figura 3.1: **Wavelet Mãe Primeira Derivada Da Gaussiana.** Função usada como Wavelet Mãe neste trabalho em diferentes escalas a . Para valores maiores de a , a função resulta em uma versão mais esticada, ideal para frequências mais baixas.

Extraído de [39]

Após aplicar a transformada ao sinal de ECG com a função wavelet e escala escolhidas, é extraída a derivada do sinal transformado, elevada ao quadrado e, finalmente, extraída a média móvel para resultar no sinal utilizado como limiar de detecção.

Para realizar a detecção é escolhido um limiar inicial, baseado no começo do sinal. Quando um valor acima do limiar é encontrado, procura-se pelo cruzamento com zero da convolução do sinal original com a derivada da gaussiana e finalmente encontra-se o pico exato no sinal original.

Esses três sinais mencionados, original, após convolução e sinal de limiar, média móvel da derivada da convolução ao quadrado, podem ser observados na Figura 3.2.

É interessante observar na Figura 3.2 como o sinal verde se destaca das demais regiões quando está perto da onda R, por isso da sua utilização na detecção.




Figura 3.2: **Sinais para Detecção da onda R.** Em azul pode-se observar o sinal original após a filtragem tradicional na banda de 10 a 25 Hz. O sinal em vermelho representa a convolução do sinal em azul com a Wavelet escolhida, segunda derivada da Gaussiana. Já em verde, está representado o sinal utilizado como limiar de detecção, podendo-se observar o seu destaque para as demais regiões da janela.

3.1.2 Extração do sinal de HRV a partir da detecção

A partir da detecção apresentada anteriormente, é extraído o intervalo temporal entre a ocorrência de duas ondas R consecutivas. Cada ponto gerado para a série temporal de HRV em milissegundos é obtido a partir da expressão definida pela Equação 3.4, onde R é um vetor de amostras onde ocorrem as ondas R e f_s é a frequência de amostragem.

$$VFC(i) = \frac{(R(i) - R(i - 1))}{f_s} \cdot 1000 \quad (3.4)$$

3.2 Parâmetros de Variabilidade Cardíaca

A partir do sinal de HRV podem ser extraídos diversos parâmetros. Nesta seção serão detalhados os parâmetros de HRV utilizados neste trabalho, os quais podem ser divididos em parâmetros temporais, frequenciais e não-lineares.

3.2.1 Parâmetros Temporais

Os parâmetros temporais apesar de simples são utilizados em praticamente todas as aplicações envolvendo análises de variabilidade cardíaca [36, 63, 70].

3.2.1.1 Parâmetros Temporais Estatísticos

SDNN (*ms*) Desvio Padrão dos Intervalos Normais de RR - Também conhecido como SDRR, é o desvio padrão dos intervalos normais de RR. A Equação 3.5 apresenta o cálculo desse parâmetro [36, 69, 70].

$$SDNN = \sqrt{\frac{1}{N-1} \sum_{n=2}^N [VFC(n) - \overline{VFC}]^2}, \quad (3.5)$$

onde \overline{VFC} é a média da série temporal de glshrv.

RMSSD (*ms*) Raiz Quadrada da Média da Soma do Quadrado das Diferenças Sucessivas dos Intervalos Normais de RR - Representado pela equação 3.6, é a raiz quadrada da média da soma do quadrado das diferenças sucessivas dos intervalos normais RR. [36, 57, 63].

$$RMSSD = \sqrt{\frac{1}{N-2} \sum_{n=3}^N [VFC(n) - VFC(n-1)]^2} \quad (3.6)$$

pNN50 (%) Porcentagem de Intervalos Normais de RR Normais Sucessivos Superiores a 50 milissegundos - Definido como a relação entre o número de intervalos normais sucessivos superiores a 50 milissegundos e o número total de intervalos. Apesar do padrão mais conhecido ser 50*ms*, é possível trabalhar com valores diferentes de até 100*ms* [33].

3.2.2 Parâmetros Freqüenciais

Existem três divisões de bandas de frequências para a análise de sinais de HRV. Essas divisões representam as atividades simpática e parasimpática e estão na faixa de até $0,4Hz$ [10, 12, 29].

A Figura 3.3 demonstra a Densidade Espectral de Potência de um sinal de HRV, onde podem ser observadas as três divisões principais de Muito Baixa Frequência (VLF) ($0.003 - 0.04Hz$), de Baixa Frequência (LF) ($0.04 - 0.15Hz$) e de de Alta Frequência (HF) ($0.15 - 0.4Hz$) e uma faixa menos usada de Ultra Baixa Frequência (ULF) ($0 - 0.003Hz$)

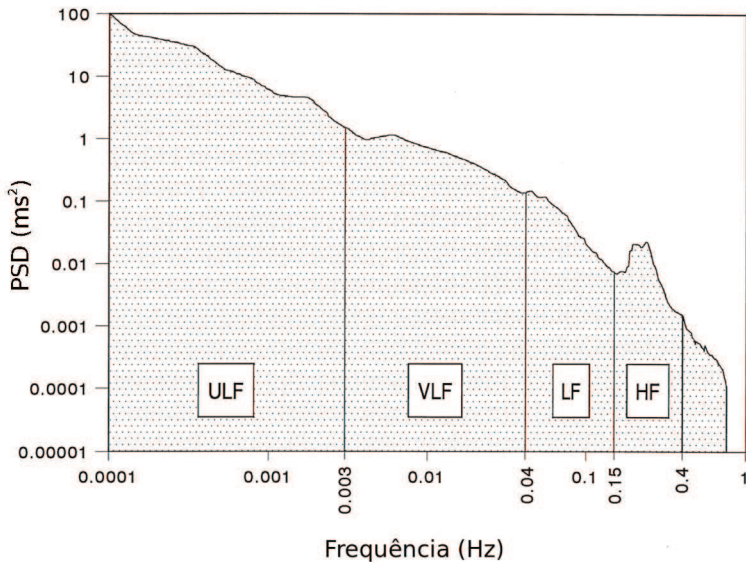


Figura 3.3: PSD das principais frequências do sinal de HRV - Pode-se observar as divisões de faixas de frequência de um sinal de HRV: De $0 - 0.003Hz$ para ULF, $0.003 - 0.04Hz$ para VLF, de $0.04 - 0.15Hz$ para LF e de $0.15 - 0.4Hz$ HF

Extraído de [47]

Para realizar as análises de sinais de HRV, os parâmetros freqüenciais mais utilizados são [10, 12, 29]:

VLF (ms^2) - Banda relacionada a regulações de longa duração como o sistema de termorregulação, renina-angiotensina e outros fatores

hormonais [10, 12, 29].

LF (ms^2) - Relacionada principalmente à atividade simpática, mas podendo também ser relacionada a reflexos da atividade parassimpática. [10, 29, 43]. Alguns autores relacionam essa faixa de frequência como sendo exclusivamente de atividade simpática [12].

HF (ms^2) - Relacionada pela comunidade científica a reflexos da atividade parassimpática [10, 12, 29].

Índice Simpatovagal (SVI) - Dado pela razão da PSD total da banda de LF pela PSD total da banda de HF. Esse índice é relacionado ao balanço entre as vias simpática e vagal, por isso do seu nome [10, 12, 29]. Esse parâmetro reflete a modulação da função de três das principais estruturas do sistema cardiovascular: nó sinusal (frequência cardíaca), ventrículos (volumes sistólico e diastólico finais) e vasos sanguíneos, incluindo a microcirculação (resistência periférica total) [12].

3.2.3 Parâmetros Não-lineares

Sendo proveniente de diversos sistemas não-lineares, trabalhos afirmam que o sinal de HRV possui uma natureza não-linear [60, 62]. Por essa razão, faz sentido utilizar ferramentas não-lineares para realizar análises de sinais de HRV.

As principais ferramentas não-lineares usadas em análises de HRV e também utilizadas neste trabalho são brevemente descritas a seguir.

3.2.3.1 Gráfico de Poincaré

A partir de uma série temporal de HRV, é plotado cada ponto de intervalo $VFC(n)$ sobre o ponto de intervalo anterior $VFC(n-1)$. Esse gráfico resultante é chamado de Gráfico de Poincaré, que pode ser observado na Figura 3.4, construído a partir de um instante onde o sujeito estava sob condição de alto estresse, e de onde é possível extrair algumas informações da atuação do sistema nervoso autônomo [42, 60].

Essas informações podem ser extraídas a partir do comprimento do eixo transversal (T) que reflete a variabilidade dos batimentos relacionados a predominância do sistema parassimpático. Além disso, pode-se




Figura 3.4: **Gráfico de Poincaré** - Representando um estado de alto estresse, cada ponto n no gráfico é o ponto do intervalo $VFC(n)$ sobre o ponto do intervalo anterior $VFC(n - 1)$.

inferir influências de ambos os sistemas simpático e parassimpático a partir do comprimento do eixo longitudinal.

Dois índices que podem ser extraídos do gráfico de Poincaré e que tem sido bastante utilizados para análise de HRV para diversas patologias [42, 43, 60] são: Índice Cardiovagal (CVI), definido pela Equação 3.7 e o Índice Cardiosimpático (CSI), definido pela Equação 3.8, onde L e T são os eixos longitudinal e transversal do gráfico conforme descrito anteriormente, respectivamente.

$$CVI = \log[LT] \quad (3.7)$$

$$CSI = \frac{L}{T} \quad (3.8)$$

A partir da equação 3.7, é possível inferir que o índice CVI, reflete a atividade de ambos os sistemas simpático e parassimpático, com uma predominância do sistema parassimpático, justificando o seu nome, Índice Cardiovagal.

Já na equação 3.8, observa-se que, como L reflete a atividade de ambos os sistemas e T com uma predominância do sistema parassimpático, o índice CSI tem uma predominância do sistema simpático.

3.2.3.2 Maior Expoente de Lyapunov

O expoente de Lyapunov(λ) é uma medida quantitativa de previsibilidade do sinal. Através desse expoente é possível distinguir entre dinâmica caótica e previsibilidade [46].

Um expoente de Lyapunov negativo implica em que as órbitas tendem para um ponto fixo comum, quanto mais negativo o expoente, mais estável é o sistema e mais rápido ele volta para o ponto fixo comum. Um expoente igual a zero indica que as órbitas mantêm suas posições relativas. Finalmente, um expoente de valor maior do que zero indica que as órbitas estão sobre um atrator caótico. Em casos de bloqueio congênito ou isquemia, o valor do expoente é menor do que corações saudáveis [1, 2].

Em geral, é utilizado o maior expoente de Lyapunov, que quantifica a sensibilidade do sistema e previsibilidade. Em [49] é apresentado um método robusto e rápido de calcular o maior expoente de Lyapunov, algoritmo implementado em uma biblioteca aberta (*nolds*) utilizada neste trabalho.

3.2.3.3 Dimensão Fractal de Higuchi

Fractal é um conjunto de pontos que quando olhados em escalas menores se assemelham. O termo Dimensão Fractal (DF) se refere a dimensão não inteira ou fracionada de um objeto geométrico, fornecendo uma medida de quanto espaço um objeto ocupa entre dimensões euclidianas [46].

A DF pode ser estimada através de diversos algoritmos e tem sido usada como uma ferramenta para analisar sinais de ECG e de EEG

devido a sua robustez na detecção de transientes [46].

Um desses algoritmos é o de Higuchi [25], que tem sido utilizado para estimar a DF para séries temporais não-periódicas e irregulares. Esse algoritmo constrói k novas séries a partir da série original $X = [x_1, x_2, \dots, x_N]$ por

$$x_m, x_{m+k}, x_{m+2k}, \dots, x_{m+\lfloor \frac{(N-m)}{k} \rfloor k}, \quad (3.9)$$

onde $m = 1, 2, \dots, k$ e o operador $\lfloor \frac{(N-m)}{k} \rfloor$ indica a parte inteira de $\frac{(N-m)}{k}$.

Para cada série temporal construída a partir da Equação 3.9, o comprimento $L(m, k)$ é computado por

$$L(m, k) = \frac{\sum_{i=2}^{\lfloor \frac{N-m}{k} \rfloor} |x_{m+ik} - x_{m+(i-1)k}| (N-1)}{\lfloor \frac{(N-m)}{k} \rfloor k} \quad (3.10)$$

O comprimento médio é calculado como

$$L(k) = \frac{\sum_{i=1}^k L(i, k)}{k}. \quad (3.11)$$

Esse procedimento repete k_{max} vezes para cada k a partir de 1 até k_{max} , e então utiliza o método dos mínimos quadrados para determinar a inclinação da linha que melhor se adapta a curva $\frac{\ln(L(k))}{\ln(L(1/k))}$. O valor da inclinação é a Dimensão Fractal de Higuchi (DFH).

Poucos trabalhos utilizaram DFH em análises de variabilidade, no entanto, em [59] é demonstrado que DFH aumenta através de uma respiração controlada, demonstrando também uma relação direta com o sistema parassimpático.

3.2.3.4 Parâmetros de Hjorth

Os parâmetro de Hjorth são maneiras de indicar a propriedade estatística de um sinal no domínio do tempo. Os principais tipos desses parâmetros são a mobilidade e a complexidade.

A mobilidade é proporcional ao desvio padrão do espectro de potência do sinal e representa uma estimativa da frequência média. Já a complexidade entrega uma estimativa da banda do sinal, indicando a similaridade com uma onda senoidal pura [26].

Dado uma série temporal $X = [x_1, x_2, \dots, x_N]$, a mobilidade (MH) e a complexidade de Hjorth (CH), são definidas pelas Equações 3.12 e 3.13 respectivamente [26],

$$MH = \sqrt{\frac{M2}{TP}} \quad (3.12)$$

e

$$CH = \sqrt{\frac{M4 \times TP}{M2^2}}, \quad (3.13)$$

onde

$$TP = \sum_{i=1}^N \frac{x_i}{N}, \quad (3.14)$$

$$M2 = \sum_{i=1}^N \frac{d_i}{N}, \quad (3.15)$$

$$M4 = \sum_{i=1}^N \frac{(d_i - d_{i-1})^2}{N} \quad (3.16)$$

e

$$d_i = x_i - x_{i-1}. \quad (3.17)$$

3.2.3.5 Entropia Amostral

O cálculo da Entropia Amostral (SampEn) quantifica complexidade e regularidade de séries temporais, portanto é facilmente aplicado para séries temporais biológicas [46, 48]. Quanto maior o valor da SampEn, maior complexidade ou irregularidade do sinal.

