



TRABALHO DE CONCLUSÃO DE CURSO

Detecção de Doenças Usando Smartwatches

Heitor de Melo Cardozo

Thiago Sales Vilela

Brasília, Novembro de 2021

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA

UNIVERSIDADE DE BRASÍLIA
Faculdade de Tecnologia

TRABALHO DE CONCLUSÃO DE CURSO
Detecção de Doenças Usando Smartwatches

Heitor de Melo Cardozo
Thiago Sales Vilela

*Trabalho de conclusão de curso submetido ao Departamento de Engenharia
Elétrica como requisito parcial para obtenção
do grau de Engenheiro de Redes de Comunicação*

Banca Examinadora

Prof. Eduardo Peixoto Fernandes da Silva, _____
ENE/UnB
Orientador

Prof. Adson Ferreira da Rocha, ENE/UnB _____
Examinador Interno

Prof. Daniel Guerreiro e Silva, ENE/UnB _____
Examinador Interno

FICHA CATALOGRÁFICA

CARDOZO, HEITOR DE MELO; VILELA, THIAGO SALES

Detecção de Doenças Usando Smartwatches [Distrito Federal] 2021.

xvi, 60 p., 210 x 297 mm (ENE/FT/UnB, Engenheiro, Engenharia Elétrica, 2021).

Trabalho de conclusão de curso - Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Elétrica

1. RHR

2. SmartWatches

3. Python

4. COVID-19

I. ENE/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

CARDOZO, H. M.; VILELA, T. S. (2021). *Detecção de Doenças Usando Smartwatches*. Trabalho de conclusão de curso, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 60 p.

CESSÃO DE DIREITOS

AUTOR 1: Heitor de Melo Cardozo

AUTOR 2: Thiago Sales Vilela

TÍTULO: Detecção de Doenças Usando Smartwatches.

GRAU: Engenheiro de Redes de Comunicação ANO: 2021

É concedida à Universidade de Brasília permissão para reproduzir cópias deste Trabalho de conclusão de curso e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. Os autores reservam outros direitos de publicação e nenhuma parte desse Trabalho de conclusão de curso pode ser reproduzida sem autorização por escrito dos autores.

Heitor de Melo Cardoso

Depto. de Engenharia Elétrica (ENE) - FT

Universidade de Brasília

Campus Darcy Ribeiro

CEP 70919-970 - Brasília - DF - Brasil

Thiago Sales Vilela

Depto. de Engenharia Elétrica (ENE) - FT

Universidade de Brasília

Campus Darcy Ribeiro

CEP 70919-970 - Brasília - DF - Brasil

Agradecimentos

Primeiramente, agradeço à minha mãe, Rosimary de Melo, por me guiar com sabedoria, acreditar nas minhas escolhas e prover tudo que um ser humano precisa para viver. agradeço ao meu pai, Jorge Roberto Cardozo, por ter me proporcionado uma infraestrutura adequada para os estudos e por nunca ter deixado faltar algo em casa. Agradeço também aos meus irmãos e tios que mantiveram o meu bom humor e o alto astral, mesmo nos momentos difíceis. Agradeço à minha namorada Beatriz por não ter me deixado largar a rede, além de ser muito compreensiva, amorosa e paciente com todas as vezes que precisei estudar ou virar a noite. Também sou extremamente grato aos meus três grandiosos amigos que fiz no curso e estiveram ao meu lado desde o primeiro dia de aula: Hítalo, Larika e Valdin. Enfrentamos vários dias difíceis e sem eles eu não seria capaz de concluir a graduação. Gostaria de agradecer à todos meus amigos do grupo "telesap" em ordem alfabética: Bel, Dialgo, Fu, Guto, Igão, Litchi, Rodrigão, Rori, Senai e Vitinho. Vocês me acompanharam, aconselharam e me inspiraram desde a escolha do curso até o final, especialmente Vitinho. Por fim e não menos importante, agradeço ao Professor Eduardo Peixoto por ter confiado e nos orientado nesse trabalho com toda atenção e dedicação. Agradeço também ao meu amigo e co-autor desse trabalho, Thiago, o seu empenho foi essencial para a conclusão do projeto.

Heitor de Melo Cardozo

Gostaria de agradecer aos meus pais Edevaldo Vilela e Flávia Christine Pires Sales por toda a orientação e suporte, minha família e amigos que sempre me apoiaram na trajetória acadêmica e em todos os meus planos. Agradeço também ao Professor Eduardo pela orientação, atenção e sabedoria nos conselhos. Sendo integrante fundamental para a realização deste trabalho, presto agradecimentos ao meu amigo Heitor pela parceria e dedicação.

Thiago Sales Vilela

SUMÁRIO

1	INTRODUÇÃO	3
1.1	MOTIVAÇÃO	3
1.2	OBJETIVO	4
1.3	ORGANIZAÇÃO DO TRABALHO	4
2	FUNDAMENTAÇÃO TEÓRICA	5
2.1	<i>Wearables</i>	5
2.1.1	DESENVOLVIMENTO DOS <i>Smartwatches</i>	5
2.1.2	SENSORES E DADOS	9
2.2	MONITORES CARDÍACOS	11
2.2.1	CONTEXTO HISTÓRICO	11
2.2.2	ELETROCARDIOGRAMA (ECG)	13
2.2.3	FOTOPLETISMOGRAFIA (PPG)	13
2.3	RESTING HEART RATE (RHR)	15
2.4	<i>Wearables</i> NA SAÚDE	16
2.4.1	RELAÇÃO DOS <i>Smartwatches</i> NO COVID-19	17
2.5	CONCLUSÕES ACERCA DO CAPÍTULO	18
3	TRABALHOS RELACIONADOS	19
3.1	<i>Smartwatches</i> NA MEDICINA	19
3.2	DETECÇÃO DE DOENÇAS	21
3.2.1	DETECÇÃO DO COVID-19	22
3.3	SÍNTESE	24
3.4	CONCLUSÕES ACERCA DO CAPÍTULO	25
4	METODOLOGIA	26
4.1	DELIMITAÇÃO DO ESCOPO	26
4.2	OBTENÇÃO DO BANCO DE DADOS	27
4.3	ANÁLISE E COMPREENSÃO DOS DADOS	28
4.4	IMPLEMENTAÇÃO DO ALGORITMO	31
4.4.1	ESCOLHA DA TECNOLOGIA	31
4.4.2	LIMPEZA DOS DADOS E CÁLCULO DO RHR	32
4.4.3	PRÉ-PROCESSAMENTO	33
4.4.4	CORREÇÃO SAZONAL	35
4.4.5	TREINAMENTO DO MODELO	36
4.5	CONCLUSÕES ACERCA DO CAPÍTULO	37

5	RESULTADOS	38
5.1	GRUPOS IDENTIFICADOS.....	39
5.2	ANÁLISE E DISCUSSÃO DOS RESULTADOS	40
5.3	CONCLUSÕES DO CAPÍTULO.....	51
6	CONCLUSÃO	52
6.1	TRABALHOS FUTUROS	53
	REFERÊNCIAS BIBLIOGRÁFICAS	54

LISTA DE FIGURAS

2.1	Os Primeiros <i>Smartwatches</i>	6
2.2	<i>IBM WatchPad</i>	6
2.3	Exemplos de <i>Wearables</i> focados em monitoração cardíaca.	7
2.4	Exemplos de <i>Smartwatches</i> : <i>Palm Fossil Wrist PDA e Microsoft SPOT</i>	7
2.5	Exemplos de <i>Smartwatches</i> : <i>Samsung S9110 e Apple Watch 1</i>	8
2.6	Exemplos de <i>smartbands</i> atuais.....	8
2.7	<i>Smartwatches</i> mais vendidos.	10
2.8	O primeiro eletrocardiograma elétrico	11
2.9	Exemplo de caso do <i>Holter</i>	12
2.10	Exemplo de monitor ECG	13
2.11	Exemplo de monitor PPG	14
2.12	Sinal simplificado do PPG	14
2.13	Modos de operação do monitor PPG	15
4.1	Fluxograma do sistema.....	26
4.2	Exemplo do <i>dataset</i> referente à frequência cardíaca.	28
4.3	Exemplo do <i>dataset</i> referente à quantidade de passos.	28
4.4	Exemplo das médias de frequência cardíaca e passos ao longo do tempo	29
4.5	Exemplo de parâmetros estatísticos da frequência cardíaca.....	30
4.6	Exemplo de parâmetros estatísticos da quantidade de passos	30
4.7	Fluxograma do algoritmo.....	31
4.8	Exemplo de RHR bruto	32
4.9	Exemplo de parâmetros estatísticos do RHR bruto	33
4.10	Exemplo do RHR pré-processado	34
4.11	Exemplo dos parâmetros estatísticos do RHR pré-processamento.	34
4.13	Exemplo do RHR após a correção sazonal	36
4.14	Exemplo dos parâmetros estatísticos do RHR pré-processamento.	36
4.15	Exemplo do envelope elíptico	37
5.1	Exemplo do compilado de alertas emitidos para um indivíduo.....	38
5.2	Anomalias RHR do indivíduo A0VFT1N	41
5.3	Anomalias RHR do indivíduo A3OU183.....	42
5.4	Anomalias RHR do indivíduo A4G0044	43
5.5	Anomalias RHR do indivíduo AOYM4KG	44
5.6	Anomalias RHR do indivíduo AA2KP1S	45
5.7	Anomalias RHR do indivíduo AKXN5ZZ	46
5.8	Anomalias RHR do indivíduo APGIB2T.....	47
5.9	Anomalias RHR do indivíduo AS2MVDL.....	48

5.10 Anomalias RHR do indivíduo AURCTAK.....	49
5.11 Anomalias RHR do indivíduo AYWIEKR.....	50

LISTA DE TABELAS

2.1	Sensores comuns e dados coletados.....	9
2.2	Smartwatches mais populares e seus respectivos sensores	10
3.1	Catálogo dos artigos	25
5.1	Identificação dos tipos de alerta emitidos pelo algoritmo.....	38
5.2	Indivíduos com alterações fisiológicas detectadas pelo algoritmo.....	39
5.3	Casos com alterações fisiológicas detectadas e informações de sintomas	39
5.4	Casos detectados antes de apresentar sintomas	40

LIST OF ACRONYMS

COVID	<i>Corona Virus Disease</i>
CSV	<i>Comma-separated-values</i>
ECG	<i>Electrocardiogram</i>
GPS	<i>Global Positioning System</i>
HROS	<i>Heart Rate Over Steps</i>
IOT	<i>Internet Of Things</i>
OMS	<i>Organização Mundial de Saúde</i>
PPG	<i>Photoplethysmogram</i>
RHR	<i>Resting Heart Rate</i>

O presente trabalho buscou analisar e explorar o mundo dos *wearables*, mais especificamente os *smartwatches*, os quais têm ganhado o mercado nos últimos anos, e relacionar esses dispositivos com o cuidado à saúde humana. É possível observar que a interação entre a medicina e a engenharia tem proporcionado grandes avanços para o conhecimento humano, no que diz respeito à saúde. Um exemplo dessa parceria é o eletrocardiograma, que permite a monitoração em tempo real dos batimentos cardíacos, além de fornecer valiosos dados fisiológicos que auxiliam na detecção de doenças. Esses dados se popularizaram graças aos *wearables*, os quais ganharam destaque após a diminuição dos processadores e barateamento dos componentes eletrônicos, possibilitando a criação de sensores de alta precisão.

Os *smartwatches* têm sido cada vez mais utilizados por profissionais na área da saúde para detectar e monitorar doenças. Em razão do acompanhamento contínuo e em tempo real dos sinais vitais, além de fornecer dados biométricos de boa precisão. Analisando esse contexto, este trabalho apresenta um panorama geral de artigos e um estudo de caso sobre os *smartwatches* na área da saúde.

Tendo vista o contexto internacional com a pandemia do COVID-19, o presente trabalho tem como objetivo realizar um estudo de caso sobre o artigo “Pre-symptomatic detection of COVID-19 from smartwatch data”. Neste artigo é colocado que a frequência cardíaca em repouso tem comportamento direto com alterações fisiológicas, podendo auxiliar de forma considerável a detecção de infecções respiratórias como COVID-19. Por fim, será apresentada a implementação de um algoritmo não supervisionado em *Python* que detecta anomalias na frequência cardíaca em repouso, indicando uma possível infecção.

ABSTRACT

This work aims to analyze and explore the world of wearables, specifically the smartwatches, which have been gaining market share in recent years, and relate these devices to human health care. It is possible to observe that the interaction between medicine and engineering has provided great advances for human knowledge, as far as health is concerned. An example of this partnership is the electrocardiogram, which allows real-time monitoring of the heartbeat and provides valuable physiological data to help detect diseases. This data has become popular thanks to wearables, which have gained prominence after the shrinking of processors and the cheapening of electronic components, enabling the creation of high-precision sensors.

Smartwatches have been increasingly used by healthcare professionals to detect and monitor diseases. Due to the continuous and real-time monitoring of vital signs and to provide biometric data with good accuracy. Analyzing this context, this work presents an overview of articles and a case study on smartwatches in healthcare.

Considering the international context with the COVID-19 pandemic, this work aims to perform a case study on the article "Pre-symptomatic detection of COVID-19 from smartwatch data". The work claims that resting heart rate has direct behavior with physiological changes, and can considerably aid the detection of respiratory infections such as COVID-19. Finally, the implementation of an unsupervised algorithm in Python for anomaly detection in resting heart rate, indicating a possible infection, will be presented in this work

1 INTRODUÇÃO

A área da saúde utiliza há muito tempo equipamentos para monitorar sinais fisiológicos, como por exemplo a frequência cardíaca, a fim de diagnosticar doenças e prevenir fatalidades. Paralelamente a isso tem se observado a popularização de dispositivos vestíveis com capacidade de monitoramento de sinais vitais [1]. As pesquisas que utilizam *smartwatches* para detectar doenças são recentes, porém já disponibilizam diversas possibilidades, dentre elas: comunicação bi-direcional entre profissionais da saúde e familiares de pacientes; *feedback* baseado em monitoramento e avaliação do comportamento de pacientes *in-loco*. Todas as atividades citadas tem um potencial muito grande de auxiliar na saúde [2].