A seguir são descritos os passos para o cálculo da SampEn:

(i) Seja uma série temporal como $X = [x_1, x_2, \dots, x_N]$;

(ii) Construir subsequências

$$x(i, m) = [x_i, x_{i+1}, \dots, x_{i+m-1}] \quad (3.18)$$

para $1 \leq i \leq N - m$, onde i define o início da subsequência e m o comprimento.

(iii) Seja r representando o nível do filtro de ruído, definido como

$$r = k \times \sigma \quad (3.19)$$

para $k = 0, 0.1, 0.2, \dots, 0.9$ e σ o desvio padrão da subsequência.

(iv) Construir um conjunto de subsequências

$$x(j, m) = x(j, m) | j \in [1, \dots, N - m], \quad (3.20)$$

onde $x(j, m)$ é definido na etapa 2.

(v) Para todo $i \neq j$, calcular

$$C^a(i, m) = \frac{\sum_{j=1}^{N-m} k_j}{N - m} \quad (3.21)$$

e

$$C^b(i, m - 1) = \frac{\sum_{j=1}^{N-m-1} k_j}{N - m - 1}, \quad (3.22)$$

onde

$$k_j = \begin{cases} 1 & \text{se } |x(i, m) - x(j, m)| < r \\ 0 & \text{caso contrário.} \end{cases} \quad (3.23)$$

(vi) Calcular SampEn como:

$$SampEn(m, r, N) = -\ln \frac{C^a(i, m)}{C^b(i, m - 1)}. \quad (3.24)$$

3.3 Comentários

Com essas análises de sinais de HRV em mãos, alguns trabalhos já as utilizam como entrada. No entanto, neste trabalho será utilizada também a informação de evolução temporal dessas análises, sendo necessário um tratamento para condensá-las em vetores de entrada para algoritmos de aprendizado de máquina, descritos no capítulo 4.

No capítulo 5 será abordada a metodologia utilizada para condensar essas análises em vetores de entrada para os algoritmos de aprendizado de máquina descritos no capítulo seguinte.

Algoritmos de Classificação

Atualmente, diversas tarefas dentro da medicina utilizam algoritmos de classificação para aprender padrões e usá-los como biomarcadores de estados[37, 44]. Esses estados podem estar relacionados a doenças como: chance de ocorrer uma crise epiléptica, chance de ocorrer um infarto, anomalias cardíacas ou até mesmo níveis de stress, aplicação deste trabalho.

Neste trabalho foram utilizadas duas estratégias de classificação: SVM com kernel gaussiano e classificação em matrizes de covariância usando métricas de Riemann.

4.1 Máquinas de Vetores Suporte (SVM)

O algoritmo de SVM foi escolhido por se tratar de um classificador vastamente utilizado em aplicações semelhantes, robusto perante parâmetros de entrada com separação não-linear e com garantia de atingir uma solução ótima por se tratar de um problema de otimização convexo[21, 37, 64].

As Máquinas de Vetores resolvem o problema de classificação resolvendo uma otimização convexa de forma a achar o melhor hiperplano

que separa as classes de interesse, maximizando a margem do limite de decisão entre elas [9, 52]. A Figura 4.1 ilustra um exemplo onde duas classes são separadas por uma reta, maximizando a margem entre elas.




Figura 4.1: Separação por hiperplano

Para entender o funcionamento básico desse classificador para os capítulos seguintes é feita uma breve explicação teórica baseada em [9, 52]. Inicialmente é definido um problema ideal onde duas classes são separadas linearmente por uma máquina de vetor suporte com margens rígidas, como pode ser observado na Figura 4.1. A seguir, é definida uma margem suave com a introdução de variáveis de folga para casos reais onde estão presentes *outliers*, como pode ser observado na Figura 4.2. Finalmente, é introduzido o conceito de Kernel para problemas onde a separação não é linear.

4.1.1 SVMs com Margens Rígidas

SVM com margens rígidas estabelecem hiperplanos que conseguem separar dados linearmente separáveis [9, 52]. Um exemplo desse caso pode ser observado na Figura 4.1.




Figura 4.2: Separação por hiperplano com *outlier*

Considere um conjunto de treinamento contendo N vetores \mathbf{x}_n , onde $\mathbf{x}_n \in \mathcal{X}$ de entrada com respectivos *labels* $t_n \in \{-1, 1\}$, \mathcal{X} o espaço vetorial padrão de entrada que pode ser mapeado para o espaço vetorial de características \mathcal{H} .

Para um problema de separação linear no espaço de características entre duas classes, pode-se definir o modelo de separação com a Equação 4.1, onde $\phi(\mathbf{x})$ é a transformação do espaço vetorial padrão de entrada \mathcal{X} para o espaço vetorial de características \mathcal{H} , $\mathbf{w} \in \mathcal{X}$ o vetor normal ao hiperplano de separação e $b \in \mathcal{R}$.

$$y(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b \quad (4.1)$$

Novos pontos \mathbf{x} são classificados de acordo com o sinal de $y(\mathbf{x})$. Como o conjunto de dados é linearmente separável no espaço de características, existe pelo menos um conjunto de parâmetros \mathbf{w} e b que faz com que a Equação 4.1 satisfaça as condições: $y(\mathbf{x}_n) > 0$ para pontos com *labels* $t_n = +1$ e $y(\mathbf{x}_n) < 0$ para pontos com $t_n = -1$, resultando em $t_n y(\mathbf{x}_n) > 0$ para qualquer ponto do conjunto de treinamento.

Para achar a melhor solução que respeite às condições impostas anteriormente, a máquina de vetor suporte procura pela solução que maximiza a margem, definida pela menor distância entre o hiperplano que separa as classes e qualquer ponto do conjunto de treinamento, como pode ser observado na Figura 4.1.

A distância perpendicular entre um ponto \mathbf{x} e o hiperplano definido por $y(\mathbf{x}) = 0$, onde $y(\mathbf{x})$ é dado pela Equação 4.2, é dada por $|y(\mathbf{x})|/\|\mathbf{w}\|[9]$. Com isso, pode-se escrever essa distância da seguinte forma:

$$\frac{t_n y(\mathbf{x}_n)}{\|\mathbf{w}\|} = \frac{t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b)}{\|\mathbf{w}\|} \quad (4.2)$$

Como a margem foi definida pela distância entre o hiperplano de separação e o ponto \mathbf{x}_n e o objetivo é maximizar a margem em função de \mathbf{w} e b , a solução para a margem é encontrada resolvendo

$$\arg \max_{\mathbf{w}, b} \left\{ \frac{1}{\|\mathbf{w}\|} \min_n [t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b)] \right\} \quad (4.3)$$

Considere a representação canônica do hiperplano de separação, onde a condição da equação é respeitada para os pontos mais próximos ao hiperplano

$$t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b) = 1 \quad (4.4)$$

Com essa simplificação e observando que maximizar $\|\mathbf{w}\|^{-1}$ é equivalente a minimizar $\|\mathbf{w}\|^2$, é possível escrever o problema de otimização como:

$$\arg \min_{\mathbf{w}, b} \left\| \frac{1}{2} \mathbf{w} \right\|^2 \quad (4.5)$$

sujeito às condições dadas pela Equação 4.6 impostas pela forma canônica e que restringem qualquer ponto de estar entre as margens de separação, o que define o nome margens rígidas.

$$t_n (\mathbf{w}^T \phi(\mathbf{x}_n) + b) \geq 1, \quad n = 1, \dots, N \quad (4.6)$$

4.1.2 SVMs com Margens Suaves

Para casos reais o conjunto de dados não necessariamente vai ser linearmente separável no espaço de características definido anteriormente, devido a diversos fatores, dentre eles ruídos e *outliers*. Utilizando margens rígidas pode levar para uma generalização de baixa qualidade, podendo gerar o que se chama de *overfitting*[9].

Com o intuito de resolver essa limitação, são introduzidas variáveis de penalidade para pontos do lado "errado" da margem de decisão. Essas variáveis são chamadas de variáveis de folga e são função linear da distância para a margem de decisão, definidas como $\xi_n = 0$ para pontos dentro da margem correta e $\xi_n = \|t_n - y(\mathbf{x}_n)\|$ para os demais pontos[9, 52].

As restrições de otimização definidas anteriormente pela Equação 4.6 e impostas pela forma canônica agora assumem o formato da Equação 4.7, onde as variáveis de folga possuem a restrição $\xi \geq 0$.

$$C \sum_{n=1}^N \xi_n + \frac{1}{2} \|\mathbf{w}\|^2 \quad (4.7)$$

O problema de otimização agora é modificado para suavizar a margem e permitir pontos do lado "errado" do hiperplano de decisão e é definido de acordo com a Equação 4.8, respeitando as condições impostas pela Equação 4.6[9, 52]. Ainda em relação ao novo problema de otimização dado pela Equação 4.8, o parâmetro $C > 0$ define o *trade-off* entre a variável de penalidade e a margem, servindo como um coeficiente de regularização. Quanto maior o valor do parâmetro de regularização C mais a curva tentará se adaptar a respeitar todos os pontos do conjunto de treinamento.

$$\arg \min_{\mathbf{w}, b, \xi} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{n=1}^N \xi_n \quad (4.8)$$

4.1.3 SVMs Não-Lineares

Apesar de funcionar muito bem para conjuntos de dados com separação linear, mesmo na presença de ruídos e *outliers* através das margens suaves, existem casos onde as SVM não são capazes de gerar um hiperplano que separe satisfatoriamente o conjunto de dados.

Para resolver essa limitação, o conjunto de dados é mapeado do espaço de entrada \mathcal{X} para o espaço vetorial de características \mathcal{H} através da transformação $\phi(\mathbf{x})$, que na maioria dos casos é não-linear. Esse espaço de características geralmente possui uma dimensão maior do que a de entrada e pode separar dados utilizando SVM que antes não eram linearmente separáveis[9, 52].

A Figura 4.3 demonstra um exemplo onde o conjunto de entrada não é linearmente separável, mas ao aplicar uma transformação para o espaço de características essa separação é facilmente realizada.




Figura 4.3: Espaços transformados

Esse mapeamento é realizado pela introdução dos *kernels*, que é a medida de distância entre dois vetores no espaço de características. Como na Equação 4.1 o problema de separação foi definido já no espaço de características, para a introdução da não-linearidade ao problema basta apenas introduzir a função do *kernel* escolhido como $\phi(\mathbf{x})$ para mapear o vetor de entrada para o espaço de características [9, 52].

Uma abordagem não otimizada para realizar o mapeamento do conjunto de entrada para o espaço de características, apenas por questão de intuição, é considerar que cada amostra de entrada de treinamento define um ponto no espaço de entrada, chamado de *landmark*. Para cada iteração na etapa de otimização referente a uma amostra é calculada a distância dessa amostra para cada *landmark* através do *kernel*, onde cada distância define uma dimensão no novo espaço de características utilizado para a otimização no lugar do vetor de entrada.

A Tabela 4.1 exemplifica os *kernels* mais utilizados na prática, os Polinomiais, os Gaussianos ou RBF (*Radial-Basis Function*) e os Sig-moidais. Cada um deles apresenta parâmetros que devem ser determinados ao serem utilizados, indicados também na tabela. É importante

ressaltar que para ser considerado uma função *kernel* existem algumas restrições que são detalhadas em [56].

Tabela 4.1: Funções Kernel mais comuns.

Tipo de Kernel	Função $K(x, y)$	Parâmetros
Polinomial	$(\delta(x^T y) + \kappa)^d$	δ, κ, d
Gaussiano ou RBF	$\exp(-\sigma \ x - y\ ^2)$	σ
Sigmoidal	$\tanh(\delta(x^T y) + \kappa)$	δ, κ

Neste trabalho foi utilizado o *kernel* de base radial, por isso, é interessante notar algumas características do parâmetro σ . Para valores grandes de σ a amplitude da gaussiana varia mais suavemente. Lembrando que o *kernel* é usado como uma medida de similaridade entre dois vetores, para valores muito pequenos de σ essa similaridade decai bruscamente, podendo fazer por exemplo com que o classificador fique muito específico para um determinado conjunto de dados[9].

4.1.4 Comentários

Ambos os problemas de otimizações definidos anteriormente são resolvidos através de multiplicadores de Lagrange, para mais detalhes consultar[9].

Para um problema onde existem mais de duas classes, existem algumas abordagens diferentes, como, por exemplo, treinar um modelo para cada classe considerando as remanescentes como uma classe apenas, também conhecido como uma-versus-demais (*one-versus-the-rest*)[9].

Para este trabalho, foi utilizada a estratégia de uma-versus-uma (*one-versus-one*), onde são treinados modelos para todos os possíveis pares de classes e a classificação é baseada na votação de todos os modelos[9].

Para implementação foi utilizada uma biblioteca de software aberto [41] que aplica otimizações numéricas não mencionadas neste trabalho.

4.2 Geometria de Riemann e Matrizes de Covariância

Métricas de Riemann tem sido utilizadas em sinais de EEG para classificação de atividades motoras e remoção de artefatos com bastante sucesso, explorando a relação temporal entre os diversos canais[5, 8, 14].

No caso do ECG, por se tratar de apenas uma derivação (D2), não é possível aplicar essa ferramenta diretamente ao sinal extraído. No entanto, com o sinal de HRV trabalhado de uma forma correta, é possível a utilização dessas métricas em matrizes de covariância estimadas.

No capítulo 5 é demonstrado detalhadamente como é feita a estimação da matriz de covariância desde um sinal de ECG contaminado por ruído até como as métricas de Riemann são utilizadas para classificação dessas matrizes.

Neste capítulo, é interessante notar que a matriz usada para gerar a matriz de covariância é uma matriz onde as linhas representam parâmetros de HRV e as colunas evoluem temporalmente com um passo fixo em segundos.

Essa abordagem de classificação foi escolhida para ser usada neste trabalho pelo fato de que matrizes de covariância exploram a evolução temporal da relação entre os canais da matriz usada para construir a matriz de covariância, além de estar mostrando resultados promissores em sinais bioelétricos.

Para entender como essas métricas são aplicadas em matrizes de covariância, é necessário fazer uma breve fundamentação teórica sobre o assunto, usando como base as notações e definições do trabalho [7].

4.2.1 Símbolos

4.2.2 Matrizes de Covariância

Matrizes de covariância são importantes descritores que indicam a dispersão de uma distribuição de pontos. A matriz de covariância Σ de \mathbf{X} é definida pela Equação 4.9, onde M é o valor esperado ou médio de \mathbf{X} , T o operador de transposição e $E(\cdot)$ o operador de média [18].

$$\Sigma = E \{ (\mathbf{X} - M)(\mathbf{X} - M)^T \} \quad (4.9)$$

A diagonal principal de Σ tem como seus componentes as variâncias individuais da matriz \mathbf{X} , já os demais componentes representam as covariâncias entre as variáveis de Σ . É interessante notar que Σ é simétrica em relação a sua diagonal principal, permitindo uma facilitação nas operações proporcionadas pelas propriedades dessas matrizes.

4.2.3 Notações e Definições

O espaço de todas as matrizes simétricas $n \times n$ dentro do espaço de matrizes quadradas $M(n)$ pode ser definido como $S(n) = \{\mathbf{S} \in M(n), \mathbf{S}^T = \mathbf{S}\}$ e o conjunto de matrizes $n \times n$ simétricas, positivas e definidas (SPD) como $P(n) = \{\mathbf{P} \in S(n), \mathbf{u}^T \mathbf{P} \mathbf{u} > 0, \forall \mathbf{u} \in \mathbb{R}^n\}$, onde \mathbf{u} é um vetor coluna não-nulo de n números reais. Além disso, é importante ressaltar que toda matriz SPD é diagonalizável com autovalores estritamente reais e positivos [7].

Outra definição importante é a norma de Frobenius de uma matriz \mathbf{A} , dada pela Equação 4.10, onde $Tr(\cdot)$ é o operador conhecido como traço. Para um vetor a , a norma em \mathbb{L}_2 é escrita como $\|a\|_2$ [7].

$$\|\mathbf{A}\|_F^2 = Tr(\mathbf{A}\mathbf{A}^T) = \sum |A_{ii}|^2 \quad (4.10)$$

Para matrizes SPD dentro de $P(n)$, as operações de exponencial e logaritmo, são obtidas através da decomposição de autovalores de \mathbf{P} , como pode ser observado na Equação 4.11.

$$\mathbf{P} = \mathbf{U}diag(\sigma_1, \dots, \sigma_n)\mathbf{U}^T \quad (4.11)$$

onde $\sigma_1 > \sigma_2 > \dots > \sigma_n > 0$ são os autovalores de \mathbf{P} e \mathbf{U} a matriz de autovetores de \mathbf{P} [7].

Portanto, pode-se escrever as operações de exponencial e logaritmo como [7]:

$$exp(\mathbf{P}) = \mathbf{U}diag(exp(\sigma_1), \dots, exp(\sigma_n))\mathbf{U}^T \quad (4.12)$$

$$log(\mathbf{P}) = \mathbf{U}diag(log(\sigma_1), \dots, log(\sigma_n))\mathbf{U}^T \quad (4.13)$$

Finalmente, algumas propriedades utilizadas mais adiante devem ser mencionadas [7]:

- $\forall \mathbf{P} \in P(n), det(\mathbf{P}) > 0$
- $\forall \mathbf{P} \in P(n), \mathbf{P}^{-1} \in P(n)$
- $\forall \mathbf{P} \in P(n), log(\mathbf{P}) \in S(n)$
- $\forall \mathbf{S} \in S(n), exp(\mathbf{S}) \in P(n)$

4.2.4 Geometria de Riemann

O espaço das matrizes Simétrica Positiva e Definida (SPD), definidas como $P(n)$, é uma variedade Riemanniana (*Riemann Manifold*) diferenciável \mathcal{M} , ou seja, as derivadas em um ponto \mathbf{P} pertencente ao espaço de matrizes $P(n)$ projetam em um espaço $T_{\mathbf{P}}$ tangente, como pode ser observado no exemplo da Figura 4.4. Com essa variedade é possível definir noções métricas como distâncias em curvas ou ângulos [7, 17].

O espaço tangente está contido no espaço de todas as matrizes simétricas $S(n)$ definido anteriormente, contendo um produto interno $\langle \cdot, \cdot \rangle_{\mathbf{P}}$ que varia de forma suave de ponto a ponto ao longo da variedade de Riemann [7].




Figura 4.4: Variedade de Riemann (*Riemann Manifold*) Extraído de [7]

O produto interno em uma variedade de matrizes SPD é dado pela Equação 4.14, que define uma norma para vetores tangentes no espaço tangente como é mostrado na Equação 4.15 [7]. Para um caso específico onde \mathbf{P} é a matriz identidade, a norma se resume a norma de Frobenius dada pela Equação 4.10.

$$\langle \mathbf{S}_1, \mathbf{S}_2 \rangle_{\mathbf{P}} = \text{Tr}(\mathbf{S}_1 \mathbf{P}^{-1} \mathbf{S}_2 \mathbf{P}^{-1}) \quad (4.14)$$

$$\|\mathbf{S}\|_{\mathbf{P}}^2 = \langle \mathbf{S}, \mathbf{S} \rangle_{\mathbf{P}} = \text{Tr}(\mathbf{S} \mathbf{P}^{-1} \mathbf{S} \mathbf{P}^{-1}) \quad (4.15)$$

A menor distância entre dois pontos da variedade de Riemann que respeita as suas restrições é dada pelo comprimento de uma curva cha-

mada de geodésica, que pode ser observada na Figura 4.4 pelo símbolo $\Gamma(t)$ conectando os pontos P e P_i . Essa curva é dada pela Equação 4.16 [7, 34]. É interessante destacar que, caso estivessem sendo utilizadas métricas euclidianas, a menor distância seria dada por uma reta, o que não garantiria que todo ponto pertencente a reta se tratasse de uma matriz SPD.

$$\delta_R(\mathbf{P}_1, \mathbf{P}_2) = \|\log(\mathbf{P}_1^{-1}\mathbf{P}_2)\|_F = \left[\sum_{i=1}^n \log^2 \lambda_i \right]^{\frac{1}{2}} \quad (4.16)$$

onde $\lambda_i, i = 1 \dots n$ são os autovalores de $\mathbf{P}_1^{-1}\mathbf{P}_2$.

É importante ressaltar que a distância de um ponto \mathbf{P}_1 a um ponto \mathbf{P}_2 possui o mesmo valor que a distância do ponto \mathbf{P}_2 ao ponto \mathbf{P}_1 [7, 34].

Através da operação de mapeamento logarítimo dada pela Equação 4.17, é possível realizar uma projeção de um ponto $\mathbf{P} \in P(n)$ da variedade de Riemann para o espaço tangente $S(n)$ [7, 8].

$$\mathbf{S}_i = \text{Log}_{\mathbf{P}}(\mathbf{P}_i) = \mathbf{P}^{\frac{1}{2}} \log(\mathbf{P}^{-\frac{1}{2}}\mathbf{P}_i\mathbf{P}^{-\frac{1}{2}})\mathbf{P}^{\frac{1}{2}} \quad (4.17)$$

O caminho inverso, do espaço tangente para a variedade de Riemann é dado pela Equação 4.18 [7, 8].

$$\mathbf{P}_i = \text{Exp}_{\mathbf{P}}(\mathbf{S}_i) = \mathbf{P}^{\frac{1}{2}} \exp(\mathbf{P}^{-\frac{1}{2}}\mathbf{S}_i\mathbf{P}^{-\frac{1}{2}})\mathbf{P}^{\frac{1}{2}} \quad (4.18)$$

Essas projeções podem ser observadas na Figura 4.4, onde o espaço tangente é dado por $\mathbf{T}_{\mathbf{P}}$ e as operações de mapeamento por $\text{Log}_{\mathbf{P}(P_i)}$ e por $\text{Exp}_{\mathbf{P}(S_i)}$.

Para chegar na etapa de classificação utilizando as métricas até então abordadas, é necessário definir a média das matrizes SPD. A média pode ser uma média Euclidiana, conhecida também como média aritmética, ou uma média de Riemann, conhecida como média geométrica.

A média aritmética é definida pela Equação 4.19, onde é utilizada como base a distância Euclidiana, dada pela norma de Frobenius definida na Equação 4.10.

$$\mathfrak{A}(\mathbf{P}_1, \dots, \mathbf{P}_I) = \arg \min_{\mathbf{P} \in P(n)} \sum_{i=1}^I \delta_E^2(\mathbf{P}, \mathbf{P}_i) = \frac{1}{I} \sum_{i=1}^I \mathbf{P}_i \quad (4.19)$$

Já a média geométrica, natural de matrizes SPD e utilizada neste trabalho, usa como base a distância de Riemann (ver Equação 4.16) e é definida pela Equação 4.20

$$\mathfrak{G}(\mathbf{P}_1, \dots, \mathbf{P}_I) = \arg \min_{\mathbf{P} \in P(n)} \sum_{i=1}^I \delta_R^2(\mathbf{P}, \mathbf{P}_i) \quad (4.20)$$

Finalmente, é importante destacar que não existe uma forma fechada para o cálculo da média de Riemann como há para a média Euclidiana, entretanto existem algoritmos iterativos que cumprem essa tarefa de forma eficaz. [7, 8].

4.2.5 Classificação através da Distância

Para utilizar as métricas definidas anteriormente como classificador, são calculadas as médias das matrizes de covariância do conjunto de treinamento de cada classe de interesse. A seguir, para o conjunto de validação, cada ponto representado por uma matriz de covariância é avaliado pela distância para as médias calculadas, a menor distância define a classe a qual o ponto avaliado pertence.

O algoritmo que calcula a média geométrica é dado pela Tabela 4.2

Entradas: m matrizes SPD $\mathbf{P}_i \in P(n)$ e um limiar $\alpha > 0$

Saída: Média estimada $\mathbf{P}_\Omega \in P(n)$

1: Inicializa $\mathbf{P}_\Omega = \frac{1}{m} \sum_{i=1}^m \mathbf{P}_i$

2: Repete

3: $\mathbf{S} = \frac{1}{m} \sum_{i=1}^m \text{Log}_{\mathbf{P}_\Omega^{(t)}}(\mathbf{P}_i)$ {Média aritmética no espaço tangente}

4: $\mathbf{P}_\Omega^{(t+1)} = \text{Exp}_{\mathbf{P}_\Omega^{(t)}}(\mathbf{S})$

5: Até $\|\mathbf{S}\|_F < \alpha$

Tabela 4.2: Algoritmo da Média de Riemann
Adaptado de [6]

4.3 Comentários

Este capítulo abordou os classificadores usados por este trabalho, SVM e Classificação através de métricas de Riemann, para realizar a classi-

ificação dos eventos de interesse, no caso níveis de stress baixo, médio e alto.

No próximo capítulo será demonstrado como esses classificadores foram utilizados em uma base de dados aberta, também detalhada no próximo capítulo.

CAPÍTULO 5

Resultados

Neste capítulo será descrita toda a metodologia e ferramentas utilizadas para obter os resultados, desde a escolha do conjunto de dados, fluxo de extração do sinal de HRV baseado no algoritmo Wavelet descrito no capítulo 3, até aos resultados aplicando diferentes abordagens, incluindo a metodologia proposta neste trabalho.

Primeiramente será descrita a base de dados usada, com alguns detalhes de como o procedimento de aquisição foi feito para esclarecer futuras conclusões e imagens.

A seguir, será descrito o fluxo usado, desde a entrada do sinal, escolha de épocas a serem analisadas, até a construção do conjunto de entrada para os classificadores descritos no capítulo 4.

Antes de apresentar os resultados finais de classificação, serão apresentadas constatações práticas que evidenciam as diferenciações das classes de estresse baixo, médio e alto através de parâmetros de HRV.

Finalmente, resultados obtidos através de variações de configurações da metodologia, seleção de épocas diferentes, combinações de parâmetros de HRV descritos no capítulo 3 e de classificadores utilizados serão apresentados.

5.1 Base de dados usada

Assim como alguns trabalhos mencionados anteriormente, foi utilizada a base de dados descrita em [24]. Na descrição da base de dados é implementada uma metodologia que utiliza outros sinais complementares ao sinal de ECG para realizar classificação entre níveis de estresse baixo, médio e alto.

A montagem da aquisição desses sinais é ilustrada na Figura 5.1, onde pode-se observar que foram utilizados os sinais de ECG, EMG, respiração e condutividade da pele.




Figura 5.1: **Montagem do Experimento** - Cinco sinais fisiológicos foram extraídos na montagem desse experimento: eletrocardiograma, representado por EKG, eletromiograma, representado por EMG, dois sensores de condutividade da pele, representados por SC, e sensor de respiração, representado por Resp. Todos os sensores foram conectados a um computador, representado por *Computer*.

Extraído de [24]

A obtenção desses sinais foi realizada em condições reais de trânsito, onde cada sujeito devia seguir uma rota específica como em uma situação real. Essa rota teve uma duração de 50min a 1h30min e foi composta de intervalos de descanso, representados por nível baixo de estresse, intervalos de tráfego dentro da cidade, representados por nível alto de estresse, e intervalos de tráfego por rodovias, representados por

nível médio de estresse. Esses trajetos foram realizados durante períodos no meio da manhã ou meio da tarde onde existe pouco trânsito nas rodovias. Todos os sujeitos foram apresentados as mesmas condições de trajeto e nível médio de tráfego.

Dos sinais adquiridos pelo experimento, foi utilizado neste trabalho apenas o de ECG. Esse sinal foi extraído com a derivação II, conforme detalhado no Capítulo 2, com uma frequência de amostragem de 496 Hz .

Foram disponibilizados 16 sujeitos pelo banco de dados usado, dos quais apenas 9 foram utilizados por limitação de qualidade de sinal e dúvida na marcação dos eventos. Por se tratar de uma análise com muitos graus de liberdade, optou-se por utilizar apenas sinais com alta qualidade e com a certeza de marcação dos eventos, os quais foram disponibilizados através de um sinal contínuo de marcação, ao invés de apenas o instante de transição de eventos.