1.1 MOTIVAÇÃO

A engenharia tem sido utilizada em conjunto com diferentes disciplinas com o intuito de fornecer soluções ao decorrer da história humana. Em particular, a medicina se beneficia dessa cooperação com a engenharia, uma vez que diversos aparelhos desenvolvidos auxiliaram no diagnóstico e tratamento de doenças, revolucionando os conhecimentos acerca da saúde humana. O eletrocardiograma e a máquina de ressonância magnética são exemplos de ferramentas produzidas dessa parceria.

Graças ao avanço global da tecnologia, é possível encontrar dispositivos com sensores que monitoram em tempo real informações fisiológicas de forma precisa. Esses dispositivos são conhecidos como *wearables* (vestíveis, em tradução livre) e exibem dados em tempo real nos *smartwatches* (relógios inteligentes), *smartbands* (pulseiras inteligentes) e *smartphones*. Cientistas e médicos enxergaram nesses dispositivos uma oportunidade de integração com a área da saúde, uma vez que são amplamente utilizados e fazem monitorações de maneira não invasiva. Estudos mostram que os *smartwatches* já estão sendo utilizados para monitoramento de idosos, diagnosticar doenças cardíacas e infecções respiratórias.

O início de 2020 é caracterizado por um surto global causado pelo COVID-19. O vírus possui alta infectividade e é difícil de diagnosticar pois os sintomas apresentados são genéricos e frequentes em outras infecções respiratórias, além de haver casos sem sintomas. Porém, o vírus pode causar alterações nos batimentos cardíacos, uma vez que as funções cardiopulmonares são afetadas.

Portanto, a motivação deste trabalho surge diante do potencial de detecção do COVID-19 por meio da frequência cardíaca, utilizando *smartwatches*. O principal estímulo para sustentar o presente projeto reside no momento de emergência sanitária mundial que se tornou uma pandemia em 2020, com o surgimento do COVID-19 no final de 2019. Apesar dos esforços e das evoluções para diagnosticar o vírus, ainda se faz necessário uma melhora substancial na área [3], por exemplo, o teste PCR requer 3 dias para obter um resultado confiável.

1.2 OBJETIVO

Este trabalho conta com dois objetivos: o primeiro objetivo é realizar uma revisão bibliográfica dos estudos que utilizam *wearables* na área da saúde, apresentando os promissores estudos e identificar quais doenças já são diagnosticadas, ou monitoradas pelos aparelhos. A partir desse compilado de estudos, é definido o segundo objetivo deste trabalho, a implementação de um algoritmo que sirva como um sistema de alerta para a detecção do COVID-19, identificando anomalias nos batimentos cardíacos obtidos pelos *smartwatches*. Vale realçar que esse algoritmo não visa substituir os exames PCR, mas sim auxiliar a população na detecção dos sintomas do vírus, evitando a exposição desnecessária e sobrecarga do sistema de saúde.

1.3 ORGANIZAÇÃO DO TRABALHO

O Capítulo 2 fornece revisão teórica necessária para o entendimento dos conceitos abordados como: o que são os dispositivos *wearables*, bem como sua funcionalidade e seus dispositivos mais vendidos; sensores dos dispositivos e métricas fisiológicas coletadas; conceitos básicos dos monitores cardíacos e a utilidade dos *wearables* dentro da medicina.

Capítulo 3 faz uma coleção com os estudos de casos que relacionaram os *wearables* com a área da saúde, mostrando as principais doenças que podem ser detectadas ou até mesmo monitoradas pelo dispositivo. Dentre as doenças e dispositivos mencionados no capítulo, será discutido a influência dos *wearables* na detecção do COVID-19, o qual é o escopo deste trabalho.

Capítulo 4 apresenta a metodologia utilizada para a pesquisa deste trabalho, baseada em *MISHRA, T. et al.* [4] passando pela arquitetura do sistema, etapas do algoritmo, dados retirados, pré-processamento, correção sazonal e treinamento do modelo.

O Capítulo 5 apresenta uma discussão dos resultados atingidos: anomalias detectadas nos pacientes de COVID-19 bem como a visualização gráfica dos *outliers* detectados.

Por último, o capítulo 6 contém as conclusões e limitações acerca das análises realizadas. Também aponta possíveis trabalhos futuros a serem desenvolvidos.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, é apresentado um panorama da evolução dos wearables, mais especificamente os smartwatches, bem como sua contextualização histórica e sua relação com a área da saúde. Isso se faz necessário para entender como a evolução tecnológica desses mecanismos tem sido importante para o conhecimento precoce de algumas doenças. O capítulo traz também uma série de estudos e artigos acadêmicos relevantes para o tema.

2.1 WEARABLES

A popularização das tecnologias móveis levou ao surgimento de dispositivos inteligentes e viáveis conhecidos como *wearables* (vestíveis, em tradução livre). O termo é utilizado para descrever computadores portáteis que recorrem a componentes de *hardware* avançados, utilizados no corpo com contato direto com a pele, disponibilizando interações entre os usuários e o ambiente inteligente (celulares, sensores, portas) a qualquer hora e em qualquer lugar [5].

Os *smartwatches* e *smartbands*, também conhecidos como relógios inteligentes e pulseiras inteligentes, são os *wearables* em alta no mercado que se assemelham aos relógios, porém desempenham funções semelhantes a computadores e *smartphones* [6]. Surgiram com o intuito de ajudar de uma forma inteligente, consistente e contínua, a realização de tarefas e atividades do usuário, quaisquer elas sejam [7].

A popularidade e a versatilidade destes equipamentos cresceram significativamente nos últimos anos, devido à crescente utilidade nos usos domésticos, em estudos dedicados à saúde humana [8] e até em ambiente empresarial, facilitando a comunicação e notificação entre funcionários [9].

2.1.1 Desenvolvimento dos *Smartwatches*

O primeiro relógio inteligente capaz de fazer mais do que indicar a hora foi criado em 1982 pela *Seiko*, o Pulsar NL C01. Ele possui 24 dígitos de informação e podia ser acoplado à impressora [10]. Em seguida a *Seiko* lançou o UC-2000 em 1984, este *smartwatch* contava com novas funções em relação ao modelo anterior como: armazenamento de texto e a conexão entre relógio e computador por meio de um cabo, proporcionando a transmissão de lista telefônica, documentos importantes e tarefas diárias do computador para o relógio [10]. A empresa *Casio* também inovou e criou a linha de relógios calculadoras de oito dígitos, com funções de soma, subtração, multiplicação, divisão e um calendário pré-programado [11]. Estes aparelhos podem ser vistos na Figura 2.1.




Figura 2.1: Primeiros *smartwatches*: (a) Pulsar NL C01 [12] (b) Seiko UC-2000 [12] (c) Casio Relógio Calculadora [13].

No início dos anos 2000, a diminuição dos processadores e o barateamento dos componentes eletrônicos possibilitou a criação de *wearables* mais potentes. A IBM idealizou o *IBM WatchPad* ou *Linux Watch*, criado com o intuito de facilitar a vida de trabalhadores. O *smartwatch* tinha o sistema operacional *Linux* e apresentava novidades como: acesso a agenda, *display touchscreen*, leitor de digital e conexão *Bluetooth* para conectar-se à computadores. Infelizmente o *IBM WatchPad* não chegou a ser vendido devido a restrições de tamanho e desempenho limitado [11, 14]. A Figura 2.2 mostra o modelo da IBM.



Figura 2.2: *IBM WatchPad*, ou *Linux Watch*. Adaptado de [11].

Enquanto alguns *smartwatches* tentavam replicar funções dos computadores, uma nova vertente de *smartwatches* especializados exclusivamente em monitoração cardíaca ganhavam notoriedade no mercado. Em particular, a partir dos anos 2000 os monitores cardíacos e as cintas peitorais da empresa *Polar* destacaram-se no mercado brasileiro. Esses *wearables* inovaram ao disponibilizar o monitoramento do desempenho cardíaco durante a execução das atividades físicas e também o funcionamento cardíaco durante repouso. A figura 2.3 mostra alguns modelos de *smartwatches*, cintas peitorais e os gráficos fornecidos pelo *software* da *Polar*.



Figura 2.3: Exemplos de *Wearables* focados em monitoração cardíaca: (a) *Polar Vantage NV*[15] (b) *Polar FT1*[16] (c) Monitoração cardíaca em tempo real da *Polar*[17]

Posteriormente, em 2003, a marca *Fossil* anunciou o *Palm Fossil Wrist PDA* e este reunia novas funções como o acesso à agenda pessoal eletrônica, contatos, bloco de notas e compromissos pessoais, tudo isso sob um sistema proprietário intitulado como *Palm OS* [18]. Importante ressaltar que todos os dispositivos a partir dos anos 2000 contavam com o *display touchscreen*. Em 2004, a *Microsoft* adentrava o mercado com o *Smart Personal Object Technology*, ou *SPOT*. Este *smartwatch* entregava informações de trânsito, previsão do tempo, notícias e acesso ao *MSN Messenger* [18]. A Figura 2.4 apresenta os dois aparelhos.



Figura 2.4: Exemplos de *smartwatches*: (a) *Palm Fossil Wrist PDA* [18] (b) *Microsoft SPOT* [18].

A partir de 2009, a *Samsung* busca revolucionar o mercado com o *Samsung S9110*, o primeiro dispositivo de sua linha *wearables* [18]. Basicamente, o modelo entregava funções iguais a de um *smartphone* da época, ou seja, realizava ligações, possuía microfone embutido, conexão *bluetooth* e tocador MP3. Vale destacar que apesar das inovações tecnológicas dos *smartwatches*, os mesmos não foram tão populares em suas respectivas épocas uma vez que enfrentavam problemas em relação à tamanho, consumo de bateria e desempenho, além do preço não acessível.

Por fim, em 2014, a *Apple* apresentou o seu primeiro *smartwatch*, o *Apple Watch* [18]. Com novas funções e um novo sistema operacional, *watchOS*, oferecendo um sistema intuitivo, rápido e simples. Além de ofertar sensores voltados para a saúde como sensores de frequência cardíaca, pedômetro e acelerômetro, todos integrados em um *software* de saúde [19]. As figuras 2.5 (a) e (b) ilustram respectivamente os aparelhos da *Samsung*, *S9110*, e o *Apple Watch*.



Figura 2.5: Exemplos de *Smartwatches* e *Smartbands* mais recentes: (a) *Samsung S9110* [18] (b) *Apple Watch 1* [18].

Desde então, o mercado dos *smartwatches* passa a se popularizar ainda mais, não somente com *Smartwatches*, mas também com *Smartbands*, pulseiras inteligentes focadas em monitoração das atividades físicas e saúde por meio de sensores e *softwares* de saúde. Há grandes marcas no mercado como a *FitBit*, da *Google*, *Garmin* e *Xiaomi*. A Figura 2.6 mostra alguns exemplos de *smartbands* disponíveis no mercado.



Figura 2.6: Exemplos de *Smartbands* atuais: (a) *Garmin Vivosmart 4* [20] (b) *FitBit Inspire 2* [21] (c) *Xiaomi Mi Band 6* [22].

2.1.2 Sensores e Dados

Em consequência do desenvolvimento acelerado da tecnologia, os sensores estão ainda menores, mais acessíveis e dispõem de alta precisão. Em razão disso, os *wearables* também apresentam vários desses sensores, entre os mais conhecidos como o acelerômetro, termômetro, GPS, sensor de luminosidade e monitores de frequência cardíaca (ECG são os monitores elétricos e PPG os monitores ópticos). Algumas empresas estão investindo para que seus *smartwatches* tenham tecnologias que possibilitem monitores de glicose não invasivos, sem a necessidade do sangue [23]. A Tabela 2.1 apresenta um resumo dos principais sensores e dados extraídos dos mesmos.

Tabela 2.1: Sensores comuns e dados coletados.

Sensores	Dados coletados
Acelerômetro/Giroscópio	- Passos e distância percorrida (auxílio do GPS); - Nível de intensidade de atividade física; - Consumo energético durante exercícios (bicicleta, natação, corrida)
GPS	- Localização em tempo real
Monitor Cardíaco Elétrico (ECG)	- Frequência e eficiência cardíaca; - Fase e Padrão do sono; - Atividade elétrica cardíaca (Eletrocardiograma)
Monitores Cardíaco Óptico (PPG)	- Frequência e eficiência cardíaca; - Fase e padrão do sono; - Nível de oxigenação no sangue;
Termômetro	- Temperatura da pele; - Saúde do sistema imunológico;

Com o auxílio desses sensores, pode-se inferir dados de extrema relevância como frequência cardíaca, frequência cardíaca em repouso, eletrocardiograma simplificado, monitoração ou qualidade do sono. As informações provenientes desses dados são de interesse de diversos públicos, desde jovens que buscam medir a sua evolução e desempenho físico com base na frequência cardíaca, oxigenação no sangue, passos ou quilômetros percorridos até idosos que desejam monitorar o nível de glicose no sangue de maneira não invasiva, acompanhar a qualidade do sono e, se necessário, alertar a emergência de eventuais quedas. A figura 2.7 ilustra a tendência mundial do mercado de *smartwatches* [24]. Em contrapartida a Tabela 2.2 expõe um comparativo entre os *smartwatches* mais populares do mercado brasileiro, seus respectivos sensores e as médias dos preços, coletados no dia 27/09/2021 [25, 26].




Figura 2.7: Relação de *smartwatches* mais vendidos no mercado em 2019-2020. Adaptado de [24].

Tabela 2.2: Smartwatches mais populares e seus respectivos sensores

Empresa	Modelo	Preço Estimado	Sensores disponíveis
- Apple	R\$ 2.599,00	- Apple Watch Series 3	- Sensor cardíaco óptico (PPG); - GPS integrado; - Acelerômetro e Giroscópio; - Altímetro barométrico; - Sensor de luminosidade;
- Huawei	R\$ 1.499,00	- Huawei Watch GT 2	- Sensor cardíaco óptico (PPG); - GPS integrado; - Acelerômetro e Giroscópio; - Oxímetro; - Sensor de luminosidade;
- Samsung	R\$ 809,10	- Galaxy Watch Active 2	- Sensor cardíaco elétrico (ECG) e Eletrocardiograma; - GPS integrado; - Acelerômetro e giroscópio; - Barômetro; - Sensor de luminosidade
- Amazfit	R\$ 998,00	- Amazfit GTR	- Sensor cardíaco óptico (PPG); - GPS integrado; - Acelerômetro e giroscópio; - Oxímetro; - Sensor de Luminosidade

Dos sensores percorridos até o momento, os monitores de frequência cardíaca são fundamentais uma vez que não é mais necessário ir, exclusivamente, ao hospital para obter informações referente à frequência cardíaca. Atualmente já é possível obter eletrocardiogramas simplificados por meio de *smartwatches* com o auxílio dos sensores e *softwares integrados*. O próximo tópico abordará com mais detalhes os tipos de sensores e as diferenças entre eles.