É interessante observar que estão presentes nesses sujeitos tanto homens quanto mulheres saudáveis. Para maiores detalhes referentes a esse banco de dados, consultar a tese de doutorado que o apresenta em [24]. Além disso, em [24], a autora comprova que esses sujeitos estão expostos, em média, as situações de estresse propostas.

5.2 Metodologia utilizada

Com os sinais e marcações em mãos, seguiu-se a metodologia definida nesta seção para realizar o treinamento e classificação. Primeiramente será abordada a estratégia usada para uma pré-seleção de épocas a serem utilizadas para montar o conjunto de dados para treinamento e validação. A seguir, a metodologia aplicada para essas épocas até a etapa de classificação será apresentada detalhadamente. Resumidamente, essa metodologia é ilustrada pela Figura 5.2.

5.2.1 Pré-processamento e Extração da HRV

Antes de ser fornecido ao algoritmo de detecção, o sinal passou por um conjunto de filtros que limitam o sinal a banda de interesse, de aproximadamente 20 Hz para o pico da onda R.

Todos os filtros utilizados foram filtros do tipo *butterworth* por possuírem a região de banda passante a mais plana possível, aplicados

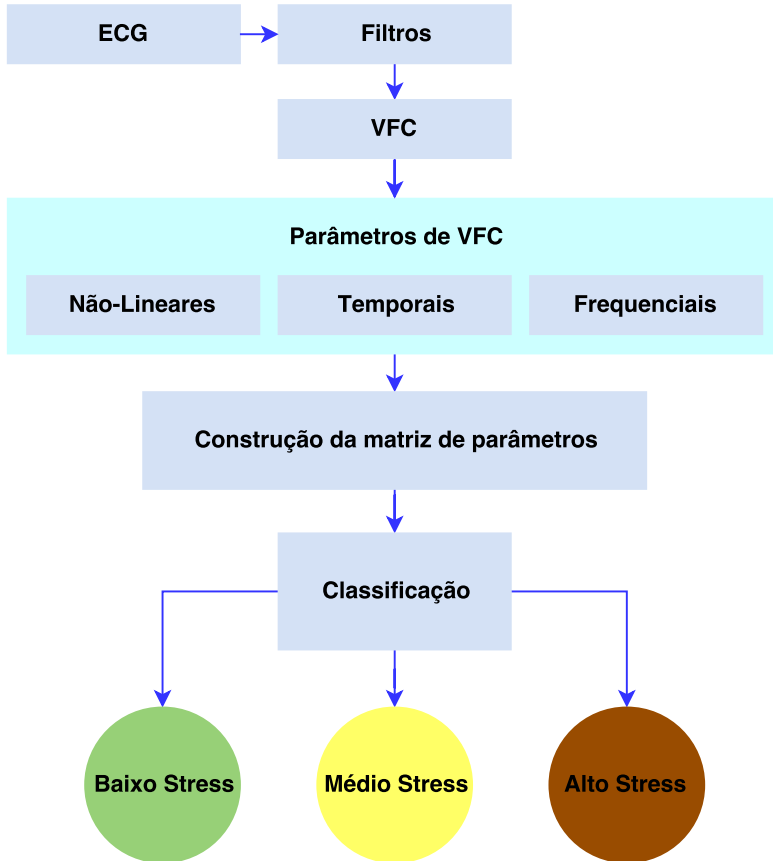


Figura 5.2: **Fluxo da Metodologia** - Partindo de sinais não filtrados aplica-se os filtros para limitar a banda de interesse (Aproximadamente 20 Hz), é extraída a série temporal de HRV e a partir dela podem ser extraídos diversos parâmetros de natureza temporal, frequencial ou não-linear. Finalmente esses parâmetros podem ser usados diretamente como entrada de um classificador, ou, como proposto neste trabalho, combinados através de sua evolução temporal para construir uma matriz de parâmetros, onde as linhas são os parâmetros seleccionados e as colunas a evolução temporal. Finalmente dessa matriz são extraídas as entradas do classificador que decide por uma das três classes ilustradas.

usando a estratégia de fase-zero, processando o sinal de entrada de forma direta e de forma reversa, removendo qualquer distorção inserida pela fase do filtro [22].

Inicialmente, o sinal foi filtrado em 60 Hz removendo interferências de linha usando um *butterworth* de ordem 2. A seguir, para remover interferências de linha de base provenientes de movimentos de eletrodos ou até mesmo respiração, sem distorcer o sinal de ECG, foi utilizado um *butterworth* passa-alta de ordem 2 com frequência de corte em 1 Hz.

Finalmente, para remover ruídos de alta-frequência, principalmente ruídos musculares que contém um espectro que faz intersecção com o espectro do sinal de ECG, foram utilizados 2 filtros *butterworth*, um de ordem 2 e frequência de corte em 20 Hz e outro de ordem 4 com frequência de corte em 30 Hz. Esse segundo filtro em 30 Hz não foi inserido junto do filtro com corte em 20 Hz para não atenuar a onda R excessivamente já que ela se estende para faixas acima de 20 Hz.


Após filtrado, o sinal é fornecido ao algoritmo de detecção de onda R, descrito no capítulo 3, que nada mais é do que um outro filtro de banda, seguido de uma diferenciação para realçar a derivada da onda R. Ao encontrar o pico exato de cada onda R, o intervalos de cada pico com o anterior é calculado para resultar na nova série temporal de HRV.

A Figura 5.3 ilustra um janela onde o sinal já está filtrado, com a devida detecção do pico R realizada, podendo-se observar o sinal de HRV referente a essa janela logo abaixo.


5.2.2 Pré-Seleção Manual e divisão em épocas

A partir dos sinais de ECG, foi primeiramente realizada uma análise da qualidade do sinal para, a seguir, remover regiões de muito artefato, onde a combinação de filtros e algoritmo de detecção baseado na Transformada Wavelet não são suficientes para realizar a correta detecção das ondas R.

Para realizar essa seleção de regiões, observou-se inicialmente a amplitude do sinal após os filtros aplicados. Para regiões de amplitude muito alta, um ordem de grandeza longe de um valor médio de um sinal de ECG (Aproximadamente $1mV$), e de amplitudes muito baixas prolongadas, valores próximos de $0mV$ por mais do que um valor



ECG pós filtros e detecção do pico R



Sinal de HRV

Figura 5.3: Sinal de ECG com HRV

mínimo normal de batimento cardíaco (Acima de 2 segundos), foram adicionadas marcações de seções de sinal de baixa qualidade, não utilizados para análise.

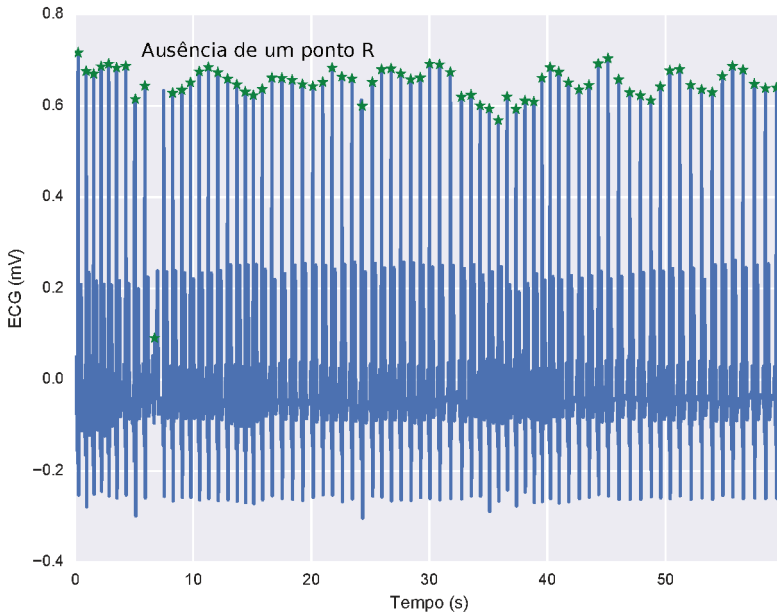
O algoritmo de detecção foi aplicado e considerado apenas nas regiões remanescentes, extraindo-se a HRV e observando-se a sua evolução temporal em uma interface gráfica desenvolvida para facilitar este trabalho. Pedacos com variações muito bruscas de variabilidade podem ser facilmente observados e analisados, como é exemplificado pela Figura 5.4, onde a Figura de cima ilustra a falta de um ponto R, removido manualmente para exemplificar, e a Figura de baixo demonstra a variação brusca na variabilidade cardíaca.

Ainda em relação a Figura 5.4, com a média da janela de HRV em aproximadamente 75bpm e desvio padrão de aproximadamente 7bpm, é possível concluir que a ausência de um ponto R em uma janela de 1 minuto no sinal de variabilidade é facilmente detectado, mesmo com técnicas simples de limites dentro de 2 ou até 3 desvios padrões.

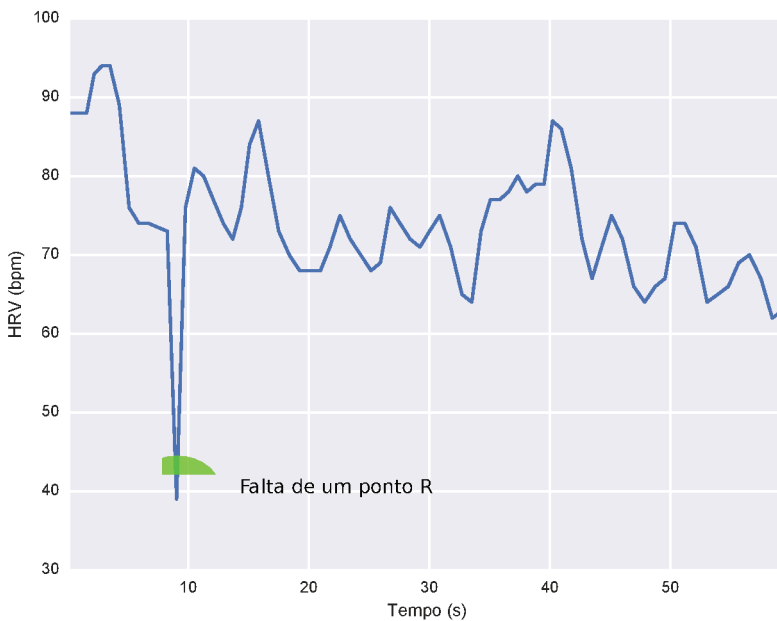
O processo de validação da metodologia apresentada neste trabalho foi aplicado em duas situações distintas de dados selecionados.

O primeiro conjunto de dados a ser usado para treinamento e validação foi escolhido manualmente, observando alguns sinais evoluindo temporalmente. Para cada estado de estresse, foram observados alguns parâmetros para garantir a validade do dado a ser usado para treinamento e validação dentro daquele estado de estresse, mantendo um equilíbrio entre o número de eventos usados para cada estado de estresse. Esses parâmetros serão melhor exemplificados a seguir.

Essa escolha foi feita pois cada estado tem uma duração de 10 minutos, mas que não necessariamente apresenta o estado de estresse definido de acordo com a marcação por toda a duração. Por exemplo, durante os 10 minutos de nível baixo de estresse, o indivíduo pode ficar estressado naturalmente por alguma razão, ou ao contrário, durante os 10 minutos de nível alto de estresse o indivíduo pode apresentar nível baixo de estresse, durante a maior parte do tempo, época que não faz sentido ser utilizada para treinar uma classe de nível alto de estresse. Essa seleção foi feita considerando já o conhecimento de que o evento era dentro de uma janela de baixo, médio ou alto estresse, usando parâmetros de variabilidade apenas para confirmar o evento. Além disso, essa inserção de garantias manuais foi feita também para reduzir ao



ECG na ausência de um ponto R.



HRV na ausência de um ponto R

Figura 5.4: Sinal de ECG com HRV na ausência de um ponto R extraído manualmente para exemplificar a consequência no sinal de HRV.

Nível de estresse	Baixo		Médio		Alto		Total	
	Marcado	Original	Marcado	Original	Marcado	Original	Marcado	Original
Motorista 5	2	1	1	1	4	3	7	5
Motorista 6	2	1	1	2	3	3	6	6
Motorista 7	2	1	1	2	3	3	6	6
Motorista 8	4	1	2	2	2	3	8	6
Motorista 10	1	1	2	2	2	1	5	4
Motorista 11	2	1	1	2	2	3	5	6
Motorista 12	1	0	2	2	2	3	5	5
Motorista 15	2	1	2	2	2	3	6	6
Motorista 17	2	1	2	2	2	3	6	6
Total	18	8	14	17	22	25	54	50

Tabela 5.1: **Tabela de eventos por nível de estresse e motorista** - Comparação entre o número de eventos de cada classe (nível de estresse) no conjunto de dados fornecido e na marcação manual, com um equilíbrio maior entre o número de exemplos de cada classe.

mínimo os graus de liberdade de toda a metodologia e para manter um equilíbrio no número de eventos de cada classe, no caso cada nível de estresse.

A Tabela 5.1 mostra o número de eventos de cada nível de estresse para cada motorista usado neste trabalho para as marcações fornecidas pelo conjunto de dados [24] e para as marcações realizadas manualmente, conforme mencionado anteriormente. Ambas as marcações possuem um número total de eventos próximo, no entanto, é possível notar que a marcação original não possui um equilíbrio entre o número de eventos de cada estado de estresse, pois o número de exemplos de estresse baixo é de apenas 8, comparado com os 25 exemplos de estresse alto.

Após a validação da metodologia aplicada a um conjunto de dados selecionado manualmente, foram utilizadas as marcações de eventos fornecidas originalmente pelo próprio banco de dados usado.

Por final, é importante ressaltar que alguns outros trabalhos [24, 36, 65] que utilizaram também essa base de dados não fizeram essa pré-seleção, tratando toda a janela do evento igualmente, apenas centralizando o pedaço de sinal utilizado na janela do evento.

5.2.3 Construção da matriz de parâmetros para análise dinâmica

Conforme mencionado no capítulo referente às características de um sinal de HRV, Captítulo 3, este trabalho utiliza uma etapa intermediária entre essas análises e a entrada do classificador.

Diferentemente de outros trabalhos que calculam um valor de cada parâmetro para ser inserido já como um elemento do vetor de entrada do classificador, este trabalho realiza também a análise dinâmica desses parâmetros ao longo do tempo, comparando com a abordagem sem considerar essa evolução temporal.

Para realizar essa análise dinâmica, é necessário construir uma matriz de parâmetros $X \in \mathbb{R}^{p \times n}$, onde p é o número de parâmetros de HRV e n o número de amostras de cada parâmetro.

Cada valor de um parâmetro é calculado com uma janela W_o de sinal de HRV, com o instante final da janela sendo o instante de interesse do evento, neste caso nível baixo, médio ou alto de estresse.

A janela W_o no instante de interesse pode ser observada na Figura 5.5a, que ilustra o início do processo realizado para construir a matriz de parâmetros X . Nesse exemplo, é calculado o valor de um parâmetro específico dentro da janela com o seu final no instante de interesse, preenchendo a matriz X na linha do parâmetro em questão e na coluna n .

A seguir, a janela desliza para trás com um passo S em segundos e calcula novamente um valor para o parâmetro em questão, preenchendo a coluna $n - 1$. Esse deslizamento é realizado $n - 1$ vezes e pode ser observado nas Figuras 5.5a, 5.5b e 5.5c, onde a janela W_o encontra-se no instante de interesse, após 5 deslizamentos e após 15 deslizamentos, respectivamente. Cada deslizamento da janela W_o adiciona uma nova coluna a matriz de parâmetros X , totalizando n colunas.

Esse processo descrito é realizado para cada parâmetro, constituindo p linhas, já que cada parâmetro pode ter a sua janela, o que é interessante pois alguns parâmetros possuem uma resposta mais rápida do que outros. Por exemplo, para um parâmetro que avalia respostas de baixa frequência é interessante ter uma janela maior do que um parâmetro que avalia respostas de alta frequência.

É possível fazer uma analogia entre a matriz X e uma época de um sinal de EEG. No caso da matriz X , as linhas definidas pelos parâmetros extraídos da série temporal HRV, seriam o que os canais são em épocas de EEG, enquanto que em ambos os casos as colunas representam novas amostras ao longo do tempo.

Para que essa analogia seja ainda mais real, é necessário realizar uma normalização nas linhas da matriz X para uma distribuição de

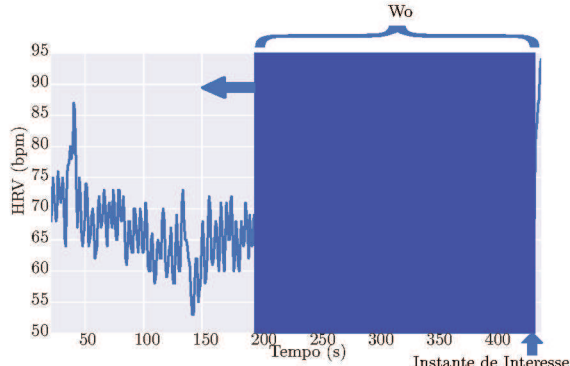
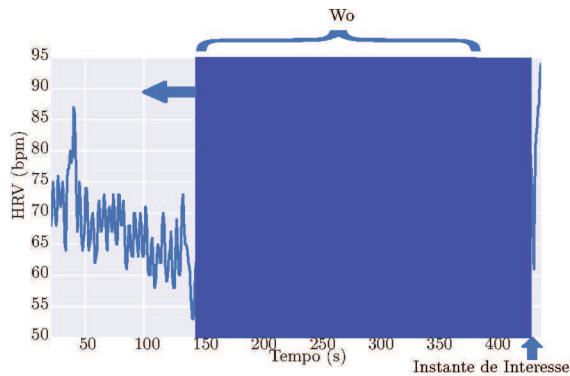

Janela W_o no instante de interesseJanela W_o com 5 passos S de 10sJanela W_o com 15 passos S de 10s

Figura 5.5: **Janela W_o deslizando** - A sequência das Figuras 5.5a, 5.5b e 5.5c ilustra o processo de construção da matriz $X \in \mathbb{R}^{p \times n}$. Cada linha que representa cada parâmetro é constituída pelo deslizamento de S segundos da janela W_o para trás no tempo $n - 1$ vezes, iniciando no instante de interesse e finalizando após $n - 1$ passos realizados.

média nula e variância unitária e também para que as suas amplitudes tenham a mesma ordem de grandeza, assim como em um sinal de EEG, onde todos os canais estão medidos em μV .

Essa normalização é realizada pelo procedimento vastamente utilizado por aplicações de aprendizado de máquina, definido pela Equação 5.1. Esse procedimento é aplicado em cada linha, representada por cada parâmetro de HRV usado na construção da matriz X .

$$\hat{\mathbf{x}} = \frac{\mathbf{x} - \mu}{\sigma}, \quad (5.1)$$

onde μ e σ são o valor médio e o desvio padrão, respectivamente, ambos extraídos de uma estimativa de distribuição de valores do parâmetro sendo normalizado.

Com a matriz normalizada \hat{X} a partir da matriz X , é estimada a matriz de covariância Σ definida pela Equação 4.9 no Capítulo 4. É importante lembrar que a diagonal principal dessa matriz Σ representa as variâncias da matriz \hat{X} , no caso a variância de cada parâmetro ao longo do tempo, com um intervalo de S segundos entre uma estimativa e outra. Ressaltando também que a matriz Σ é simétrica em relação a sua diagonal principal e que os seus demais componentes representam as covariâncias entre os parâmetros da matriz X .

Para estimar a matriz de covariância foi utilizada uma biblioteca aberta em Python que implementa a estimação baseada na matriz de covariância amostral (SCM - *Sample Covariance Matrix*), muito utilizada em análises de EEG e definida pela Equação 5.2 [7, 8].

$$S = \frac{1}{n-1} \hat{X} \hat{X}^T, \quad (5.2)$$

A partir da matriz de covariância estimada S , duas abordagens foram utilizadas como estratégia de classificação: A classificação utilizando métricas não-euclidianas em matrizes de covariância, conforme descrito no Capítulo 4 e a decomposição da matriz S em autovetores e autovalores para utilizar essa decomposição como entrada do classificador SVM. Na segunda abordagem, o vetor de características final fornecido como entrada ao classificador SVM foi a combinação das coordenadas do autovetor mais significativo (com a maior amplitude) da decomposição a média de cada parâmetro utilizado na matriz X , resultando em um vetor de entrada de dimensão $2p$, onde p representa o

número de parâmetros utilizados na análise. A combinação do autovetor mais significativo com a média de cada parâmetro é justificada pela informação de direção fornecida pelo autovetor mais relevante unida a informação de linha de base do parâmetro, fornecida pela média.

5.3 Análises de resultados

Para realizar a classificação final através das abordagens mencionadas, foi realizada uma pré-análise dos parâmetros de variabilidade para elencar os parâmetros que demonstram mais separabilidade entre as classes e que não adicionam informação repetida. Para isso, foram feitas análises de quartis de cada parâmetro para cada nível de estresse, considerando todos os sujeitos e para cada sujeito individualmente. Além disso, uma análise de correlação entre parâmetros através do coeficiente de correlação de Pearson foi realizada para futuras constatações.

Finalmente, foi realizada a classificação entre os três níveis de estresse, conforme proposto e descrito anteriormente. Para fins comparativos, foram utilizadas diferentes abordagens para classificar os mesmos estados, conforme será descrito posteriormente.

5.3.1 Correlação entre parâmetros de HRV

Iniciando pela análise de correlação entre os parâmetros de HRV, a Tabela 5.2 mostra todos os parâmetros utilizados neste trabalho e a correlação entre eles.

O valor de correlação entre os parâmetros foi obtido através do coeficiente de correlação de Pearson ρ , definido pela Equação 5.3, onde \mathbf{x} e \mathbf{y} são os dois conjuntos de dados. Esse coeficiente mede a relação linear entre \mathbf{x} e \mathbf{y} e pode assumir valores entre -1 e 1. Quanto mais próximo de 0 menor a correlação entre os dois conjuntos, com 0 indicando nenhuma correlação. Valores de -1 ou 1 indicam total relação linear, onde 1 representa que a medida que um conjunto cresce, o outro também, e onde -1 indica o contrário, a medida que um conjunto cresce o outro desce com uma relação linear.

$$\rho_{\mathbf{x},\mathbf{y}} = \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{\sigma_x \sigma_y}, \quad (5.3)$$

	CSI	CVI	VLF	LF	HF	SVI	μ	SDN	RM	PNN	SEN	λ	DFH	MH	CH
CSI	1.00	-0.09	0.41	0.00	-0.46	0.55	-0.55	0.42	-0.58	-0.63	-0.76	0.15	-0.70	-0.61	0.57
CVI	-0.09	1.00	0.41	0.60	0.66	-0.15	0.35	0.85	0.82	0.63	0.07	0.07	0.20	0.69	-0.56
VLF	0.41	0.41	1.00	0.28	-0.00	0.19	0.01	0.59	0.08	0.00	-0.21	0.20	-0.27	0.10	-0.08
LF	0.00	0.60	0.28	1.00	0.32	0.44	-0.10	0.54	0.48	0.16	-0.02	0.01	-0.33	0.31	-0.16
HF	-0.46	0.66	-0.00	0.32	1.00	-0.50	0.43	0.36	0.84	0.78	0.25	-0.06	0.52	0.71	-0.64
SVI	0.55	-0.15	0.19	0.44	-0.50	1.00	-0.55	0.12	-0.40	-0.57	-0.41	0.06	-0.79	-0.44	0.48
μ	-0.55	0.35	0.01	-0.10	0.43	-0.55	1.00	0.06	0.55	0.79	0.63	0.02	0.74	0.73	-0.83
SDN	0.42	0.85	0.59	0.54	0.36	0.12	0.06	1.00	0.45	0.27	-0.32	0.14	-0.15	0.33	-0.23
RM	-0.58	0.82	0.08	0.48	0.84	-0.40	0.55	0.45	1.00	0.86	0.43	-0.05	0.53	0.88	-0.74
PNN	-0.63	0.63	0.00	0.16	0.78	-0.57	0.79	0.27	0.86	1.00	0.57	-0.03	0.77	0.87	-0.84
SEN	-0.76	0.07	-0.21	-0.02	0.25	-0.41	0.63	-0.32	0.43	0.57	1.00	-0.12	0.60	0.54	-0.57
λ	0.15	0.07	0.20	0.01	-0.06	0.06	0.02	0.14	-0.05	-0.03	-0.12	1.00	-0.01	-0.00	-0.02
DFH	-0.70	0.20	-0.27	-0.33	0.52	-0.79	0.74	-0.15	0.53	0.77	0.60	-0.01	1.00	0.63	-0.69
MH	-0.61	0.69	0.10	0.31	0.71	-0.44	0.73	0.33	0.88	0.87	0.54	-0.00	0.63	1.00	-0.93
CH	0.57	-0.56	-0.08	-0.16	-0.64	0.48	-0.83	-0.23	-0.74	-0.84	-0.57	-0.02	-0.69	-0.93	1.00

Tabela 5.2: **Correlação entre parâmetros de HRV** - **CSI**: Índice Cardiosimpático, **CVI**: Índice Cardiovagal, **VLF**: Muito Baixa Frequência, **LF**: Baixa Frequência, **HF**: Alta Frequência, **SVI**: Índice Simpatovagal (LF/HF), λ : Média, **SDN**: Desvio Padrão dos Intervalos Normais de RR, **RM**: Raiz quadrada da média da soma do quadrado das diferenças sucessivas dos intervalos normais de RR, **PNN**: Porcentagem de intervalos normais de RR normais sucessivos superiores a 50 milissegundos, **SEN**: Entropia Amostral (SampEn), λ : Maior Expoente de Lyapunov, **DFH**: Dimensão Fractal de Higuchi, **MH**: Mobilidade de Hjorth, **CH**: Complexidade de Hjorth.

onde σ_x e σ_y são os desvios padrões dos conjuntos de dados \mathbf{x} e \mathbf{y} , respectivamente, e $\text{cov}()$ é a covariância entre eles.

Com esses resultados de correlação entre os parâmetros, é possível verificar comportamentos semelhantes na adição ou remoção de parâmetros com alta correlação no conjunto de entrada dos classificadores. Além disso, é interessante notar algumas correlações já esperadas entre alguns parâmetros [32], como pode ser observado na Tabela 5.2 entre os parâmetros HF (Alta Frequência), PNN (pnn50 - Porcentagem de intervalos normais de RR sucessivos superiores a 50 milissegundos) e RM (RMSSD - Raiz quadrada da média da soma do quadrado das diferenças sucessivas dos intervalos normais de RR). Esses três parâmetros possuem uma forte correlação, acima de 0.7, o que é uma correlação esperada já que todos os três refletem atividades provenientes do sistema parassimpático [32].

Ainda em relação a correlação de parâmetros referentes ao sistema parassimpático, é interessante notar como o parâmetro RM citado anteriormente tem alta correlação com CVI (Índice Cardiovagal), também conhecido na literatura como um parâmetro que reflete atividades do sistema parassimpático [60].

Outra correlação entre parâmetros que chama atenção é a correlação inversa entre CSI (Índice Cardiosimpático) e a entropia amostral (SEN), indicando que a entropia amostral reflete fortemente o sistema simpático. As demais correlações que obtiveram resultados acima de 0.8 fora consideradas na etapa final de classificação para evitar a utilização de parâmetros com alta correlação.

5.3.2 Quartis dos parâmetros de HRV e estresse

Antes de realizar os procedimentos de construção da matriz de parâmetros e da validação da acurácia dos modelos, todos os parâmetros utilizados tiveram sua distribuição de amplitudes analisadas para cada nível de estresse através da análise de quartis.

Para realizar essa análise, foram considerados todos os motoristas e todos os eventos representantes dos níveis de estresse. Para o cálculo de cada parâmetro foi utilizada uma janela de três minutos deslizante com um passo de 5 segundos, ou seja, para cada passo da janela foi gerado um novo parâmetro.