2.2 MONITORES CARDÍACOS

Monitores cardíacos são equipamentos capazes de ajudar na qualidade de vida além do âmbito hospitalar e servem basicamente para acompanhar os batimentos cardíacos, com utilizações em atividades médicas e esportivas. As próximas seções abordarão dados históricos e conceitos relacionados à compreensão dessa tecnologia.

2.2.1 Contexto histórico

O primeiro monitor cardíaco foi criado em 1902 pelo holandês Willem Einthoven. O eletrocardiograma fazia uso de um galvanômetro de corda, um instrumento capaz de medir correntes elétricas de baixa intensidade [27]. O dispositivo consegue identificar a diferença de potencial cardíaco, ainda que a corrente seja muito fraca, para produzir um eletrocardiograma fidedigno, sem a necessidade de correção matemática. Entretanto não era tão prático executar o exame, uma vez que fios eram conectados às mãos e pés do indivíduo, dentro de um balde com uma solução de eletrólitos, além disso a máquina pesava por volta de 270 quilos, ocupava dois aposentos e necessitava de cinco pessoas especializadas para operar a máquina, restringindo o acesso a informações cardiovasculares ao público [28].



Figura 2.8: O primeiro eletrocardiograma elétrico. Adaptado de [29].

Apesar das condições e requisitos, a inovação do eletrocardiograma providenciou conhecimento mais amplo acerca da estrutura, funcionamento e das doenças do coração humano. Conforme a cardiologia evoluía, melhoramentos foram feitos para tornar o exame e as informações mais práticas, de tal forma que o monitoramento pudesse ser realizado de forma contínua e sem a dependência dos hospitais [29].

A partir da década de 1960, o monitoramento eletrocardiográfico ambulatorial, conhecido como *holter*, recebeu bastante destaque pois possibilitava o monitoramento cardíaco contínuo por 24, até 48 horas, não invasivo e prático visto que não era mais necessário ficar no hospital preso ao eletrocardiograma [30]. Os elétrodos são presos ao peito e esses são ligados ao *holter* por fios, uma vez que o monitor e os elétrodos estão instalados adequadamente, o paciente está liberado para fazer suas atividades rotineiras. As aplicações dessa tecnologia são diversas, como: análise de marca-passos, variação de frequência cardíaca, efeito de medicamentos antiarrítmicos e diagnósticos de arritmias [30].

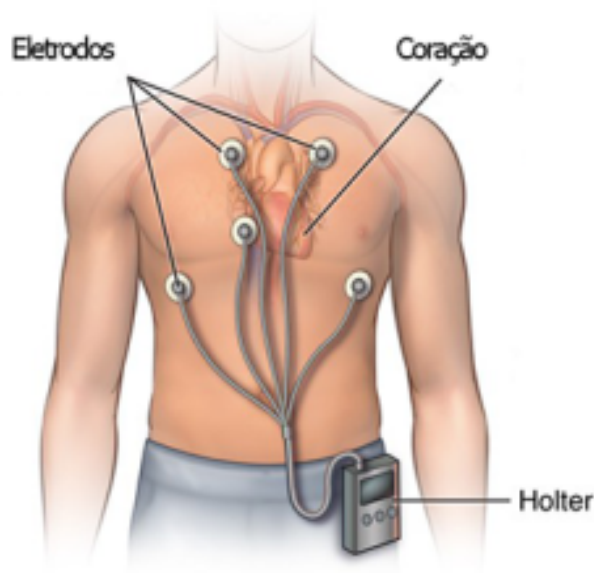


Figura 2.9: Exemplo de caso do *Holter*. Adaptado de [31].

Posteriormente, em 1982 a empresa finlandesa *Polar Electro* disponibilizou o primeiro monitor cardíaco portátil sem fio, inovando a área dos monitores cardíacos ao disponibilizar um monitor cardíaco constante, não invasivo, monitorando o desempenho cardíaco durante as atividades físicas, durante o repouso e o sono, sem preocupações [32]. A partir desse ponto, a tecnologia progrediu cada vez mais, os dispositivos tornaram-se mais leves, compactos e com o processamento mais potente, proporcionando um ambiente com dados e sensores mais precisos, até a criação de um monitor cardíaco que faz uso de leituras ópticas na pele, no lugar dos tradicionais elétrodos.

Atualmente há duas grandes classes de monitores cardíacos: os sensores ECG ou EKG, conhecidos também como Eletrocardiogramas, e os sensores PPG, ou fotopleletismografia (do inglês *photoplethysmograph*). Ambos são utilizados em *wearables* como *smartwatches* e *smartbands*.

2.2.2 Eletrocardiograma (ECG)

O monitor ECG, conforme já explicado anteriormente, funciona com o auxílio de elétrodos (pequenos discos metálicos) em contato direto com a pele. Esses elétrodos capturam os impulsos elétricos que são emitidos durante o ciclo cardíaco, ou seja, durante a entrada e saída de sangue no coração [33]. Os impulsos são registrados e o padrão que representa a atividade elétrica do coração é produzida. A princípio, os *wearables* utilizam mais os monitores PPG, o ECG é mais encontrado em cintas peitorais pois os elétrodos que estão nas faixas ficam mais próximos do coração, aumentando a precisão do eletrocardiograma. A Figura 2.10 mostra um exemplo do ECG.



Figura 2.10: Exemplo de monitor ECG. Adaptado de [34].

Ainda existem obstáculos a serem superados pela tecnologia ECG. Esses obstáculos são relacionados à anatomia particular de cada indivíduo. A localização, tamanho e gordura corporal do coração podem afetar as medições dos impulsos elétricos, além disso, a localização dos elétrodos em relação à posição do coração [35].

2.2.3 Fotopleletismografia (PPG)

O monitor PPG faz uso de sensores ópticos para obter a frequência cardíaca. Esses sensores também conseguem inferir a taxa respiratória, pressão sanguínea e o nível de oxigenação no sangue [36]. Para adquirir esses dados, o PPG faz uso de um emissor óptico, normalmente de LED, um fotodetector, um acelerômetro e algoritmos para realizar todo o cálculo matemático [36]. A Figura 2.11 mostra um exemplo do PPG.



Figura 2.11: Exemplo de monitor PPG. Adaptado de [37].

O processo inicia a partir do momento em que o emissor óptico transmite ondas de luz para a pele e, em seguida, o fotodetector faz a captura da luz refletida e traduz o sinal em códigos binários para que sejam posteriormente calculados, o acelerômetro mede o movimento dessas ondas de luz e é utilizado em combinação com o sinal produzido pelo fotodetector, gerando duas entradas para o algoritmo. Por fim, o algoritmo processa os sinais recebidos e obtém a frequência cardíaca e outros dados biomédicos úteis já citados. A Figura 2.12 mostra possíveis dados extraídos por meio do sinal PPG.

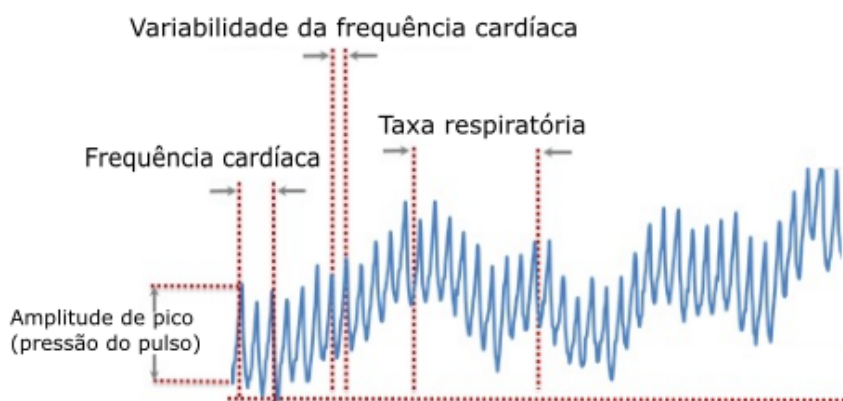


Figura 2.12: Sinal simplificado do PPG e dados inferidos. Adaptado de [36]

O PPG apresenta dois modos de operação, o modo transmissão e o modo reflexão. No modo transmissão, o transmissor óptico e o fotodetector ficam em lados opostos da pele, o fotodetector captura a onda que é transmitida pela pele, comumente utilizado na ponta do dedos ou nos lóbulos da orelha. Em contrapartida, o modo reflexão opera com o transmissor óptico e o fotodetector no mesmo lado da pele, com o fotodetector captando a onda que foi refletida pela pele [38]. A Figura 2.13 mostra os modos de operação do PPG. Informações mais detalhadas sobre o funcionamento dos monitores cardíacos óptico podem ser encontradas em [38, 39].




Figura 2.13: Modos de operação do monitor PPG: (a) modo de transmissão (b) modo de reflexão. Adaptado de [38]

A tecnologia PPG possui alguns desafios na área de medição dos dados como: distinguir o sinal biométrico do ruído branco, produzidos por pelos, tendões e contrações musculares; tons mais escuros de pele e tatuagens absorvem mais a luz do sensor ao invés de refletir, tornando a leitura e tradução do sinal mais complexa. Durante o lançamento do Apple Watch, usuários reclamaram sobre leituras imprecisas sob tatuagens [40]. No que diz respeito à acurácia dos dados coletados pelo PPG em comparação com o ECG, estudos já conseguem demonstrar que não há diferença significativa entre as duas tecnologias, ambas permaneceram coesas com as medições cardíacas [41, 42].

2.3 RESTING HEART RATE (RHR)

A frequência cardíaca em repouso (Resting Heart Rate - RHR) é uma das mais simples variáveis cardiovasculares. Ela mede a frequência cardíaca do indivíduo quando não há esforço físico (em repouso).

É um parâmetro de fácil medida e pode ser coletado tanto em ambientes clínicos, quanto em ambientes domésticos [43]. A faixa de valores RHR considerados normais é entre 60 a 100 batimentos por minuto (bpm, do inglês *beats per minute*) e serve como indicador tanto de aptidão física quanto de saúde em geral. Ao longo das últimas seis décadas, estudos evidenciam que o RHR é utilizado para indicar hipertensão, doenças arteriais coronarianas, doenças cardiovasculares e o aumento do risco de mortalidade por ataques cardíacos [43].

Alguns fatores podem afetar o RHR como: idade; sexo; temperatura do ar; efeitos de medicação; e aptidão física. Um atleta pode ter um RHR de 40 bpm, apontando um coração com músculos mais fortes e que podem bombear sangue de forma mais eficiente [44]. Dados recentes também apontam que frequências cardíacas elevadas, obtidas por meio de *smartwatches*, podem ser consumidos em estudos epidemiológicos para rastrear a propagação de vírus respiratórios [45]. Em particular, novos estudos estão surgindo com o intuito de fornecer diagnósticos pré-sintomáticos para casos de COVID-19 por meio de análises estatísticas do RHR em uma janela de tempo [46].

No que tange à acurácia destes sensores, existem estudos comparando diversos *smartwatches* populares, como o *Apple Watch*, *FitBit*, *Mi Band* com dispositivos já consolidados no mercado, como o transmissor cardíaco H7, da marca Polar [47], mostrando uma diferença mínima entre o transmissor, com o erro na ordem de grandeza de 0.09 bpm entre os sensores ópticos dos *smartwatches* em comparação com os sensores dos transmissores com eletrodos dos transmissores cardíacos [48].

2.4 WEARABLES NA SAÚDE

Existe um consenso de que os *wearables*, no geral, são adquiridos majoritariamente por indivíduos que desejam monitorar e acompanhar a evolução do estilo de vida saudável [49]. Entretanto, pode-se observar o impacto e a revolução na área da biomedicina causado por esses aparelhos, fornecendo monitoração contínua e em tempo real do estado de saúde dos pacientes fora das clínicas.

Além de medirem batimentos cardíacos, calorias consumidas e qualidade do sono, contribuindo para um estilo de vida saudável, estes dispositivos também já possuem a capacidade para identificar algumas doenças e comorbidades como: sintomas de depressão, fazendo uso de dados referentes à quantidades de conversas e batimentos cardíacos [50]; esforço e desempenho durante a prática de atividade física; obesidade, por meio da análise do pedômetro e histórico de atividades físicas [51];

Há diversos casos em que indivíduos sofreram quedas, desmaios ou paradas cardiorrespiratórias e os *wearables* dispararam alarmes para as autoridades a tempo [52, 53, 54, 55], ou que o seu RHR estava em 210 bpm e ao chegar em um hospital, descobrir que estava com fibrilação arterial [54] (arritmia cardíaca, acelerando os batimentos cardíacos e de forma irregular, mais informações podem ser consultadas em [56]). Além de salvar vidas, já existem estudos indicando de que a tecnologia adotada em alguns *wearables* já fornece dados tão precisos quanto aparelhos em hospitais [57].

As marcas de *smartwatches* têm desenvolvido aplicativos que colaboram na coleta de dados úteis para muitas pesquisas médicas, entre elas a Doença de Lyme [58], Doença de Parkinson [59], diabetes, asma e doenças cardiovasculares [60].

Posto isto, é possível discorrer a respeito da utilização de smartwatches para monitoramento e prevenção a respeito do COVID-19, dado que é uma doença cardiorrespiratória e já é possível encontrar estudos indicando um pré-diagnóstico dessas doenças.

2.4.1 Relação dos *Smartwatches* no COVID-19

Na conjuntura internacional, o início de 2020 foi marcado por um surto causado por uma variação do coronavírus, cujo primeiro caso foi anunciado em dezembro de 2019 na China. Em pouco tempo, o vírus se espalhou mundialmente, fazendo com que a Organização Mundial da Saúde (OMS) declarasse situação de emergência em saúde pública de interesse internacional e dando início a uma pandemia global [61].