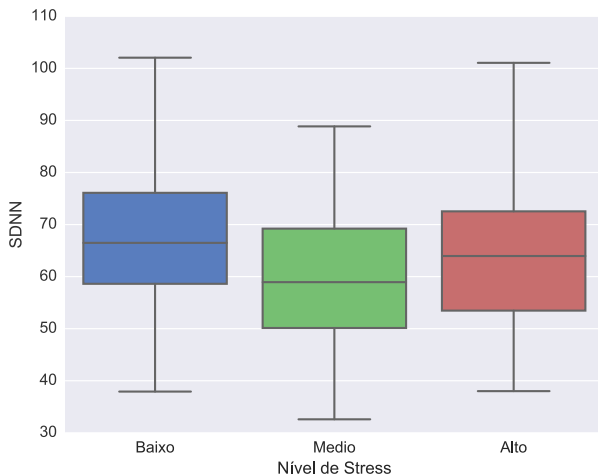


Figura 5.6: Quartis de **SDNN** da HRV

Todos as análises de quartis apresentados a seguir possuem a seguinte interpretação: Da esquerda para a direita são apresentados os três níveis de estresse, baixo, médio e alto, onde o eixo vertical representa os valores de amplitude de cada parâmetro. Os retângulos na vertical representam 50% dos dados e a linha horizontal dentro dele representa a mediana. Valores para fora dos retângulos para cima representam os 25% remanescentes com amplitude maior do que os 50% dentro do retângulo e para baixo representam os 25% com amplitude menor.

O primeiro conjunto de quartis, representado pelas Figuras 5.7, 5.6, 5.8, 5.9 apresenta a distribuição dos parâmetros temporais usados neste trabalho. É possível notar que, com exceção do parâmetro de desvio padrão (SDNN - Figura 5.6), existe uma tendência de separabilidade entre as classes de estresse baixo, médio e alto.

O parâmetro de média da HRV (Figura 5.7) mostra uma característica esperada, onde amostras de períodos em que o motorista se encontra no estado de baixo estresse os intervalos de RR são maiores, em média, aumentando a medida que o estado de estresse aumenta, para médio e finalmente para alto.

Além disso, tanto o parâmetro pNN50 (Porcentagem de intervalos




Figura 5.7: Quartis da **Média** da HRV

sucessivos superiores a 50ms - Figura 5.8) quanto o parâmetro RMSSD (Raiz quadrada da média da soma do quadrado das diferenças sucessivas - Figura 5.9) apresentam resultados esperados, já que trabalhos indicam que ambos refletem atividade do ramo parassimpático [38, 61], indicando que ambos tem seus valores reduzidos a medida que o nível de estresse aumenta.

Seguindo a análise de quartis, as figuras 5.10, 5.11 e 5.12 ilustram as distribuições dos parâmetros frequenciais em forma de diagrama de quartis.

Iniciando pelo parâmetro de baixa frequência (LF), representado na figura 5.10, não é possível observar uma diferenciação entre os três níveis de estresse, justificado por esse parâmetro possuir reflexos de ambas as atividades simpática e parassimpática [43].

Já no caso do parâmetro de alta frequência, ilustrado na figura 5.11, é possível notar a sua separabilidade de nível baixo de estresse para os demais níveis, seguindo o esperado de representar atividades parassimpáticas [12].

O parâmetro de muito baixa frequência não foi usado nas análises seguintes pela dúvida recorrente de sua relação com o SNA em diversos trabalhos e também pela utilização de janelas mais curtas, não repre-




Figura 5.8: Quartis de **PNN50** (Porcentagem de intervalos sucessivos superiores a 50ms) da HRV




Figura 5.9: Quartis de **RMSSD** (Raiz quadrada da média da soma do quadrado das diferenças sucessivas) da HRV




Figura 5.10: Quartis de LF da HRV




Figura 5.11: Quartis de HF da HRV




Figura 5.12: Quartis de **SVI** ($\frac{LF}{HF}$) da HRV

sentando baixas frequências de forma fiel.

Finalmente, o parâmetro SVI (Índice Simpatovagal) na figura 5.12 demonstra o balanço entre as vias simpática e parassimpática, aumentando a atividade simpática e reduzindo a atividade parassimpática para níveis mais elevados de estresse.

A análise de quartis dos parâmetros não-lineares inicia com os parâmetros derivados do gráfico de Poincaré, CSI e CVI.

A Figura 5.13 demonstra a distribuição do parâmetro CSI nos três estados de estresse para todos os motoristas. Pode-se observar o seu crescimento a medida que o nível de estresse aumenta, resultado esperado, já que esse parâmetro reflete predominantemente a atividade do sistema simpático.

No caso do parâmetro CVI, ilustrado na Figura 5.14, não é possível diferenciar os estados de médio e alto estresse pois ambos devem apresentar o mesmo equilíbrio entre os sistemas simpático e parassimpático. No entanto, no caso do nível baixo de estresse é possível verificar uma predominância de altos valores desse índice, demonstrando que o sistema parassimpático está em controle, o que era esperado já que se trata de uma situação de repouso.

Um dos parâmetros de Hjorth, a mobilidade tem sua distribuição




Figura 5.13: Quartis de **CSI** (Índice Simpatovagal) da HRV




Figura 5.14: Quartis de **CVI** (Índice Cardiovagat) da HRV




Figura 5.15: Quartis de **MH** (Mobilidade de Hjorth) da HRV

por nível de estresse ilustrada na Figura 5.15. Conforme esperado, é possível notar a sua correlação com o parâmetro HF de alta frequência, já que a mobilidade fornece uma estimativa da frequência média, indicando novamente que a Mobilidade de Hjorth reflete a atividade parassimpática.

O outro parâmetro de Hjorth utilizado neste trabalho que tem sua distribuição apresentada pela Figura 5.16 é a complexidade. É possível notar a sua correlação negativa com o parâmetro de mobilidade, conforme indicado pela tabela 5.2, já que a sua distribuição tem a tendência de aumentar conforme o nível de estresse aumenta. Com isso, é possível concluir que o parâmetro de Complexidade de Hjorth reflete inversamente a atividade parassimpática.

O próximo parâmetro não-linear analisado foi o maior expoente de Lyapunov (λ), com sua distribuição em níveis de estresse ilustrada pela Figura 5.17. É interessante notar como a maior parte da distribuição em ambos os estados de estresse se encontra acima do valor nulo, característica de um sistema caótico, e tem um pequeno crescimento a medida que o nível de estresse aumenta.

Conforme descrito em [59], o parâmetro DFH (Dimensão Fractal de Higuchi) possui uma relação direta com os parâmetros que refletem




Figura 5.16: Quartis de **CH** (Complexidade de Hjorth) da HRV




Figura 5.17: Quartis de λ (Maior Exponente de Lyapunov) da HRV




Figura 5.18: Quartis de **DFH** (Dimensão Fractal de Higuchi) da HRV

o sistema parassimpático. Essa característica também pode ser observada na análise de quartis desse parâmetro na Figura 5.18, onde com o aumento do nível de estresse a atividade parassimpática aparece mais fraca ao observar a distribuição de DFH.

A última análise de quartis de todos os eventos é do parâmetro não-linear SampEn (Entropia Amostral), ilustrada na Figura 5.19. Conforme observado anteriormente na tabela 5.2, esse parâmetro tem uma correlação negativa com o índice que reflete a atividade simpática (CSI). É possível concluir então que a medida que o nível de estresse aumenta a complexidade do sinal de HRV tem a tendência de redução.

5.3.3 Quartis dos parâmetros de HRV e estresse por motorista

Após a análise considerando todos os eventos de todos os motoristas, foi feita uma análise separando cada motorista para verificar se todos obtiveram o mesmo comportamento durante os diferentes níveis de estresse. Para isso, foram apenas considerados os parâmetros com maior diferenciação nas análises anteriores, pnn50, RMSSD, SVI, HF, CSI e DFH.

A partir das próximas análises, considerando os motoristas separadamente, vai ser possível observar mais claramente que não necessaria-




Figura 5.19: Quartis de **SampEn** (Entropia Amostral) da HRV

mente um motorista estará no mesmo nível de estresse em toda a janela do evento considerado. Inclusive, será avaliado motorista por motorista para verificar a qualidade do conjunto de treinamento e validação da última etapa deste trabalho, a separação entre os níveis de estresse.

A Figura 5.20 mostra a distribuição do parâmetro $pnn50$ nos três níveis de estresse por motorista. É possível observar a mesma tendência de queda a medida que o nível de estresse aumenta, com exceção do motorista 12.

Outro parâmetro temporal ilustrado por motorista e por nível de estresse é o RMSSD, apresentado na Figura 5.21. É possível notar as suas maiores amplitudes durante os eventos de baixo estresse. Novamente, o motorista 12 apresenta uma exceção em relação ao padrão demonstrado pelos outros motoristas, já que com o aumento do nível de estresse ele tem sua distribuição de RMSSD aumentando, indicando uma maior atividade parassimpática, enquanto que o esperado seria um aumento da atividade simpática.

Os parâmetros frequenciais que demonstraram a maior separação entre os níveis de estresse para todos os motoristas foram o HF e SVI, sendo portanto apresentados separadamente para cada motoristas nas Figuras 5.22 e 5.23, respectivamente.




Figura 5.20: Quartis de **pnn50** por Motorista




Figura 5.21: Quartis de **RMSSD** por Motorista




Figura 5.22: Quartis de **HF** por Motorista

Na Figura 5.22 é possível notar com ainda mais facilidade a separação do nível de baixo estresse para os demais, ao considerar o parâmetro HF. No entanto, novamente o motorista 12 apresenta uma exceção ao padrão apresentado, com níveis de HF muito próximos em todos os estados de estresse, com um leve aumento a medida que o nível de estresse aumenta.

Já na Figura 5.23, é interessante observar que nem todos os motoristas seguem o padrão de crescimento de SVI a medida que o estresse aumenta, com uma maior discrepância novamente no motorista 12. Os outros motoristas que não seguem o padrão (M6, M7 e M10) apresentam uma redução ao comparar o nível médio de estresse para o nível alto, característica não esperada, mas justificada novamente pelas diversas possibilidades de estados de estresse em uma determinada janela de tempo.

Para finalizar as análises de quartis, os parâmetros não-lineares que apresentaram maior separabilidade entre os três níveis de estresse são ilustrados nas Figuras 5.24 e 5.25.

Conforme destacado na tabela 5.2 e mostrado nas figuras 5.13 e 5.18 esses dois parâmetros possuem uma correlação negativa, indicando que conforme um aumenta o outro reduz, característica novamente obser-




Figura 5.23: Quartis de **SVI** por Motorista



vada individualmente para cada motorista.

Já que o parâmetro CSI reflete a atividade simpática, é esperado que a sua distribuição possua valores mais altos a medida que o nível de estresse aumenta, o que é respeitado por todos os motoristas na figura 5.13, com exceção de M7, M10, M11 e M12.

O último parâmetro com sua distribuição analisada por motoristas separadamente, DFH, apresenta o comportamento esperado de queda a medida que o nível de estresse aumenta, com exceção, novamente dos motoristas M7, M10 e M12.

A partir das análises de quartis separando os níveis de estresse por motoristas, foi possível observar que nem todos os motoristas seguiram o mesmo padrão, o que é justificável, já que nem todos os sujeitos reagem da mesma forma as situações apresentadas pelo experimento realizado para aquisição do conjunto de dados utilizado.

Com essas discrepâncias apresentadas nos motoristas M7, M10 e M12, na etapa de classificação, resultados com e sem esses motoristas são apresentados para o conjunto de dados fornecido.

Figura 5.24: Quartis de **CSI** por MotoristaFigura 5.25: Quartis de **DFH** por Motorista

5.3.4 Classificação entre três níveis de estresse

Com a metodologia utilizada explicada e as análises de cada parâmetro realizadas, tanto considerando todos os motoristas, quanto para cada motorista individualmente, é possível iniciar a etapa de classificação utilizando SVM e Riemann.

Para realizar a validação, tanto para o caso de marcações manuais, quanto para o caso de marcações fornecidas, o conjunto de dados usado foi dividido aleatoriamente em duas partes, tentando manter um equilíbrio entre o número de exemplos de cada classe.

O primeiro conjunto foi utilizado para treinar o classificador e o segundo para realizar a validação através da métrica de acurácia, medida através no número de classificações corretas dividido pelo número total de eventos classificados.

Conforme mencionado anteriormente, foram realizadas validações em dois conjuntos de dados diferentes, um marcado manualmente e outro da forma que foi fornecido pelo banco de dados. Ambas as validações foram feitas considerando três abordagens, descritas a seguir:

- (i) **RIEMANN** - Geometria de Riemann aplicada nas matrizes de covariância S . Através do algoritmo descrito na tabela 4.2, no capítulo 4, são utilizadas as matrizes de covariância do conjunto de treinamento para calcular a média de cada classe, representando cada nível de estresse. A seguir, para cada amostra do conjunto de validação, representada por uma matriz de covariância, é calculada a distância de Riemann entre essa amostra e a média das classes de baixo, médio e alto estresse. A menor distância define a classe;
- (ii) **SVMEVECS** - Classificador SVM com o vetor de entrada composto pelo autovetor mais significativo da matriz de covariância S e a média de cada parâmetro da matriz \hat{X} , usada para construir a matriz S . A partir de cada matriz de covariância presente no conjunto de treinamento, é feita a sua decomposição em autovalores e autovetores, com os autovetores representando a direção de cada variância da decomposição e os autovalores as suas amplitudes respectivas. De cada decomposição realizada, é utilizado como entrada do SVM o autovetor com maior amplitude junto da média ao longo do tempo de cada parâmetro usado anterior-

mente para construir a matriz de covariância como informação de linha de base, perdida com apenas a informação de direção. É importante destacar que ao fazer esse procedimento para todas as amostras do conjunto de treinamento, é feita novamente a normalização usando a equação 5.1 do vetor de entrada composto pelo autovetor e os valores médios. Essa normalização é realizada pois o algoritmo de treinamento do SVM considera que todas as amostras de entrada possuem média zero e mesma variância, caso contrário amostras com maior variância podem dominar o treinamento, não permitindo que as outras amostras sejam consideradas também no treinamento. Finalmente, com o treinamento realizado, o conjunto de validação é fornecido amostra por amostra com o vetor construído da mesma forma que o conjunto de treinamento, usando a média e desvio padrão do conjunto de treinamento para a normalização antes de fornecer o vetor ao SVM.