A doença causada pelo coronavírus (COVID-19) é conhecida por causar insuficiência respiratória aguda com alterações cardiopulmonares não totalmente esclarecidas, fazendo com que muitos pacientes se encontrem em estado grave e acabem necessitando de oxigenoterapia e suporte respiratório [62]. Além disso, a doença possui uma alta infectividade, o que gerou um grande desafio para os diversos sistemas de saúde.

Na corrida contra o tempo para combater a alta disseminação do vírus, a comunidade científica voltou seus esforços em busca de soluções e estratégias [63]. Grande parte desses esforços se deram na realização de testes diagnósticos e detecção rápida. Entende-se que com o rápido diagnóstico da doença, mais fácil fica de controlar sua transmissão, pois o doente passará por uma fase de isolamento social, tomando os cuidados necessários para sua recuperação.

No início da pandemia os gastos com os testes eram altos e com o tempo buscou-se encontrar formas de auxiliar no precoce diagnóstico da doença. É nesse sentido que alguns pesquisadores passaram a ver nos dispositivos de *smartwatches* uma possibilidade de auxiliar no diagnóstico precoce e de baixo custo do COVID-19 [64].

Entende-se que as alterações que o vírus pode causar no corpo humano envolvem a alteração na frequência cardíaca, uma vez que afeta a parte respiratória. Conforme supracitado, os *smartwatches* têm tido um relevante papel na detecção precoce de diagnóstico de doenças virais respiratórias, tendo em vista que conseguem coletar dados referentes a frequência cardíaca e temperatura da pele [64].

Sendo assim, dado o crescente uso dos wearables contendo sensores de alta precisão, conclui-se que estes aparelhos possuem um potencial amplo na luta contra o COVID-19, auxiliando nos diagnósticos iniciais. Apesar dos esforços e das evoluções para diagnosticar o vírus, ainda se faz necessário uma melhora substancial na área, por exemplo, o teste PCR requer 3 dias para obter um resultado confiável [65].

2.5 CONCLUSÕES ACERCA DO CAPÍTULO

Este capítulo estabeleceu o ferramental teórico necessário para a compreensão e contextualização do tema. Foi abordado desde o início do *wearables* e monitores cardíacos, com ênfase nos *smartwatches* e *smartbands*, até o RHR e atuação dos *wearables* na saúde. O próximo capítulo apresentará um catálogo dos estudos e artigos correntes sobre o uso de *smartwatches* na área médica.

3 TRABALHOS RELACIONADOS

Neste capítulo serão apresentados estudos que tiveram como metodologia o levantamento de pesquisas sobre *smartwatches* e a área da saúde. Isso se fez necessário para visualizar quais os andamentos das pesquisas sobre esses dispositivos e o quanto os mesmos tem sido importante para a saúde do usuário.

3.1 SMARTWATCHES NA MEDICINA

Estudos indicam que os *smartwatches* possuem uma grande capacidade de auxiliar na área da saúde, pois tais aparelhos utilizam sensores que coletam dados diários de atividades cotidianas que auxiliam na prevenção de doenças. *Reeder, B. et al.* [2] descreve que esses estudos ainda estão no seu momento inicial e necessitam ser mais aprofundados.

Ainda de acordo *Reeder, B. et al.* [2], há duas áreas em que os *smartwatches* podem ser utilizados como uma forma de prevenção e detecção de doenças, são elas: área cerebral neural e cardíaca. O sucesso desses aparelhos nas áreas mencionadas ocorre devido à grande expansão desses dispositivos no mercado, somente em 2018 foram registradas 214 milhões de unidades vendidas. Além de utilizarem constantemente dados relativos à saúde, possuem a capacidade de se integrar facilmente com os demais dispositivos da chamada "Internet Das Coisas", IOT (*Internet Of Things*).

Reeder, B. et al. [2] realizou um levantamento de estudos sobre os relógios inteligentes utilizados na medicina. Os resultados foram divididos em algumas categorias, como: pesquisadores, nome do trabalho, tipos de *smartwatches*, modelos, foco do estudo, ferramentas e participantes. Foi constatado que 88% dos estudos analisados tinham foco no paciente. Tais estudos se concentram em monitoramento de atividades dos usuários, monitoramento de frequência cardíaca, adesão à terapia da fala, auto gerenciamento de diabetes e detecções de convulsões.

Nos estudos levantados, constataram a presença de nove diferentes modelos de *smartwatches* comerciais utilizados nas pesquisas, sendo eles: *Asus Zen watch*, *Basis Peak*, *LG G watch R*, *Motorola 360*, *Pebble Classic*, *Samsung Galaxy Gear*, *Samsung Gear S* e *ZI Android watch-phone*. Segundo os *Reeder et al.* [2], dos nove relógios mencionados, somente os *Basis PEak*, *Pebble Classic* e o *SmartMonitor SmartWatch* não utilizam o sistema operacional *Android*. Vale realçar que todos os *smartwatches* necessitam de emparelhamento com *smartphones*, *tablet* ou dispositivos IoT para a funcionalidade completa.

Posteriormente foi realizada uma listagem de sensores, sendo eles: Acelerômetro, Giroscópios, Microphones, Sensores ópticos, Sensores de Contato, Sensores de luminosidades, Sinal de *Wi-Fi*. É importante ressaltar que o levantamento no artigo fez uso apenas dos dispositivos que utilizam o sistema operacional *Android*, pois não conseguiram respostas dos estudos que envolviam o *Apple Watch*.

Em suma, *Reeder et al.* [2] constatou que os *smartwatches* comerciais passaram a ter grande relevância na área da saúde. Concluíram também que futuramente a tecnologia para saúde e bem-estar exigirá que os dados coletados pelos sensores dos *smartwatches* sejam integrados a outras fontes de informação.

Lu, T.C. et al. [66] relata outro levantamento de estudos que também envolviam os *smartwatches* e a medicina. Com base na revisão bibliográfica, percebe-se que a maior parte das pesquisas utilizaram como fundamento dispositivos com o sistema operacional *Android*.

O estudo mostra que *Microsoft Kinect* foi utilizados em conjunto com os *smartwatches* na monitoração de idosos. A princípio, o *Microsoft Kinect* foi desenvolvido para fins de jogos, no entanto, os desenvolvedores identificaram que a câmera com sensor de movimento teria potencial para aplicações na área da saúde, pois possuem capacidade de rastrear movimentos em espaço tridimensional (3D). *Lu, T.C. et al.* [66] elenca vários estudos que utilizam o *Kinect* para auxiliar no diagnóstico ou monitoramento da doença de Parkinson e outras doenças de movimento.

Ainda de acordo com *Lu, T.C. et al.* [66], percebe-se que muitos aplicativos de cuidados com a saúde estão sendo desenvolvidos utilizando *smartwatches* com foco no monitoramento de saúde ou em casas inteligentes pensadas para idosos. O motivo dessa crescente, conforme o artigo, vem do fato de que tanto a população mundial, quanto a população dos Estados Unidos, vem envelhecendo nas últimas décadas. Sendo assim, observou-se que muitos aplicativos de saúde têm sido usados na prevenção de quedas, gerenciamento de doenças crônicas e gestão de medicamentos para idosos.

Outro tipo de categoria identificada no levantamento dos estudos é de pacientes com doenças neurológicas, como Parkinson, Alzheimer e Epilepsia [66]. Pesquisadores têm buscado monitorar o *feedback* de atividades durante a reabilitação de AVC e atividades de pessoas com problemas motores. É importante ressaltar que apesar do uso de *smartwatches* para detectar convulsões ter sido um sucesso em testes laboratoriais, observou-se ser necessário um maior aprofundamento e desenvolvimento dos aplicativos para vida cotidiana.

Continuando a análise das pesquisas levantadas, os autores encontraram mais artigos que possuíam como objetivo auxiliar pacientes com paradas cardíacas fora do hospital, permitindo que espectadores não treinados em manobras de ressuscitamento pudessem realizar tal ação de forma correta em caso de emergências. Utilizando o acelerômetro do *smartwatch*, um *software* de RCP (Ressuscitação Cardiopulmonar) foi desenvolvido para fornecer um *feedback* em tempo real durante a compressão torácica, utilizando três funcionalidades: frequência, profundidade e contagem. Por fim *Lu, TC. et al.* [66] demonstram que para que as tecnologias assistivas sejam implementadas com sucesso é necessário haver um equilíbrio entre o design do relógio e a experiência do usuário, pois os relógios possuem um tamanho pequeno de tela.

3.2 DETECÇÃO DE DOENÇAS

O trabalho de *DöRR, M. et al.* [67] trata da utilização do *smartwatches* para detecção de disfunções cardíacas como fibrilação cardíaca. Tal doença trata-se de um tipo de arritmia cardíaca com características muito específicas e que atinge 2 a 4% da população mundial. Entretanto, a sua taxa de mortalidade em adultos é alta e existem dificuldades de para realizar o diagnóstico, pois muitas vezes o indivíduo não apresenta sintomas do problema. Sendo assim, quanto mais precoce é o diagnóstico do problema cardíaco menor a chance do indivíduo vir a ter um AVC ou mesmo ir a óbito. Por se tratar de uma problema silencioso, para se ter o diagnóstico da fibrilação atrial é necessário o monitoramento cardíaco durante um exame físico do paciente.

Dada a crescente dos *smartwatches* e a precisão dos sensores cardíacos, *DöRR, M. et al.* [67] optaram por fazer um comparativo entre os ECG e o PPG para a detecção de fibrilação cardíaca. O artigo conclui que o PPG é tão preciso quanto o ECG e que utilizando monitoração em tempo real dos *smartwatches*, é possível fazer o diagnóstico precoce da doença, o que levará o indivíduo a procurar um médico para mais exames e diagnósticos.

Xiao, Li. et al. [68] abordam em suas pesquisas o uso de *smartwatches* para monitoramento de mudanças fisiológicas do indivíduo durante suas atividades cotidianas para pré-diagnósticos e estudos de doenças.

Neste artigo, foram utilizadas 250.000 medições diárias em até 43 indivíduos e constaram diferenças fisiológicas que podem indicar possíveis doenças. Utilizando as informações dos sensores junto a opinião médica, foi possível observar duas coisas: primeiros sinais da doença de Lyme e doenças inflamatórias. *Xiao, Li. et al.* [68] ainda colocam que com tais informações foi possível realizar um parâmetro de normalidade fisiológica, o que faz com que qualquer alteração fora desse parâmetro possa indicar alguma anormalidade. É importante ressaltar que, para chegar nesse parâmetro de normalidade, os autores levaram em consideração mudanças de altitude, quando o usuário pega um avião e também questões como cansaço físico e estresse.

Por fim, pode-se concluir no artigo que os smartwatches possuem poderosos sensores para monitorar atividades pessoais e fisiológicas que auxiliam no cuidado à saúde de forma mais versátil e com menor custo.

3.2.1 Detecção do COVID-19

Seguindo as análises bibliográficas, encontrou-se estudos referentes à utilização de *smartwatches* para auxiliar na detecção do COVID-19. Dada a pandemia global do Coronavírus e a dificuldade de diagnosticar a doença, a tecnologia passa a ser um aliado na identificação da doença e nos primeiros cuidados que o indivíduo deve ter para que não contamine outras pessoas.

Wong, C.K. et al. [69] colocam que com os avanços dos biossensores foi possível monitorar continuamente os sintomas causados pela doença do COVID-19. Uma das precauções tomadas para a não disseminação do COVID-19 é a quarentena. Nela, o indivíduo se isola de outros e assim não causa a contaminação de outras pessoas. Muitos países adotaram tal medida, que trata-se de uma recomendação da Organização Mundial de Saúde - OMS [70]. Durante a quarentena um indivíduo contaminado deve fazer o monitoramento de seus sintomas, até por motivos de não ser surpreendido por um avanço da doença que pode levá-lo a óbito.

Wong, C.K. et al. [69] ressaltam que este monitoramento é altamente dependente da auto-disciplina do indivíduo e que muitas vezes os pacientes não levam a rigor o monitoramento dos sintomas. A medição de temperatura, sozinha, não é o suficiente para monitorar o avanço da infecção. Conforme os estudos realizados, muitos indivíduos passaram a ter febre apenas na metade do período de incubação da doença. Sendo assim, outras alterações fisiológicas foram consideradas nos estudos feitos pelos autores, como frequência cardíaca, frequência respiratória, saturação de oxigênio e transpiração.

Wong, C.K. et al. [69] informam que tais medições são difíceis sem um treinamento médico e é por isso que a utilização de biossensores tem sido de grande importância para essa questão. Portanto, o avanço dos estudos dos biossensores será de grande apoio para área da saúde, ainda mais no que diz respeito a doença do COVID-19.

Quer, G. et al. [46] fazem um estudo de caso sobre a detecção do COVID-19 por meio de *SmartWatches e smartbands*. O artigo relata que foi conduzido um estudo durante Março até Julho de 2020 com o intuito de detectar a infecção do vírus. Para isto, dados de 30.529 participantes, residentes nos Estados Unidos, foram coletados por meio dos seus *smartwatches e smartbands*. 3.811 Voluntários também preencheram um diário informando os sintomas e 333 desses participantes reportaram testes positivos para a doença.

Para cada participante eram coletadas as medidas de RHR, a quantidade de passos e de sono em dois intervalos: uma janela de 7 a 21 dias antes dos sintomas; uma janela de 7 dias depois dos sintomas chamada de "intervalo de teste". Uma vez que os dados foram coletados, uma análise é feita a partir da diferença dos RHR máximos e da diferença entre as médias dos passos e da quantidade de sono. Após a análise, os dados passavam por um tratamento estatístico que é utilizado para classificar se o paciente é positivo ou negativo para COVID-19. Quando os dados da classificação foram comparados com os dados do diário, *Quer, G. et al.* [46] observaram uma acurácia de 80% e concluem que os *smartwatches e smartbands* são capazes de melhorar significativamente a distinção entre indivíduos sintomáticos com e sem um diagnóstico de COVID-19.

Já *Zhu, T. et al.* [64] realizou um estudo semelhante ao *Quer, G. et al.* [46], porém com uma amostra menor. O experimento utilizou um banco de dados que abrangia dados de 5.262 participantes, residentes nos Estados Unidos, coletados durante Fevereiro até Julho de 2020. Os dados foram coletados por meio dos seus *smartwatches e smartbands*. A mesma abordagem utilizada em *Quer, G. et al.*[46] para os dados e a análise foram utilizadas. Apenas 114 participantes foram diagnosticados com COVID-19 e dentre eles, somente 47 preencheram o diário de sintomas. A falta de regularidade dos usuários ao utilizar os dispositivos e preenchimento do diário de sintomas prejudica o experimento porque gera uma deficiência de dados relevantes. Apesar da falta de dados, *Zhu, T. et al.*[64] concluem que a detecção ainda não está no ápice da sofisticação, mas sugerem que um dia os *smartwatches e smartbands* poderão alertar possível infecção antes que haja aparecimento de sintomas.