- (iii) **SINGLEW_o** - Abordagem clássica, onde é calculado apenas um valor de cada parâmetro em uma janela de tamanho fixo especificada para 5 minutos. Cada vetor de entrada ao SVM é construído com esses parâmetros calculados. Como descrito no caso anterior, antes de serem fornecidos ao SVM para treinamento, os vetores são normalizados também com a equação 5.1. Da mesma forma, a validação é realizada normalizando os vetores a serem validados com a média e desvio padrão calculados antes do treinamento.

Para as marcações manuais, os resultados obtidos são apresentados na Tabela 5.3, mostrando os parâmetros utilizados com suas respectivas janelas em minutos.

Tanto para RIEMANN quanto para SVMEVECS foram utilizados passos de 10 segundos e um total de 20 passos, para obter 20 amostras de cada parâmetro ao longo do tempo (Considerando que o primeiro passo é representado pela amostra calculada no instante de interesse). É possível observar que o melhor resultado, uma acurácia de 86%, foi obtido pela metodologia de RIEMANN, seguido pela metodologia SVMEVECS com uma acurácia de 82%, e finalmente pela metodologia SINGLEW_o, utilizada pela maioria dos trabalhos com o cálculo de apenas uma amostra de cada parâmetro, com uma acurácia de 75%, consideravelmente abaixo do resultado obtido com a metodologia de RIEMANN.

Método	Acurácia	Parâmetros e Janelas em Minutos								
		SDNN	LF	HF	SVI	CSI	CVI	DFH	SampEn	λ
RIEMANN	86%		3	3	3	3		3	3	
SVMEVECS	82%	2		3	3	2	3		1	
SINGLEWo	75%	5	5	5		5		5		5

Tabela 5.3: **Acurácia em marcações manuais** - A acurácia de cada método utilizado para classificação, RIEMANN, SVMEVECS e SINGLEWo é mostrada junto com os parâmetros utilizados e as respectivas janelas em minutos para cada parâmetro (**SDNN** - Desvio Padrão dos Intervalos de RR, **LF** - Baixa Frequência de 0.004 a 0.15 Hz, **HF** - Alta Frequência de 0.15 a 0.4 Hz, **SVI** - $\frac{LF}{HF}$, **CSI** - Índice Cardiosimpático, **CVI** - Índice Cardiovascular, **DFH** - Dimensão Fractal de Higuchi, **SampEn** - Entropia Amostral, λ - Maior Expoente de Lyapunov). Para os casos de janela deslizante, foram utilizados 20 passos de 10 segundos cada, com o primeiro passo sendo o próprio instante de interesse, totalizando 20 amostras temporais para cada parâmetro. Foram utilizados 54 eventos, 18, 14 e 22 de baixo, médio e alto estresse respectivamente, divididos em treinamento e validação

Número de passos	Passo em segundos			
	2,5	5,0	7,5	10,0
10	65%	80%	78%	68%
15	67%	76%	70%	77%
20	79%	66%	79%	86%

Tabela 5.4: **Número de passos e passos em segundos** - Com a configuração da Tabela 5.3 para RIEMANN são mostradas as acurácias para diferentes passos e diferentes números de passos da janela deslizante.

Além disso, pode-se notar que há uma predominância da utilização dos parâmetros frequenciais, junto do parâmetro não-linear CSI, coerente com as análises de distribuição realizadas anteriormente, já que esses parâmetros fornecem uma maior separabilidade, considerando apenas valores estáticos e não a sua dinâmica.

Para obter esses resultados, foram utilizados 54 eventos, dos quais 18 são de baixo estresse, 14 de médio estresse e 22 de alto estresse, divididos igualmente em conjunto de treinamento e de validação, totalizando 27 amostras para cada.

Para escolher esses valores de passo e número de passos, foram realizadas diversas simulações de modelos, fixando os parâmetros e variando passo e número de passo.

Um exemplo das simulações para a escolha de passo e número de passos é ilustrado na Tabela 5.4, onde foram testados passos de 2,5, 5,0, 7,5 e 10,0 segundos com números de passos de 10, 15 e 20. Esse resultado de uma maior acurácia com valores crescentes de passo e número de passo são esperados, já que com um passo maior as amostras agregam mais informação e possuem mais independência entre si e, com um número de passos maior, mais amostras são usadas para construir a matriz de covariância, resultando em uma maior precisão na estimação, conforme é discutido em [51].

A seguir, os modelos foram simulados e testados nas marcações de eventos fornecidas pelo próprio banco de dados. A Tabela 5.5 apresenta os melhores resultados obtidos considerando todos os sujeitos, com um total de 50 eventos, 8, 17 e 25 de nível baixo, médio e alto respectivamente.

Mesmo com a melhor configuração simulada, a estratégia de RIEMANN demonstrou a pior acurácia entre os três métodos usados, justificado pelo pouco número de exemplos da classe de baixo estresse e pela dúvida em relação aos eventos fornecidos serem realmente da classe do evento marcado. O resultado utilizando SVMEVECS mostrou-se o mais robusto para esse conjunto de dados com sujeitos em estados duvidosos, mas que ainda assim necessitaria de um conjunto de dados com mais exemplos e com um número de exemplos por classe equilibrado para chegar a alguma conclusão.

Com a informação de que alguns sujeitos podem não estar seguindo o padrão dos eventos, observado nas análises de quartis, optou-se pela remoção dos motoristas 7, 10 e 12 para realizar mais simulações. Sem a presença desses motoristas foram usadas 6, 11 e 18 amostras para os níveis de estresse baixo, médio e alto respectivamente, totalizando 44 eventos.

A Tabela 5.6 ilustra os resultados dessa remoção para as três metodologias utilizadas. É possível notar novamente que as metodologias com a construção da matriz de covariância, RIEMANN e SVMEVECS, superam a metodologia de apenas uma janela SINGLEWo, mas nesse caso com uma leve diferença apenas. É possível notar também a redução de janelas e parâmetros utilizadas neste caso em comparação com o conjunto de dados marcado, ilustrado pela Tabela 5.3.

Esses resultados, removendo os sujeitos se aproximam de resultados

Método	Acurácia	Parâmetros e Janelas em Minutos								
		SDNN	LF	HF	SVI	CSI	CVI	DFH	SampEn	λ
RIEMANN	64%		3	3	3	3		2	2	2
SVMEVECS	72%	3	3		3	2	3			
SINGLEWo	66%	5		5	5			5	5	5

Tabela 5.5: **Acurácia em marcações fornecidas** - A acurácia de cada método utilizado para classificação, RIEMANN, SVMEVECS e SINGLEWo é mostrada junto com os parâmetros utilizados e as respectivas janelas em minutos para cada parâmetro (**SDNN** - Desvio Padrão dos Intervalos de RR, **LF** - Baixa Frequência de 0.004 a 0.15 Hz, **HF** - Alta Frequência de 0.15 a 0.4 Hz, **SVI** - $\frac{LF}{HF}$, **CSI** - Índice Cardiosimpático, **CH** - Complexidade de Hjorth, **DFH** - Dimensão Fractal de Higuchi, **SampEn** - Entropia Amostrada). Para os casos de janela deslizante, foram utilizados 20 passos de 10 segundos cada, com o primeiro passo sendo o próprio instante de interesse, totalizando 20 amostras temporais para cada parâmetro. Foram utilizados 44 eventos, 6, 11 e 18 de baixo, médio e alto estresse respectivamente, divididos em treinamento e validação

apresentados em [36], onde foi obtido uma acurácia de 83,33% através de parâmetros temporais e não-lineares aplicados a um classificador SVM com base radial na mesma base de dados.

Método	Acurácia	Parâmetros e Janelas em Minutos							
		SDNN	LF	HF	SVI	CSI	CH	DFH	SampEn
RIEMANN	77%		3			1		1	2
SVMEVECS	77%	1	3	3		2		1	
SINGLEWo	75%			5	5	5	5	5	

Tabela 5.6: **Acurácia em marcações fornecidas sem M7, M10, M12** - A acurácia de cada método utilizado para classificação, RIEMANN, SVMEVECS e SINGLEWo é mostrada junto com os parâmetros utilizados e as respectivas janelas em minutos para cada parâmetro (**SDNN** - Desvio Padrão dos Intervalos de RR, **LF** - Baixa Frequência de 0.004 a 0.15 Hz, **HF** - Alta Frequência de 0.15 a 0.4 Hz, **SVI** - $\frac{LF}{HF}$, **CSI** - Índice Cardiosimpático, **CVI** - Índice Cardiovagal, **DFH** - Dimensão Fractal de Higuchi, **SampEn** - Entropia Amostral, λ - Maior Expoente de Lyapunov). Para os casos de janela deslizante, foram utilizados 20 passos de 10 segundos cada, com o primeiro passo sendo o próprio instante de interesse, totalizando 20 amostras temporais para cada parâmetro. Foram utilizados 50 eventos, 8, 17 e 25 de baixo, médio e alto estresse respectivamente, divididos em treinamento e validação

CAPÍTULO 6

Considerações Finais

Este trabalho apresentou todo o processo de utilização de um sinal de ECG para o cálculo de parâmetros de variabilidade, fazendo a detecção de ondas R através da transformada Wavelet e, finalmente a classificação de níveis de stress com uma metodologia diferente. Essa metodologia, diferente de outros trabalhos que tem também o intuito de classificar níveis de stress através do sinal de ECG, considera a dinâmica dos parâmetros, temporais, frequenciais e não-lineares, extraídos do sinal de variabilidade cardíaca.

Além disso, foram utilizadas métricas de Riemann para classificação, abordagem até então não encontrada na literatura para a classificação de níveis de stress a partir de sinais de ECG.

Essa metodologia proposta foi aplicada em um conjunto de dados manualmente selecionado a partir da base de dados aberta [24], levando em consideração o equilíbrio do mesmo número de eventos para cada classe e incluindo apenas pedaços de sinais que seguissem o padrão do devido estado. Foram utilizados 54 eventos de exemplo, metade para treinamento e a outra para validação num total de 9 sujeitos.

Ao aplicar a metodologia, foram obtidas acurácias melhores do que a metodologia padrão, onde não é levada em consideração a dinâmica

dos parâmetros de variabilidade. Para o classificador baseado em métricas de Riemann, foi obtida uma acurácia de 86%, comparada a 82% do classificador SVM que recebe como entrada o autovetor mais significativo da matriz de covariância e valores médios dos parâmetros usados. Já a metodologia de calcular apenas um parâmetro para uma janela de 5 minutos, como é feito em [24] e [65], obteve uma acurácia de 75%.

Para as marcações fornecidas pelo próprio banco de dados [24], foram obtidas acurácias significantes apenas depois da remoção de sujeitos que não seguiam o padrão dos parâmetros de variabilidade dentro da janela do evento a ser analisado. Por exemplo, um desses sujeitos (M12) apresentou uma redução do parâmetro CSI (Índice Cardiosimpático), que reflete a atividade simpática, a medida que o nível de estresse aumenta, contrário do esperado. Essas acurácias foram de 77% para a metodologia proposta, tanto com Riemann quanto com SVM e 75% para a abordagem clássica. No entanto, esse resultado não é muito confiável já que houve um desequilíbrio entre o número de exemplos de cada classe e não foi levado em consideração que cada sujeito pode apresentar diversos níveis diferentes de estresse ao longo de uma janela de 10 minutos ao estar realizando uma tarefa não tão específica como a de dirigir.

Em relação a estratégia com métricas não-euclidianas em matrizes de covariância, foi possível constatar que a informação de dinâmica temporal e de relação entre parâmetros ao longo do tempo fornece bastante informação para a tomada de decisão do classificador.

Essa metodologia pode ser utilizada em sistemas de medição de estresse contínuo, fornecendo informações valiosas para que o usuário tenha controle sobre o nível de estresse a longo prazo, evitando diversas consequências de um constante estado de alto estresse. Algumas soluções de identificação de estresse já estão disponíveis no mercado, mas geralmente são utilizados sinais de PPG (Fotoplestimografia), que fornecem um erro maior na estimação da variabilidade e os que utilizam ECG não mencionam a utilização da dinâmica de parâmetros de variabilidade.

6.1 Trabalhos Futuros

O primeiro próximo passo natural deste trabalho seria fazer a mesma comparação de metodologias aplicada em um conjunto de dados maior, com mais exemplos de cada classe e com mais sujeitos. Um experimento interessante seria controlar o nível de cortisol em um experimento como o proposto em [27], disponibilizando o conjunto de dados para a comunidade, como em [24].

Outra consideração muito interessante a se fazer em relação ao conjunto de dados seria a de levar em conta a idade e gênero dos sujeitos, já que cada um tem a sua resposta em relação ao estresse [27]. Considerando essa diferenciação entre sujeitos, seria ideal também realizar uma normalização para cada sujeito separadamente, conforme o seu nível basal de estresse.

Em relação a melhoras na metodologia proposta, uma interessante abordagem seria a utilização da combinação de SVM com métricas não-euclidianas, onde cada matriz seria um ponto e o algoritmo de otimização do classificador SVM utilizaria distâncias de Riemann. Além disso, é possível obter uma melhora na estimação das matrizes de covariância através de métodos mais robustos de estimação, como descrito em [51].

Para este trabalho foram utilizados alguns valores padrões no cálculo de parâmetros não-lineares. Uma forma de melhorar ainda mais o classificador seria explorar ao máximo todos os graus de liberdade fornecidos pelos parâmetros não-lineares.

Finalmente, uma metodologia que poderia ser agregada a proposta é a abordada em [65], onde são apresentados estágios de classificação binária. Com a combinação da dinâmica dos parâmetros de variabilidade fornecida a estágios de SVM com métricas de Riemann em matrizes de covariância é possível granularizar ainda mais os níveis de estresse, podendo estabelecer uma escala.

Referências

- [1] R. Acharya, N. Kannathal, and S. Krishnan. Comprehensive analysis of cardiac health using heart rate signals. *Physiological measurement*, 25(5):1139, 2004.
- [2] R. Acharya, N. Kannathal, O. W. Sing, L. Y. Ping, and T. Chua. Heart rate analysis in normal subjects of various age groups. *Bio-medical engineering online*, 3(1):24, 2004.
- [3] M. Akay. *Detection and estimation methods for biomedical signals*. Academic Press, Inc., 1996.
- [4] N. American Psychological Association, American Institute of Stress. 2014 Stress Statistics, year = 2014, url = <https://www.stress.org/about/for-the-media/ais-press-kit/>, url-date = 2014-08-07.
- [5] A. Barachant, A. Andreev, M. Congedo, et al. The riemannian potato: an automatic and adaptive artifact detection method for online experiments using riemannian geometry. In *Proceedings of TOBI Workshop IV*, pages 19–20, 2013.
- [6] A. Barachant, S. Bonnet, M. Congedo, and C. Jutten. Riemannian geometry applied to bci classification. In *Latent Variable Analysis and Signal Separation*, pages 629–636. Springer, 2010.

- [7] A. Barachant, S. Bonnet, M. Congedo, and C. Jutten. Multiclass brain-computer interface classification by riemannian geometry. *Biomedical Engineering, IEEE Transactions on*, 59(4):920–928, 2012.
- [8] A. Barachant, S. Bonnet, M. Congedo, and C. Jutten. Classification of covariance matrices using a riemannian-based kernel for bci applications. *Neurocomputing*, 112:172–178, 2013.
- [9] C. M. Bishop. *Pattern recognition and machine learning*. springer, 2006.
- [10] S. Boonnithi and S. Phongsuphap. Comparison of heart rate variability measures for mental stress detection. In *Computing in Cardiology, 2011*, pages 85–88. IEEE, 2011.
- [11] G. P. Chrousos and P. W. Gold. The concepts of stress and stress system disorders: overview of physical and behavioral homeostasis. *Jama*, 267(9):1244–1252, 1992.
- [12] G. D. Clifford. *Signal Processing Methods For Heart Rate Variability Analysis*. PhD thesis, University of Oxford, 2002.
- [13] S. Cohen, T. Kamarck, and R. Mermelstein. A global measure of perceived stress. *Journal of health and social behavior*, pages 385–396, 1983.
- [14] M. Congedo, A. Barachant, and R. Bhatia. Riemannian geometry for eeg-based brain-computer interfaces; a primer and a review. *Brain-Computer Interfaces*, pages 1–20, 2017.
- [15] C. de Moura Costa, U. Govinda, and C. D. M. Regis. Detecção dos principais pontos no sinal de ecg para identificação do iam por meio do processamento digital do eletrocardiograma. *Revista de Tecnologia da Informação e Comunicação*, 6(1):15–20, 2016.
- [16] J. E. Dise-Lewis. The life events and coping inventory: an assessment of stress in children. *Psychosomatic medicine*, 50(5):484–499, 1988.
- [17] W. Förstner and B. Moonen. A metric for covariance matrices. In *Geodesy-The Challenge of the 3rd Millennium*, pages 299–309. Springer, 2003.

- [18] K. Fukunaga. *Introduction to statistical pattern recognition*. Academic press, 2013.
- [19] S. Gandhi, M. S. Baghini, and S. Mukherji. Mental stress assessment—a comparison between hrv based and respiration based techniques. In *Computing in Cardiology Conference (CinC), 2015*, pages 1029–1032. IEEE, 2015.
- [20] H.-W. Guo, Y.-S. Huang, C.-H. Lin, J.-C. Chien, K. Haraikawa, and J.-S. Shieh. Heart rate variability signal features for emotion recognition by using principal component analysis and support vectors machine. In *Bioinformatics and Bioengineering (BIBE), 2016 IEEE 16th International Conference on*, pages 274–277. IEEE, 2016.
- [21] H.-W. Guo, Y.-S. Huang, C.-H. Lin, J.-C. Chien, K. Haraikawa, and J.-S. Shieh. Heart rate variability signal features for emotion recognition by using principal component analysis and support vectors machine. In *Bioinformatics and Bioengineering (BIBE), 2016 IEEE 16th International Conference on*, pages 274–277. IEEE, 2016.
- [22] F. Gustafsson. Determining the initial states in forward-backward filtering. *IEEE Transactions on Signal Processing*, 44(4):988–992, 1996.
- [23] P. S. Hamilton and W. J. Tompkins. Quantitative investigation of qrs detection rules using the mit/bih arrhythmia database. *IEEE transactions on biomedical engineering*, (12):1157–1165, 1986.
- [24] J. A. Healey and R. W. Picard. Detecting stress during real-world driving tasks using physiological sensors. *IEEE Transactions on intelligent transportation systems*, 6(2):156–166, 2005.
- [25] T. Higuchi. Approach to an irregular time series on the basis of the fractal theory. *Physica D: Nonlinear Phenomena*, 31(2):277 – 283, 1988.
- [26] B. Hjorth. Eeg analysis based on time domain properties. *Electroencephalography and Clinical Neurophysiology*, 29(3):306 – 310, 1970.

- [27] C. Kirschbaum, K.-M. Pirke, and D. H. Hellhammer. The ‘trier social stress test’—a tool for investigating psychobiological stress responses in a laboratory setting. *Neuropsychobiology*, 28(1-2):76–81, 1993.
- [28] K. B. Koh, J. K. Park, C. H. Kim, and S. Cho. Development of the stress response inventory and its application in clinical practice. *Psychosomatic medicine*, 63(4):668–678, 2001.
- [29] M. Kumar, M. Weippert, R. Vilbrandt, S. Kreuzfeld, and R. Stoll. Fuzzy evaluation of heart rate signals for mental stress assessment. *IEEE transactions on fuzzy systems*, 15(5):791–808, 2007.
- [30] C. D. B. Luft, S. d. O. Sanches, G. Z. Mazo, and A. Andrade. Brazilian version of the perceived stress scale: translation and validation for the elderly. *Revista de saúde pública*, 41(4):606–615, 2007.
- [31] M. S. Manikandan and K. Soman. A novel method for detecting r-peaks in electrocardiogram (ecg) signal. *Biomedical Signal Processing and Control*, 7(2):118–128, 2012.
- [32] M. M. Massin, B. Derkenne, and G. von Bernuth. Correlations between indices of heart rate variability in healthy children and children with congenital heart disease. *Cardiology*, 91(2):109–113, 1999.
- [33] J. E. Mietus, C.-K. Peng, I. Henry, R. L. Goldsmith, and A. L. Goldberger. The pnnx files: re-examining a widely used heart rate variability measure. *Heart*, 88(4):378–380, 2002.
- [34] M. Moakher. A differential geometric approach to the geometric mean of symmetric positive-definite matrices. *SIAM Journal on Matrix Analysis and Applications*, 26(3):735–747, 2005.
- [35] G. B. Moody and R. G. Mark. The impact of the mit-bih arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3):45–50, 2001.
- [36] N. Munla, M. Khalil, A. Shahin, and A. Mourad. Driver stress level detection using hrv analysis. In *Advances in Biomedical Enginee-*

- ring (ICABME)*, 2015 International Conference on, pages 61–64. IEEE, 2015.
- [37] S. Negi, C. S. Kumar, and A. A. Kumar. Feature normalization for enhancing early detection of cardiac disorders. In *India Conference (INDICON), 2016 IEEE Annual*, pages 1–5. IEEE, 2016.
- [38] H. Otzenberger, C. Gronfier, C. Simon, A. Charloux, J. Ehrhart, F. Piquard, and G. Brandenberger. Dynamic heart rate variability: a tool for exploring sympathovagal balance continuously during sleep in men. *American Journal of Physiology-Heart and Circulatory Physiology*, 275(3):H946–H950, 1998.
- [39] V. Palodeto et al. Sistema computacional para o processamento, a análise e a classificação do sinal eletrocardiográfico de neonatos e adultos. 2006.
- [40] J. Pavei, R. G. Heinzen, B. Novakova, R. Walz, A. J. Serra, M. Reuber, A. Ponnusamy, and J. L. Marques. Early seizure detection based on cardiac autonomic regulation dynamics. *Frontiers in Physiology*, 8:765, 2017.
- [41] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, et al. Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12(Oct):2825–2830, 2011.
- [42] A. Ponnusamy, J. L. Marques, and M. Reuber. Heart rate variability measures as biomarkers in patients with psychogenic nonepileptic seizures: Potential and limitations. *Epilepsy & Behavior*, 22(4):685 – 691, 2011.
- [43] A. Ponnusamy, J. L. Marques, and M. Reuber. Comparison of heart rate variability parameters during complex partial seizures and psychogenic nonepileptic seizures. *Epilepsia*, 53(8):1314–1321, 2012.
- [44] S. A. Pramanta, A. S. Prihatmanto, and M.-G. Park. A study on the stress identification using observed heart beat data. In *Frontiers of Information Technology (FIT), 2016 International Conference on*, pages 149–152. IEEE, 2016.

- [45] H. H. Publishing. Understanding the Stress Response, year = 2016, url = <https://www.health.harvard.edu/staying-healthy/understanding-the-stress-response>, urldate = 2016-03-18.
- [46] U. Rajendra Acharya, K. Paul Joseph, N. Kannathal, C. Lim, and J. Suri. Heart rate variability: a review. *Medical and Biological Engineering and Computing*, 44:1031–1051, 2006.
- [47] H. rate variability. Standards of measurement, physiological interpretation, and clinical use. task force of the european society of cardiology and the north american society of pacing and electrophysiology. *Circulation*, 93:1043–1065, 1996.
- [48] J. S. Richman and J. R. Moorman. Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology - Heart and Circulatory Physiology*, 278(6):H2039–H2049, 2000.
- [49] M. T. Rosenstein, J. J. Collins, and C. J. De Luca. A practical method for calculating largest lyapunov exponents from small data sets. *Physica D: Nonlinear Phenomena*, 65(1-2):117–134, 1993.
- [50] D. Sadhukhan and M. Mitra. R-peak detection algorithm for ecg using double difference and rr interval processing. *Procedia Technology*, 4:873–877, 2012.
- [51] J. Schäfer and K. Strimmer. A shrinkage approach to large-scale covariance matrix estimation and implications for functional genomics. *Statistical applications in genetics and molecular biology*, 4(1), 2005.
- [52] B. Schölkopf and A. J. Smola. *Learning with kernels: support vector machines, regularization, optimization, and beyond*. MIT press, 2002.
- [53] M. Sifuzzaman, M. Islam, and M. Ali. Application of wavelet transform and its advantages compared to fourier transform. 2009.
- [54] C. Silva, R. Duarte, R. Goulart, and A. Trofino. Towards a lmi approach to feature extraction improvements and classification by riemann distance. In *Control and Automation (ICCA), 2016 12th IEEE International Conference on*, pages 990–995. IEEE, 2016.

- [55] D. Silverthorn. *Fisiologia Humana: Uma Abordagem Integrada*. Artmed, 2010.
- [56] A. J. Smola and B. Schölkopf. A tutorial on support vector regression. *Statistics and computing*, 14(3):199–222, 2004.
- [57] A. I. R. Soler. *Impact of artifact correction methods on RR inter-beat signals to quantifying heart rate variability (HRV) according to linear and nonlinear methods*. PhD thesis, Universidade de São Paulo, 2016.
- [58] M. P. Tarvainen, J.-P. Niskanen, J. A. Lipponen, P. O. Ranta-Aho, and P. A. Karjalainen. Kubios hrv—heart rate variability analysis software. *Computer methods and programs in biomedicine*, 113(1):210–220, 2014.
- [59] B. S. Tavares, G. Paula Vidigal, D. M. Garner, R. D. Raimundo, L. C. Abreu, and V. E. Valenti. Effects of guided breath exercise on complex behaviour of heart rate dynamics. *Clinical physiology and functional imaging*, 37(6):622–629, 2017.
- [60] M. Toichi, T. Sugiura, T. Murai, and A. Sengoku. A new method of assessing cardiac autonomic function and its comparison with spectral analysis and coefficient of variation of r–r interval. *Journal of the autonomic nervous system*, 62(1):79–84, 1997.
- [61] K. Umetani, D. H. Singer, R. McCraty, and M. Atkinson. Twenty-four hour time domain heart rate variability and heart rate: relations to age and gender over nine decades. *Journal of the American College of Cardiology*, 31(3):593–601, 1998.
- [62] G. Valenza, L. Citi, and R. Barbieri. Estimation of instantaneous complex dynamics through lyapunov exponents: a study on heartbeat dynamics. *PloS one*, 9(8):e105622, 2014.
- [63] G. Valenza, M. Nardelli, A. Lanata, C. Gentili, G. Bertschy, R. Paradiso, and E. P. Scilingo. Wearable monitoring for mood recognition in bipolar disorder based on history-dependent long-term heart rate variability analysis. *IEEE Journal of Biomedical and Health Informatics*, 18(5):1625–1635, 2014.

- [64] N. S. Valke and B. Karthikeyan. Development of classification algorithm for epileptic seizures using electrocardiogram signal. In *India Conference (INDICON), 2016 IEEE Annual*, pages 1–6. IEEE, 2016.
- [65] L. Vanitha and G. Suresh. Hierarchical svm to detect mental stress in human beings using heart rate variability. In *Devices, Circuits and Systems (ICDCS), 2014 2nd International Conference on*, pages 1–5. IEEE, 2014.
- [66] L. Vanitha and G. Suresh. Hierarchical svm to detect mental stress in human beings using heart rate variability. In *Devices, Circuits and Systems (ICDCS), 2014 2nd International Conference on*, pages 1–5. IEEE, 2014.
- [67] E. Won and Y.-K. Kim. Stress, the autonomic nervous system, and the immune-kynurenine pathway in the etiology of depression. *Current neuropharmacology*, 14(7):665–673, 2016.
- [68] E. Won and Y.-K. Kim. Stress, the autonomic nervous system, and the immune-kynurenine pathway in the etiology of depression. *Current neuropharmacology*, 14(7):665–673, 2016.
- [69] S.-N. Yu and S.-F. Chen. Emotion state identification based on heart rate variability and genetic algorithm. In *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, pages 538–541. IEEE, 2015.
- [70] Y. J. Yu, Z. Yang, B.-S. oh, Y. K. Yeo, Q. Liu, G.-B. Huang, and Z. Lin. Investigation on driver stress utilizing ecg signals with on-board navigation systems in use. pages 1–6, 11 2016.