Natarajan, A. et al. [71] conduziram um estudo que analisa a alteração dos sinais fisiológicos (RHR, taxa de respiração e variação da frequência cardíaca - HRV) associados à COVID-19, medidos por *smartwatches e smartbands*. Neste artigo, é considerada a correlação entre as mudanças nos sinais fisiológicos relacionados à frequência respiratória, frequência cardíaca, presença correspondente de doenças avaliadas tanto através de testes laboratoriais confirmados e sintomas auto-relatados durante o curso temporal da doença. Dados de 2.745 voluntários foram coletados durante Maio até Setembro de 2020, consistindo em testes PCR positivos realizados durante o intervalo e dados cardíacos obtidos por *smartwatches FitBit*.

Natarajan, A. et al. [71] então treinaram uma rede neural convolucional para prever a doença. O resultado para a predição baseada nos sintomas relatados pelos voluntários apresentou uma acurácia de 82%, enquanto o resultado para os sinais fisiológicos apresentou uma acurácia de 77%. Sendo assim, pode-se concluir novamente que a precisão dos dados obtidos por *smartwatches e smartbands* é elevada. A medição dessas métricas, tomadas em conjunto com diagnósticos de base molecular, pode levar a uma melhor detecção precoce e monitoramento da COVID-19.

Por fim, *MISHRA, T. et al.* [4] comprovam que os dados biológicos dos *smartwatches* podem ser utilizados para a detecção pré-sintomática do COVID-19. O experimento utilizou um banco de dados que abrangia dados de 5.262 participantes, residentes nos Estados Unidos, coletados durante Fevereiro até Junho de 2020. Da amostra inicial, 32 indivíduos testaram positivo para COVID-19 e constataram que 26 desses indivíduos apresentaram alterações na frequência cardíaca, número de passos diário ou tempo de sono. Então, *MISHRA, T. et al.* [4] implementaram um algoritmo que consome as métricas fisiológicas para alertar irregularidades no RHR e atestaram que 63% dos casos COVID-19 poderiam ter sido detectados antes do início dos sintomas em tempo real por meio de um sistema de alerta de dois níveis baseado na ocorrência de elevações extremas RHR.

3.3 SÍNTESE

Com esse levantamento de estudos sobre a tecnologia de biossensores utilizados em wearables foi possível observar que cada vez mais a tecnologia tem avançado para dentro da área da saúde. O mais interessante é que progressivamente o indivíduo passa a ter um certo controle de sua saúde e ainda a baixo custo, como com a utilização de *smartwatches*, *smartphones* e demais equipamentos tecnológicos. A Tabela 3.1 apresenta um catálogo simplificado dos estudos apresentados, com as seguintes informações:

- Autores;
- Ano
- Smartwatch/Sensor utilizado;
- Qual doença/foi observada;
- Dados Consumidos;
- Código / banco de dados, disponíveis publicamente;

Tabela 3.1: Catálogo dos artigos

Autor	Ano	Área observada	Smartwatches/Sensor	Dados Consumidos	Banco de dados ou Código públicos
Reeder, B. et al. [2]	2016	Diabetes; convulsões	Asus Zen watch; Basis Peak LG G watch R Motorola 360 Pebble Classic Samsung Galaxy Gear Samsung Gear S	RHR; Quantidade de sono e passos; Temperatura da pele;	Não disponível
Lu, T.C. et al. [66]	2016	Parkinson; Alzheimer; AVC; Monitoração de idosos	Fitbit; Microsoft Kinect	RHR; Quantidade de sono e passos;	Não disponível
DöRR, M. et al. [67]	2019	Fibrilação cardíaca	Gear Fit 2; AliveCor Kardia;	RHR	Não disponível
Xiao, Li. et al. [68]	2017	Doença de Lyme; Doenças inflamatórias;	Sensor cardíaco PPG; Sensor de temperatura; Monitor de glicose;	RHR; Oxigenação do sangue; Quantidade de sono e passos; Temperatura da pele; Glicose no sangue;	Não disponível
Wong, C.K. et al. [69]	2020	COVID-19	Biovitals Sentinel platform	RHR Temperatura da pele;	Não disponível
Quer, G. et al. [46]	2021	COVID-19	FitBit	RHR; HVR; Temperatura da pele; Quantidade de sono e passos;	Não disponível
Zhu, T. et al. [64]	2020	COVID-19	FitBit	RHR; HVR; Temperatura da pele; Quantidade de sono e passos;	Não disponível
Natarajan, A. et al. [71]	2020	COVID-19	FitBit	RHR; HVR; Temperatura da pele; Quantidade de sono e passos;	Não disponível
MISHRA, T. et al. [4]	2020	COVID-19	FitBit	RHR; Quantidade de sono e passos;	Disponível em [4]

3.4 CONCLUSÕES ACERCA DO CAPÍTULO

Este capítulo reuniu e sintetizou uma série de estudos sobre o uso de *smartwatches* na área médica. O texto faz um compilado de informações sobre os autores, ano dos artigos, áreas de atuação dentro da saúde, *smartwatches* utilizados, dados biométricos utilizados em cada pesquisa e disponibilidade dos dados consumidos. Por fim, uma tabela contendo todas as informações apresentadas, de maneira sucinta, é disponibilizada. O próximo capítulo descreve a metodologia utilizada no trabalho.

4 METODOLOGIA

Neste capítulo serão descritos os dados utilizados, as etapas de processamento aplicadas, bem como todas as especificidades do problema a ser analisado. É importante ressaltar que o objetivo deste trabalho é replicar e compreender os resultados do algoritmo encontrado no artigo "*Pre-symptomatic detection of COVID-19 from smartwatch data*" [4]. O artigo em questão foi escolhido como base pois é o único que disponibiliza para uso um banco de dados contendo as informações fisiológicas, anonimizadas, dos voluntários. Além disso, é detalhada uma forma de detectar a infecção do COVID-19 antes de aparecerem os sintomas.

O processamento de passos e frequência cardíaca são realizados caso a caso e consistem em uma série de médias móveis aplicadas com o intuito de suavizar o sinal de RHR gerado. Parte-se da premissa que a frequência cardíaca em repouso (RHR) do indivíduo tem o comportamento estatístico de uma distribuição normal, e a partir disso são analisadas as amostras estatisticamente associadas a *outliers* (valores discrepantes e fora da curva).

4.1 DELIMITAÇÃO DO ESCOPO

Esse trabalho tem o propósito de replicar o algoritmo criado por *MISHRA, T. et al.* [4] com o intuito de compreender os impactos desses resultados para o diagnóstico do COVID-19. A fim de atingir esse objetivo, foi criado um fluxograma de três etapas que englobam todo o processo. A Figura 4.1 mostra o fluxograma do sistema.




Figura 4.1: Fluxograma do sistema

- Etapa 1: Obtenção do banco de dados

Esta etapa consiste em procurar um banco de dados contendo métricas coletadas pelos *smartwatches*. Esses deverão ser de voluntários que participaram do experimento da detecção do COVID-19. A princípio, estarão sem nenhum tratamento prévio, apenas dados brutos.

- Etapa 2: Análise e compreensão dos dados

Nesta etapa, será realizada uma análise dos dados obtidos, como se comportam, se são contínuos ou discretos no tempo.

- Etapa 3: Implementação do algoritmo;

Por fim, será implementado o algoritmo que expõe os dados em formato gráfico, indicando a frequência cardíaca, alerta de anomalias e as marcações temporais dos sintomas reportados previamente. Cada etapa será descrita detalhadamente nas seções a seguir.

4.2 OBTENÇÃO DO BANCO DE DADOS

Para implementar o algoritmo é necessário um banco de dados que contenha grandes amostras das informações sobre os batimentos cardíacos e passos dos voluntários, obtidos por meio dos *smartwatches*. Além disso, também é necessário o diário dos sintomas reportados pelos indivíduos. Sendo assim, construir um banco de dados massivo contendo dados biométricos dos voluntários demanda muito trabalho e ainda é preciso obter autorização de entidades médicas para a utilização dos dados.

MISHRA, T. et al. [4] registraram sob o protocolo 55577, aprovado pela Universidade de Stanford, uma amostra de 5.262 participantes residentes nos Estados Unidos para o estudo, dentre eles, 3.325 utilizavam *smartwatches* da empresa *Fitbit*. Os dados foram coletados durante o período de Fevereiro a Junho de 2020. Posto que grande parte da amostra utilizava *Fitbits*, o estudo foi direcionado para esses usuários. Desse modo, partindo da sub-amostra de 3.325 usuários, 114 indivíduos reportaram positivo a infecção do COVID-19, enquanto 47 reportaram outras infecções respiratórias.

O banco de dados disponibilizado em *MISHRA, T. et al.* [4] contém as métricas biomédicas coletadas pelos *smartwatches* e informações dos diários dos sintomas, como: datas dos sintomas; data do diagnóstico positivo para COVID-19; gravidade da infecção e tipos de sintomas dos indivíduos, referente aos pacientes que foram diagnosticados positivo para COVID-19, ou com outras infecções respiratórias. É importante ressaltar que dentre essas 114, somente 32 indivíduos possuem dados completos referentes às métricas biomédicas do *Fitbit* adjacentes ao diário de sintomas. Também existem casos de indivíduos que não possuem informações no diário, ou faltam medições após a infecção, sugerindo que alguns participantes não usam os dispositivos quando estão doente.

Os dados disponíveis consistem em amostras de frequências cardíacas e quantidade de passos dos indivíduos. Essas informações precisam ser anonimizados para que não haja exposição dos indivíduos. Portanto, ID's aleatórios foram gerados para cada paciente e as datas referentes aos sintomas, batimentos cardíacos e passos foram modificadas para um ano/mês fictícios. Os *datasets* (conjunto de dados em tradução livre) de frequência cardíaca e passos são armazenados em arquivos .csv (do inglês "*comma-separated-values*"). Os arquivos são identificados por *ID_<metrica>* utilizada e possuem três colunas: *user*, *datetime* e a métrica utilizada. As Figuras 4.2 e 4.3 mostram os padrões utilizados nos *datasets*.

- A coluna *user* apresenta o ID anonimizado do voluntário;

- A coluna *datetime* mostra em que momento temporal da métrica foi coletada, no padrão: "ano-mês-dia hora:minutos:segundos";
- Por fim a última coluna apresenta a métrica coletada, logo após a data de coleta.

	user	datetime	heartrate
0	AOYM4KG	2023-06-28 00:00:00	60
1	AOYM4KG	2023-06-28 00:01:00	60
2	AOYM4KG	2023-06-28 00:02:00	61
3	AOYM4KG	2023-06-28 00:03:00	59
4	AOYM4KG	2023-06-28 00:04:00	57

Figura 4.2: Exemplo do *dataset* referente à frequência cardíaca.

	user	datetime	steps
0	AOYM4KG	2023-06-28 00:00:00	0
1	AOYM4KG	2023-06-28 00:01:00	0
2	AOYM4KG	2023-06-28 00:02:00	0
3	AOYM4KG	2023-06-28 00:03:00	0
4	AOYM4KG	2023-06-28 00:04:00	0

Figura 4.3: Exemplo do *dataset* referente à quantidade de passos.

4.3 ANÁLISE E COMPREENSÃO DOS DADOS

Primeiramente foi realizada uma visualização nos *datasets* com o intuito de entender os dados. A Figura 4.4 mostra a média das frequências cardíacas e de passos ao longo dos dias, também foram realizadas marcações que indicam dias dos sintomas, diagnóstico e recuperação da infecção. Com isso é possível inferir que cada *dataset* grava a respectiva métrica por segundo, ao longo de um intervalo variável de dias.




Figura 4.4: Exemplo das médias de frequência cardíaca e passos ao longo do tempo. As marcações vermelhas, azuis e verdes são, respectivamente: data de início dos sintomas; data do diagnóstico positivo para COVID-19; data de recuperação da infecção

Posto isso, alguns parâmetros estatísticos foram gerados a fim de compreender o comportamento dos dados. As Figuras 4.5 e 4.6 mostram esses parâmetros e a partir daí pode-se concluir o seguinte:

heartrate	
count	146627.000000
mean	67.459281
std	17.939396
min	41.000000
25%	57.000000
50%	61.000000
75%	68.000000
max	185.000000

Figura 4.5: Exemplo de parâmetros estatísticos da frequência cardíaca.

steps	
count	120960.000000
mean	5.642419
std	19.606535
min	0.000000
25%	0.000000
50%	0.000000
75%	0.000000
max	176.000000

Figura 4.6: Exemplo de parâmetros estatísticos da quantidade de passos.

- Nenhum dado dentro do *dataset* é contínuo, isto é, existem interrupções ao longo do tempo na captura de informações fisiológicas;
- Existem valores zero dentro das métricas, indicando que não houve medição naquele instante, ou houve falha durante a medição;
- Pode-se observar pelos valores dos quartis que os batimentos estão concentrados na média de 67,45 bpm;

4.4 IMPLEMENTAÇÃO DO ALGORITMO

O algoritmo é composto de quatro estágios que, em síntese, consomem e fazem as análises dos *datasets*, detectam as anomalias e informam caso haja grandes alterações nos valores de RHR. Na primeira etapa uma limpeza inicial é realizada nos *datasets* para que posteriormente seja realizado o cálculo do RHR. O RHR passará por duas etapas: pré-processamento e correção sazonal. Uma vez que o RHR está processado e corrigido, o modelo de detecção de anomalias online é treinado. Após o treinamento, o resultado da análise é exibida em formato gráfico, com os valores normalizados de RHR, alertas de anomalias e marcações temporais dos sintomas reportados previamente. A Figura 4.7 mostra o fluxograma das etapas descritas. As próximas seções abordarão cada passo executado do algoritmo e a escolha da tecnologia para implementar o algoritmo.



Figura 4.7: Fluxograma do algoritmo.

4.4.1 Escolha da Tecnologia

O algoritmo foi desenvolvido utilizando a linguagem de programação *Python* por ser amplamente utilizada em processamento e análise de dados. A ferramenta apresenta uma série de características desejáveis, entre elas:

- Linguagem de alto nível, com uma sintaxe elegante e simplificada. Também suporta orientação a objetos, programação estruturada e funcional [72];
- Compatibilidade com diversas plataformas de sistemas operacionais [72];
- Várias bibliotecas disponíveis que contêm tipos de dados, funções, exceções e módulos, aumentando a capacidade de executar as tarefas mais complexas. [73]

Para auxiliar na implementação do algoritmo, visualização dos dados e geração de gráficos, as seguintes bibliotecas, já conhecidas pela sua eficiência, foram utilizadas:

1. *Pandas*: provê estruturas de dados simplificadas para facilitar a manipulação de *datasets* e ferramentas de análise de dados [74];
2. *Numpy*: provê objetos em forma de *array* N-dimensional e funções que realizam operações com tais objetos [75];
3. *Matplotlib*: Uma biblioteca abrangente para criar visualizações estáticas animadas e interativas em Python [76];

4. *statsmodels*: É uma biblioteca que fornece classes e funções para a estimativa de modelos estatísticos, bem como para a realização de testes e exploração de dados estatísticos. [77];
5. *Scikit-Learn*: conjunto de ferramentas que implementam algoritmos de ML supervisionados e não-supervisionados [78].

4.4.2 Limpeza dos dados e Cálculo do RHR

Nesta etapa, o algoritmo recebe os *datasets* dos batimentos cardíacos e dos passos, em seguida é realizada uma manipulação dos *datasets* com o intuito de facilitar os cálculos. Primeiramente, a coluna das datas são definidas como *index*, ou seja, uma coluna que não pode ser alterada, seus valores serão imutáveis. Isso é feito para evitar que qualquer data seja perdida ou alterada. Em seguida, a coluna referente ao ID é removida e os dois *datasets* são concatenados, formando um *dataset* de três colunas: datas, frequência cardíaca e quantidade de passos.

Os *outliers* de frequência cardíaca acima de 200 bpm e abaixo de 30 bpm são removidos e então os dados são amostrados em um intervalo de um minuto, substituindo os dados pela média dos valores dentro desse minuto. Isto é feito para uniformizar as métricas, uma vez que existem amostras zeradas. Com os dados uniformizados e amostrados, o cálculo do RHR é realizado por meio de um somatório das frequências cardíacas dentro de um intervalo de 12 minutos, se e somente se a quantidade de passos for zero. Essa abordagem está descrita e disponível em *Li, X. et al.* [58]. Por último, é retornado somente um *dataset* contendo os valores brutos do RHR. As Figuras 4.8 e 4.9 mostram um exemplo de gráfico e parâmetros estatísticos do RHR bruto.




Figura 4.8: Exemplo de RHR bruto.

heartrate	
count	62237.000000
mean	58.638278
std	5.214329
min	43.000000
25%	55.000000
50%	58.000000
75%	61.000000
max	119.000000

Figura 4.9: Exemplo de parâmetros estatísticos do RHR bruto.

4.4.3 Pré-processamento

Os dados coletados tem a finalidade de auxiliar no diagnóstico de anomalias na frequência cardíaca causada pelo COVID-19. Para isso, foram reproduzidas algumas etapas de tratamento que serão descritas nesta seção. Essas decisões foram tomadas ao lidar com dados faltantes e processam uma série temporal de sinais biológicos para detectar *outliers*. Por vezes é necessário realizar uma seleção de *features*, que consiste no processo de identificar e remover a maior quantidade de informações desnecessárias. Com isso é possível reduzir a dimensionalidade e remover informação redundante, o que pode resultar em uma melhora na precisão na etapa de classificação [79].

O processo de lidar com valores faltantes é extremamente recorrente durante a aquisição de dados, o que pode ocorrer em função de problemas no armazenamento, coleta, amostragem ou até mesmo restrições e limitações no processo de aquisição [80]. A etapa de pré-processamento dos dados, quando executada com sucesso, possibilita aos pesquisadores identificar e relatar as imperfeições presentes nos dados, fazendo com que os *datasets* sejam mais apropriados para realizar o treinamento de modelos[81]. Diversas explicações foram dadas à importância e necessidade de processamento de dados. No caso da modelagem, variações nos dados causadas por mudanças nos processos ou condições dos sistemas, bem como na coleta/transmissão dos dados podem ser modelados em conformidade com a informação alvo [82].

A primeira etapa na fase de pré-processamento remove amostras nulas (com o valor "NaN") identificadas no *dataset*. Em seguida é aplicada uma média móvel de 400 períodos na RHR para suavizar o sinal. Após isso é possível observar uma maior concentração dos parâmetros estatísticos em torno da RHR média observada como, por exemplo, a redução do desvio padrão. Todos os outros valores analisados (mínimo, máximo, primeiro, segundo e terceiro quartis) apresentaram uma maior concentração em torno da média. O próximo passo foi um redimensionamento para o período de uma hora, com substituição de valores nulos pela média. A coluna de passos (*steps*) foi removida e por fim, são retiradas quaisquer eventuais amostras nulas. As Figuras 4.10 e 4.11 mostram um exemplo de gráfico e parâmetros estatísticos dos dados após o processamento.

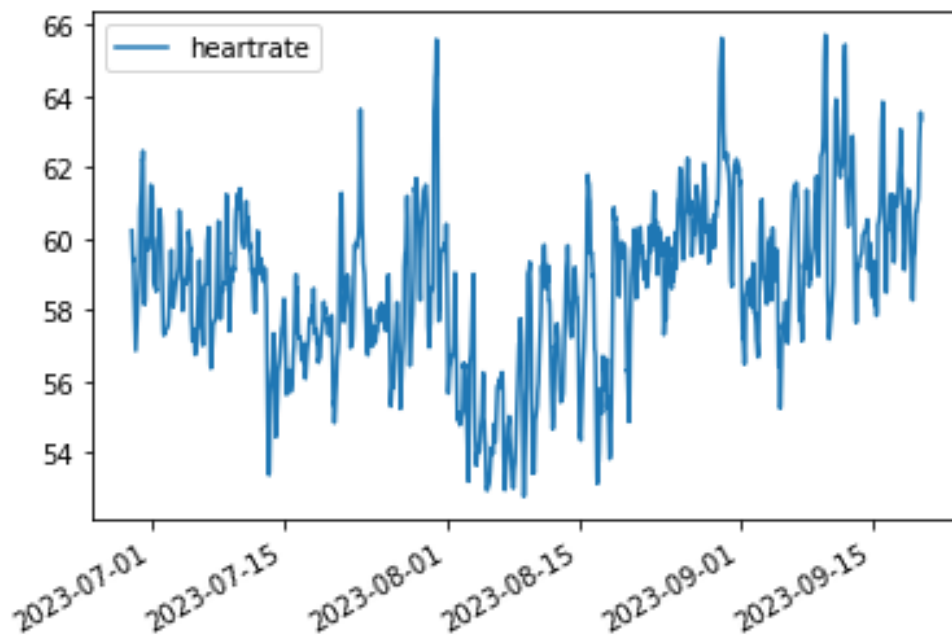


Figura 4.10: Exemplo do RHR pré-processado.

heartrate	
count	1838.000000
mean	58.604154
std	2.332640
min	52.776083
25%	57.172720
50%	58.740762
75%	60.108361
max	65.698958

Figura 4.11: Exemplo dos parâmetros estatísticos do RHR pré-processamento.

4.4.4 Correção Sazonal

A etapa seguinte inclui uma decomposição do sinal para remover quaisquer componentes de sazonalidade do sinal de RHR. Entende-se por componentes de sazonalidade os sinais que apresentam alterações discrepantes em momentos específicos e, posteriormente, retornam ao padrão que observado [83]. No caso do RHR, isso pode ocorrer em estações mais quentes, ou em épocas festivas como Natal e Ano Novo. Para isso é treinado um modelo aditivo de representação do sinal indicado na Equação 4.1 em três componentes: tendência, sazonalidade e residual. Respectivamente $t(x)$, $s(x)$ e $r(x)$.

$$f(x) = t(x) + s(x) + r(x) \quad (4.1)$$

A Figura 4.12 indica um exemplo do comportamento dessas componentes em uma série temporal. Sendo a tendência $t(x)$ responsável por indicar o crescimento ou decaimento do sinal. A componente de sazonalidade $s(x)$ apresenta o comportamento periódico. E por fim, a componente residual $r(x)$ representa a parte do sinal que não pode ser representada como um padrão de crescimento/decrescimento ou sazonalidade.




Figura 4.12: Exemplo de componentes do sinal em um modelo aditivo

Com esta representação do sinal é possível analisar somente as componentes de tendência e resíduo. Desta forma sobram do sinal original os valores que oscilam em torno desta componente. Remover a componente sazonal de uma série temporal pode resultar em uma relação mais clara entre as variáveis de entrada e saída [83]. As Figuras 4.13 e 4.14 mostram o RHR após a correção sazonal e os parâmetros estatísticos obtidos.

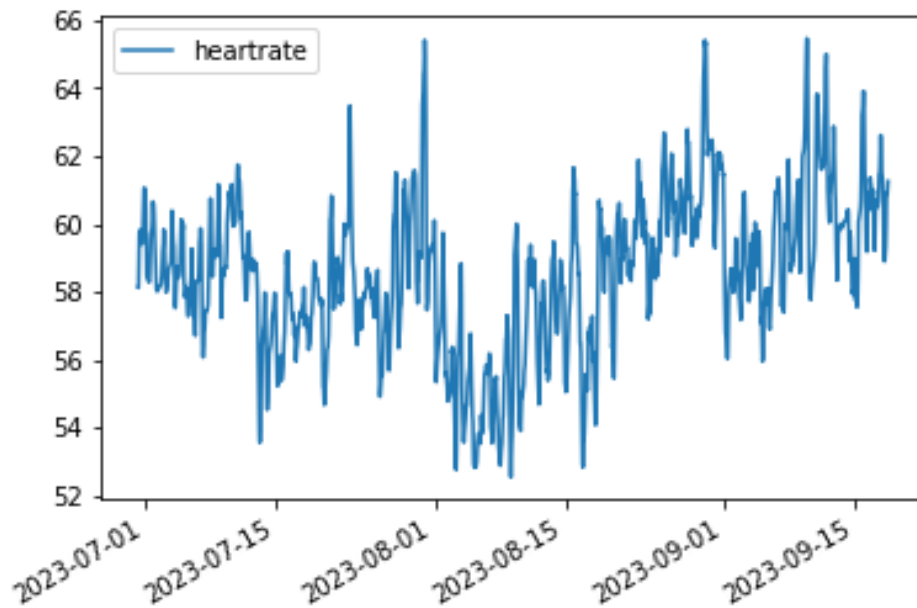


Figura 4.13: Exemplo do RHR após a correção sazonal.

heartrate	
count	1778.000000
mean	58.547834
std	2.297893
min	52.543060
25%	57.187379
50%	58.621966
75%	60.010138
max	65.468940

Figura 4.14: Exemplo dos parâmetros estatísticos do RHR pré-processamento.

4.4.5 Treinamento do Modelo

Por fim, é possível dar início ao preparo dos conjuntos de treino e teste. A partir do conjunto de dados inteiro são separadas amostras com base em parâmetros de janela deslizante. Nos conjuntos de treino o sinal é subtraído de sua média e é dividido pelo desvio padrão. Desta forma o sinal de RHR para valores de média igual a 0 e desvio padrão igual a 1. O modelo que realizou o ajuste de normalização no conjunto de treino é o mesmo que aplica a normalização do conjunto de testes.

O treino para detecção de *outliers* é baseado em uma implementação do algoritmo de *Rousseeuw e Driessen* [84] que pode ser encontrada na biblioteca *scikit-learn*, no módulo *covariance* com o nome de *EllipticEnvelope*. Esse algoritmo modela uma área elíptica ao redor das amostras do *dataset*. Os valores que ficam dentro do envelope são considerados normais e qualquer coisa fora do envelope é marcado como *outlier*. A Figura 4.15 mostra uma representação do algoritmo e percebe-se que o algoritmo funciona melhor se os dados tiverem uma distribuição normal, justificando a normalização do *dataset*.

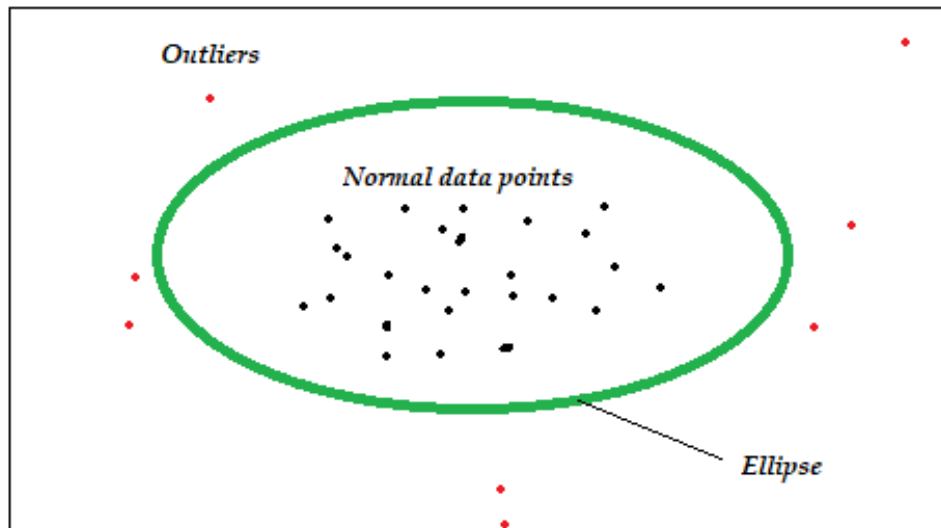


Figura 4.15: Exemplo do envelope elíptico. Adaptado de [85].

Todas as predições de possíveis anomalias são identificadas e concatenadas para que posteriormente um gráfico seja disponibilizado, identificando-as. As saídas do algoritmo e visualizações gráficas podem ser conferidas no capítulo 5 a seguir.

4.5 CONCLUSÕES ACERCA DO CAPÍTULO

Este capítulo demonstrou toda a metodologia utilizada ao longo do processo. Todo o processo foi detalhado, desde a obtenção e análise do banco de dados até a descrição do algoritmo em alto nível. É importante lembrar que para cada etapa do processo, um gráfico do RHR era gerado com o intuito de observar e comparar o refinamento dos dados. O próximo capítulo apresenta os resultados obtidos no fim do algoritmo, portanto os gráficos referente à Seção 4.4.5 serão apresentados no capítulo referente aos resultados.

5 RESULTADOS

Este capítulo apresenta as anomalias detectadas na frequência cardíaca de pacientes de COVID-19. Os *status* emitidos e detalhados na Tabela 5.1 baseiam-se em agrupamentos das últimas 24 horas e são classificados em 3 grupos: verde, amarelo e vermelho. Quando são detectadas mais do que 5 anomalias nas últimas 24 horas, é emitido o alerta vermelho; Entre 1 e 5 detectadas, o alerta é amarelo e em ambos os casos sugere-se uma investigação mais a fundo do caso com um teste para diagnóstico de COVID-19. Quando o *status* verde aparece, significa que não foram detectadas anomalias nas últimas 24 horas. A Figura 5.1 mostra um exemplo do compilado de *status* para um único indivíduo.

Os resultados atingidos por *Mishra et Al* [4] são compostos por dois algoritmos que detectam *outliers* a partir de duas *features* principais: *Resting Heart Rate* (RHR) e *Heart Rate Over Steps* (HROS). O algoritmo alvo deste trabalho utiliza a RHR e a parte de resultados envolvendo a detecção com *Heart Rate Over Steps* não será abordada. Os algoritmos em questão são do tipo não-supervisionados, ou seja, o próprio algoritmo busca uma correlação dos dados sem nenhuma entrada externa além dos dados brutos. Posto isso, os resultados obtidos serão descritos e analisados como tal.

Tabela 5.1: Identificação dos tipos de alerta emitidos pelo algoritmo

Tipo de Alerta	Anomalias detectadas
verde	0
amarelo	1 a 5
vermelho	maior que 5

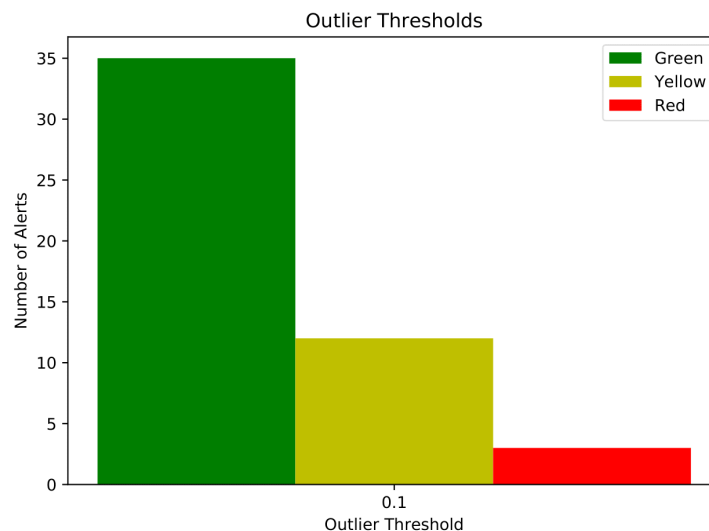


Figura 5.1: Exemplo do compilado de alertas emitidos para um indivíduo.

5.1 GRUPOS IDENTIFICADOS

Alterações na frequência cardíaca, passos diários ou tempo de sono foram detectadas em 10 indivíduos listados na Tabela 5.2. A Tabela 5.3 apresenta os 8 casos de COVID-19 com alterações fisiológicas detectadas e informações de sintomas disponível nos dados; 3 casos foram detectados antes ou durante a manifestação de sintomas, conforme a Tabela 5.4. Um caso foi detectado com pelo menos nove dias de antecedência: AS2MVDL. Os gráficos desta seção permitem visualizar as informações descritas anteriormente caso a caso. O eixo Y representa a frequência cardíaca em repouso normalizada, indicada em azul. O eixo X indica as datas de coleta do sinal fisiológico. As linhas tracejadas verde, amarela e vermelha seguem a descrição conforme indicado pela Tabela 5.1. A linha tracejada cinza indica o início dos sintomas; e a roxa representa a data de diagnóstico. Com essas informações é possível analisar os gráficos de emissão dos alertas.

Respectivamente as linhas tracejadas cinza e roxa indicam as datas de sintomas e de diagnóstico

Tabela 5.2: Indivíduos com alterações fisiológicas detectadas pelo algoritmo.

ID indivíduo	Gráfico
A0VFT1N	Figura 5.2
A3OU183	Figura 5.3
A4G0044	Figura 5.4
AOYM4KG	Figura 5.5
AA2KP1S	Figura 5.6
AKXN5ZZ	Figura 5.7
APGIB2T	Figura 5.8
AS2MVDL	Figura 5.9
AURCTAK	Figura 5.10
AYWIEKR	Figura 5.11

Tabela 5.3: Casos com alterações fisiológicas detectadas e informações de sintomas

ID indivíduo	Gráfico
A0VFT1N	Figura 5.2
A3OU183	Figura 5.3
A4G0044	Figura 5.4
AOYM4KG	Figura 5.5
AA2KP1S	Figura 5.6
APGIB2T	Figura 5.8
AS2MVDL	Figura 5.9
AYWIEKR	Figura 5.11

Tabela 5.4: Casos detectados antes de apresentar sintomas

ID indivíduo	Gráfico
A4G0044	Figura 5.4
AOYM4KG	Figura 5.5
AS2MVDL	Figura 5.9

5.2 ANÁLISE E DISCUSSÃO DOS RESULTADOS

O algoritmo de detecção de anomalias do RHR foi reproduzido com sucesso, identificando anomalias dentro do RHR normalizado de cada indivíduo. Dentre os pacientes diagnosticados com COVID-19, destaca-se três tipos de casos: casos com anomalias detectadas pelo algoritmo; casos com anomalias detectadas pelo algoritmo contendo datas de sintomas e diagnóstico; casos com anomalias detectadas antes do início dos sintomas.

Os casos de sucessos deste algoritmo são as detecções de anomalias antes da aparição dos sintomas, mostradas na Tabela 5.4. A linha pontilhada em cinza indica o aparecimento dos sintomas, enquanto a linha pontilhada roxa mostra o diagnóstico positivo do COVID-19. Este cenário, acompanhado do teste PCR, possibilita um pré-diagnóstico mais rápido, permitindo realizar a quarentena com antecedência e por consequência limitando a taxa de infecção do vírus. Também é interessante evidenciar os resultados obtidos com os indivíduos descritos na Tabela 5.3. Ainda que não tenham sido identificadas anomalias antes da manifestação de sintomas, os alertas servem como um aviso adicional para indicar a realização de um teste. O mesmo serve para os casos em que os indivíduos acometidos por COVID-19 não relataram datas de sintomas ou diagnóstico.

Percebe-se que o algoritmo foi capaz de identificar as irregularidades no RHR nos casos de COVID-19 indicados. As Figuras 5.2 a 5.11 mostram essas detecções. Os resultados alcançados foram os mesmos em *MISHRA, T. et al.* [4]. Essa contribuição corrobora com o uso dos *wearables* para a detecção em grande escala e em tempo real de infecções respiratórias, até antes da presença dos sintomas. Mesmo considerando o pior caso, no qual há uma detecção de anomalia mas o paciente testa negativo para o COVID-19, não há desvantagem para o paciente. É válido destacar que o algoritmo não busca substituir o diagnóstico PCR, mas sim auxiliar a população na detecção dos sintomas do vírus, incentivando a realização do teste PCR, diminuindo a exposição desnecessária e sobrecarga do sistema de saúde.




Figura 5.2: Anomalias RHR do indivíduo AOVFT1N




Figura 5.3: Anomalias RHR do indivíduo A3OU183




Figura 5.4: Anomalias RHR do indivíduo A4G0044




Figura 5.5: Anomalias RHR do indivíduo AOYM4KG




Figura 5.6: Anomalias RHR do indivíduo AA2KP1S




Figura 5.7: Anomalias RHR do indivíduo AKXN5ZZ




Figura 5.8: Anomalias RHR do indivíduo APGIB2T




Figura 5.9: Anomalias RHR do indivíduo AS2MVDL




Figura 5.10: Anomalias RHR do indivíduo AURCTAK




Figura 5.11: Anomalias RHR do indivíduo AYWIEKR

5.3 CONCLUSÕES DO CAPÍTULO

Este capítulo demonstrou os resultados obtidos com a metodologia descrita no capítulo 4. Após a leitura desta seção foi possível compreender a forma como são definidos os status de avaliação cardíaca e como eles se apresentam nas saídas gráficas de série temporal. Outras informações importantes foram abordadas, por exemplo as datas dos sintomas e de diagnósticos. Em suma, o algoritmo consegue identificar anomalias no RHR e sugere que o indivíduo busque auxílio médico.

6 CONCLUSÃO

A evolução de dispositivos medidores de sinais biológicos em termos de miniaturização, acurácia e portabilidade facilitou a captura dessas informações. O campo da cardiologia utiliza há muito tempo dispositivos vestíveis para monitorar frequência e ritmo cardíacos [1]. Com a realização deste trabalho foi possível compreender a possibilidade de analisar registros de passos e frequências cardíacas para detectar doenças de forma pouco invasiva e economicamente acessível. Tudo isso foi permitido com o avanço da tecnologia de sensoriamento e processamento embarcada em dispositivos vestíveis. Estes são uma alternativa tecnológica de baixo custo que possibilita o monitoramento de sinais biológicos com uma abordagem promissora em situações que necessitam a captura de sinais fisiológicos diversas vezes ao dia [68]. Segundo *Reeder et al* [2], os *smartwatches* apresentam potencial para transformar os cuidados e diagnósticos na área da saúde por diversos motivos. Dentre eles a familiaridade para a maioria das pessoas e aumento da disponibilidade deste tipo de dispositivo ao consumidor.

É comum em determinadas áreas de pesquisa encontrar dificuldades em identificar alarmes falsos devido a natureza de padrões desconhecidos contidos nos dados [86]. Tudo isso ressalta a importância da detecção de *outliers*, que vem sendo reconhecida como uma importante ferramenta de descoberta, habilitando a construção de melhores sistemas de aprendizado, tomada de decisão e sistemas especialistas [87]. Outra constatação importante deste trabalho é que a identificação de amostras inconsistentes com a maioria das observações em um conjunto de dados multidimensional pode ser uma tarefa difícil de realizar por meio de inspeção visual [88].

O algoritmo estudado teve a sua estrutura de funcionamento abordada em detalhes, e foram discutidas passo a passo as decisões de implementação tomadas pelos autores. Foi possível observar nas etapas de pré-processamento a aplicação de médias móveis funcionando como filtro passa-baixa, uma alternativa de filtragem em sinais discretizados. Bem como a decisão tomada sobre o que fazer com valores nulos em diferentes etapas. Por exemplo na etapa de reamostragem, substituindo-os pela média. Os resultados obtidos expandem as possibilidades de realização de um diagnóstico e também elucidam um novo método para testagem contínua de doenças relacionadas ao sistema cardiorrespiratório. A revisão sistemática realizada no capítulo 3 respalda a visibilidade do tema no meio acadêmico, apresentando um panorama das pesquisas na área de equipamentos vestíveis aplicados a sinais fisiológicos. O que confirma a viabilidade nas pesquisas com esses tipos de dispositivos e possivelmente no futuro os algoritmos desenvolvidos possam trazer benefício da sociedade. De maneira que o usuário da tecnologia proposta possa receber notificações caso seja detectada alguma anomalia fisiológica. Sugerindo a realização de exames para o diagnóstico médico de doenças.

6.1 TRABALHOS FUTUROS

Como proposta de trabalhos futuros é sugerido a produção de um novo banco de dados, com outros voluntários, no intuito de melhorar a robustez do algoritmo e explorar os novos resultados. Além disso, utilizar dados referentes à oxigenação no sangue, uma vez que a infecção do COVID-19 afeta as funções cardiopulmonares. Também seria interessante a criação de uma API (*Application Programming Interface*) para que novas pesquisas sejam desenvolvidas com os resultados obtidos.

No que tange a complexidade e precisão do algoritmo, é válido analisar o algoritmo que realiza detecção de anomalias com base na *feature Heart Rate Over Steps* (HROS) e desta forma será possível verificar a parte complementar aos estudos aqui descritos. Seria interessante a produção de um novo banco de dados com o intuito de melhorar a robustez do algoritmo. Podem ser explorados caminhos para aumentar a robustez do diagnóstico obtido: variação de parâmetros do algoritmo atual, modificação das técnicas utilizadas ou buscar meios para aumentar a quantidade de amostras do *dataset*. Para otimizar os parâmetros do algoritmo atual, podem ser utilizadas técnicas como: *grid search*, *random search* ou algoritmo genético [89]. Seguindo pelo caminho da modificação de técnicas escolhidas, pode-se avaliar opções de algoritmos com diferentes premissas de correção sazonal [90, 91].

REFERÊNCIAS BIBLIOGRÁFICAS

- 1 PEVNICK, J. M.; BIRKELAND, K.; ZIMMER, R.; ELAD, Y.; KEDAN, I. Wearable technology for cardiology: An update and framework for the future. *Trends in Cardiovascular Medicine*, v. 28, n. 2, p. 144–150, 2018. ISSN 1050-1738. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1050173817301202>>.
- 2 REEDER, B.; DAVID, A. Health at hand: A systematic review of smart watch uses for health and wellness. *Journal of Biomedical Informatics*, v. 63, p. 269–276, 2016. ISSN 1532-0464. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1532046416301137>>.
- 3 SESHADRI, D. R.; DAVIES, E. V.; HARLOW, E. R.; HSU, J. J.; KNIGHTON, S. C.; WALKER, T. A.; VOOS, J. E.; DRUMMOND, C. K. Wearable sensors for covid-19: A call to action to harness our digital infrastructure for remote patient monitoring and virtual assessments. *Frontiers in Digital Health*, v. 2, p. 8, 2020. ISSN 2673-253X. Disponível em: <"<https://doi.org/10.3389/fdgth.2020.00008>">.
- 4 MISHRA, T.; WANG, M.; METWALLY, A.; BOGU, G.; BROOKS, A.; BAHMANI, A.; ALAVI, A.; CELLI, A.; HIGGS, E.; DAGAN-ROSENFELD, O.; FAY, B.; KIRKPATRICK, S.; KELLOGG, R.; GIBSON, M.; WANG, T.; HUNTING, E.; MAMIC, P.; GANZ, A.; ROLNIK, B.; SNYDER, M. Pre-symptomatic detection of covid-19 from smartwatch data. *Nature Biomedical Engineering*, v. 4, p. 1–13, 12 2020.
- 5 DEGHANI, M.; DANGELICO, R. M. Smart wearable technologies: Current status and market orientation through a patent analysis. In: *2017 IEEE International Conference on Industrial Technology (ICIT)*. [S.l.: s.n.], 2017. p. 1570–1575.
- 6 PASCOE, J. The smartwatch. p. 204–206, 2006.
- 7 STARNER, T.; MANN, S.; RHODES, B.; LEVINE, J.; HEALEY, J.; KIRSCH, D.; PICARD, R. W.; PENTLAND, A. Augmented Reality through Wearable Computing. *Presence: Teleoperators and Virtual Environments*, v. 6, n. 4, p. 386–398, 08 1997. Disponível em: <<https://doi.org/10.1162/pres.1997.6.4.386>>.
- 8 RAWASSIZADEH, R.; PRICE, B. A.; PETRE, M. Wearables: Has the age of smartwatches finally arrived? *Commun. ACM*, Association for Computing Machinery, New York, NY, USA, v. 58, n. 1, p. 45–47, dez. 2014. ISSN 0001-0782. Disponível em: <<https://doi.org/10.1145/2629633>>.
- 9 BERNAERTS, Y.; DRUWÉ, M.; STEENSELS, S.; VERMEULEN, J.; SCHÖNING, J. The office smartwatch: Development and design of a smartwatch app to digitally augment interactions in an office environment. In: *Proceedings of the 2014 Companion Publication on Designing Interactive Systems*. New York, NY, USA: Association for Computing Machinery, 2014. (DIS Companion '14), p. 41–44. ISBN 9781450329033. Disponível em: <<https://doi.org/10.1145/2598784.2602777>>.
- 10 KIM, K. J.; SHIN, D. An acceptance model for smart watches: Implications for the adoption of future wearable technology. *Internet Research: Electronic Networking Applications and Policy*, v. 25, 08 2015.
- 11 CHARLTON, A. *From IBM to Microsoft - A Brief History of The Smartwatch*. 2013. Disponível em: <<https://www.ibtimes.co.uk/smartwatch-history-apple-iwatch-samsung-galaxy-gear-503752>>. Acesso em: 27 de Setembro de 2021.
- 12 TECH, M. *History of SmartWatch*. 2016. Disponível em: <<http://mount-tech.blogspot.com/2016/11/history-of-smart-watch.html>>. Acesso em: 05 de Outubro de 2021.

- 13 CASIO. *History of SmartWatch*. Disponível em: <<https://www.casio.com/products/watches/databank/ca53w-1>>. Acesso em: 05 de Outubro de 2021.
- 14 NARAYANASWAMI, C.; KAMIJOH, N.; RAGHUNATH, M.; INOUE, T.; CIPOLLA, T.; SANFORD, J.; SCHLIG, E.; VENKITESWARAN, S.; GUNIGUNTALA, D.; KULKARNI, V.; YAMAZAKI, K. Ibm's linux watch: The challenge of miniaturization. *Computer*, IEEE Computer Society Press, Washington, DC, USA, v. 35, n. 1, p. 33–41, jan 2002. ISSN 0018-9162. Disponível em: <<https://doi.org/10.1109/2.976917>>.
- 15 POLAR. *Polar FT1 com cinta peitoral*. Disponível em: <<https://www.pngwing.com/pt/search?q=polar+H7>>. Acesso em: 05 de Outubro de 2021.
- 16 POLAR. *Polar Vantage NV*. Disponível em: <<https://docs.google.com/document/d/19WF430iyaaifQqEfdBlG9GiD0B92V4TQXkhG43lBuHA/edit>>. Acesso em: 05 de Outubro de 2021.
- 17 POLAR. *POLAR EQUINE APP FEATURES*. Disponível em: <<https://support.polar.com/en/viewing-the-horse-s-heart-rate>>. Acesso em: 05 de Outubro de 2021.
- 18 WILLIAMS, W. *The evolution of the smartwatch – from IBM Watch-Pad to Apple Watch*. 2013. Disponível em: <<https://betanews.com/2015/05/29/the-evolution-of-the-smartwatch-from-ibm-watchpad-to-apple-watch/#comments>>. Acesso em: 27 de Setembro de 2021.
- 19 VERIZON. *A timeline: A brief history of Apple Watch*. Disponível em: <<https://www.verizon.com/articles/brief-history-of-apple-watch/>>. Acesso em: 27 de Setembro de 2021.
- 20 GARMIN. *vivosmart® 4*. Disponível em: <<https://www.garmin.com/pt-PT/p/605739>>. Acesso em: 05 de Outubro de 2021.
- 21 FITBIT. *FitBit Inspire 2*. Disponível em: <<https://www.fitbit.com/global/us/products/trackers/inspire2>>. Acesso em: 05 de Outubro de 2021.
- 22 XIAOMI. *Mi Smart Band 6*. Disponível em: <<https://www.mi.com/global/product/mi-smart-band-6/>>. Acesso em: 05 de Outubro de 2021.
- 23 HEALTHLINE. *Thank You, Smartwatches: Monitoring Diabetes from Your Wrist*. Disponível em: <<https://www.healthline.com/diabetesmine/wrist-smartwatches-and-diabetes-tech#FreeStyle-Libre>>. Acesso em: 27 de Setembro de 2021.
- 24 LIM, S. *Global Smartwatch Market Revenue*. Disponível em: <<https://www.counterpointresearch.com/global-smartwatch-market-revenue-h1-2020/>>. Acesso em: 27 de Setembro de 2021.
- 25 ZOOM. *Melhor smartwatch: confira as opções para comprar em 2021*. Disponível em: <<https://www.zoom.com.br/smartwatch/deumzoom/melhores-smartwatch#xiaomi-amazfit-gts>>. Acesso em: 27 de Setembro de 2021.
- 26 HARADA, E. *5 smartwatches que estão em alta no Brasil*. Disponível em: <<https://www.tecmundo.com.br/produto/150092-5-smartwatches-alta-brasil.htm>>. Acesso em: 27 de Setembro de 2021.
- 27 FYE, W. B. A history of the origin, evolution, and impact of electrocardiography. *The American journal of cardiology*, v. 73, n. 13, p. 937–949, may 1994. Disponível em: <[https://doi.org/10.1016/0002-9149\(94\)90135-x](https://doi.org/10.1016/0002-9149(94)90135-x)>.
- 28 GUARISCH, A. *Uma breve história do eletrocardiograma*. Disponível em: <<https://cbc.org.br/artigo-uma-breve-historia-do-eletrocardiograma/>>. Acesso em: 05 de Outubro de 2021.

- 29 ALGHATRIF, M.; LINDSAY, J. A brief review: history to understand fundamentals of electrocardiography. *Journal of Community Hospital Internal Medicine Perspectives*, Taylor & Francis, v. 2, n. 1, p. 14383, 2012. PMID: 23882360. Disponível em: <<https://doi.org/10.3402/jchimp.v2i1.14383>>.
- 30 GIFFONI, R. M. T. R. T. Breve história da eletrocardiografia. *Revista Médica de Minas Gerais*, Revista Médica de Minas Gerais, v. 20.2, p. 271–272, Abril 2010.
- 31 DIAGNÓSTICOS, E. *Exame de holter: o que é, para que serve e como é feito*. Disponível em: <<https://eigierdiagnosticos.com.br/blog/exame-de-holter/>>. Acesso em: 05 de Outubro de 2021.
- 32 POLAR. *POLAR'S 40 YEARS OF INCREDIBLE FIRSTS*. Disponível em: <<https://www.polar.com/blog/40-years-of-incredible-firsts-polar-history/>>. Acesso em: 05 de Outubro de 2021.
- 33 INSTITUTE, T. H. *Electrocardiogram*. Disponível em: <<https://www.texasheart.org/heart-health/heart-information-center/topics/electrocardiogram/>>. Acesso em: 05 de Outubro de 2021.
- 34 UEM-MALL. *UHM-2 Wearable EKG/ECG Monitor*. Disponível em: <<https://www.uem-mall.com/shop/wearable-ekg-ecg-monitor>>. Acesso em: 05 de Outubro de 2021.
- 35 POLAR. *Abnormal Heart Rate Readings During Exercise*. Disponível em: <https://support.polar.com/en/support/FAQs/Abnormal_Heart_Rate_Readings_During_Exercise>. Acesso em: 05 de Outubro de 2021.
- 36 VALENCELL. *Optical Heart Rate Monitoring: What You Need to Know*. Disponível em: <<https://valencell.com/blog/optical-heart-rate-monitoring-what-you-need-to-know/>>. Acesso em: 05 de Outubro de 2021.
- 37 APPLE, M. H. *Fitbit Photoplethysmography green light to measure blood flow*. Disponível em: <<https://www.myhealthyapple.com/wp-content/uploads/Fitbit-Photoplethysmography-green-light-to-measure-blood-flow.jpg>>. Acesso em: 05 de Outubro de 2021.
- 38 FOUAD, R.; OMER, O.; ALI, A.-M.; ALY, M. Refining roi selection for real-time remote photoplethysmography using adaptive skin detection. In: . [S.l.]: International Conference on Innovative Trends in Computer Engineering, 2019. p. 70–75.
- 39 RUNDO, F.; CONOCI, S.; ORTIS, A.; BATTIATO, S. An advanced bio-inspired photoplethysmography (ppg) and ecg pattern recognition system for medical assessment. *Sensors*, v. 18, n. 2, 2018. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/18/2/405>>.
- 40 HERN, A. *How tattoogate has highlighted a wider problem with wearables*. 2015. Disponível em: <<https://www.theguardian.com/technology/2015/apr/30/how-tattoogate-has-highlighted-a-wider-problem-with-wearables>>. Acesso em: 05 de Outubro de 2021.
- 41 WEILER, D. T.; VILLAJUAN, S. O.; EDKINS, L.; CLEARY, S.; SALEEM, J. J. Wearable heart rate monitor technology accuracy in research: A comparative study between ppg and ecg technology. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, v. 61, n. 1, p. 1292–1296, 2017. Disponível em: <<https://doi.org/10.1177/1541931213601804>>.
- 42 PHAN, D.; SIONG, L. Y.; PATHIRANA, P. N.; SENEVIRATNE, A. Smartwatch: Performance evaluation for long-term heart rate monitoring. In: *2015 International Symposium on Bioelectronics and Bioinformatics (ISBB)*. [S.l.: s.n.], 2015. p. 144–147.

- 43 MENOWN, I. B. A.; DAVIES, S.; GUPTA, S.; KALRA, P. R.; LANG, C. C.; MORLEY, C.; PADMANABHAN, S. Resting heart rate and outcomes in patients with cardiovascular disease: Where do we currently stand? *Cardiovascular Therapeutics*, v. 31, n. 4, p. 215–223, 2013. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1755-5922.2012.00321.x>>.
- 44 KUMAR, P. S. U. K. *What Is a Good Resting Heart Rate by Age?* 2019. Disponível em: <https://www.medicinenet.com/what_is_a_good_resting_heart_rate_by_age/article.htm>. Acesso em: 05 de Outubro de 2021.
- 45 RADIN, J.; WINEINGER, N.; TOPOL, E.; STEINHUBL, S. Harnessing wearable device data to improve state-level real-time surveillance of influenza-like illness in the usa: a population-based study. *The Lancet Digital Health*, v. 2, p. e85–e93, 02 2020.
- 46 QUER, G.; RADIN, J.; GADALETA, M.; BACA-MOTES, K.; ARINIELLO, L.; RAMOS, E.; KHETERPAL, V.; TOPOL, E.; STEINHUBL, S. Wearable sensor data and self-reported symptoms for covid-19 detection. *Nature Medicine*, v. 27, p. 1–5, 01 2021.
- 47 RUSSELL, A.; HENEGHAN, C.; VENKATRAMAN, S. Investigation of an estimate of daily resting heart rate using a consumer wearable device. *medRxiv*, Cold Spring Harbor Laboratory Press, 2019. Disponível em: <<https://www.medrxiv.org/content/early/2019/10/18/19008771>>.
- 48 ETIWY, M.; AKHRASS, Z.; GILLINOV, L.; ALASHI, A.; WANG, R.; BLACKBURN, G.; GILLINOV, S.; PHELAN, D.; GILLINOV, A.; HOUGHTALING, P.; JAVADIKASGARI, H.; DESAI, M. Accuracy of wearable heart rate monitors in cardiac rehabilitation. *Cardiovascular Diagnosis and Therapy*, v. 9, 05 2019.
- 49 PIWEK, L.; ELLIS, D. A.; ANDREWS, S.; JOINSON, A. The rise of consumer health wearables: Promises and barriers. *PLOS Medicine*, Public Library of Science, v. 13, n. 2, p. 1–9, 02 2016. Disponível em: <<https://doi.org/10.1371/journal.pmed.1001953>>.
- 50 MCCALL, W. V. A rest-activity biomarker to predict response to ssris in major depressive disorder. *Journal of Psychiatric Research*, v. 64, p. 19–22, 2015. ISSN 0022-3956. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0022395615000679>>.
- 51 KREBS, P.; PROCHASKA, J.; ROSSI, J. A meta-analysis of computer-tailored interventions for health behavior change. *Preventive medicine*, v. 51, p. 214–21, 09 2010.
- 52 BRAZILIENSE, C. *Apple Watch salva vida de idoso de 78 anos após queda e desmaio nos EUA*. Disponível em: <<https://www.correiobraziliense.com.br/mundo/2021/07/4935889-apple-watch-salva-vida-de-idoso-de-78-anos-apos-queda-e-desmaio-nos-eua.html>>. Acesso em: 05 de Outubro de 2021.
- 53 DIGITAL, O. *Apple Watch ‘salva vida’ de homem que caiu no gelo com função de emergência*. Disponível em: <<https://olhardigital.com.br/2021/03/12/reviews/apple-watch-salva-vida-de-homem-que-caiu-no-gelo/>>. Acesso em: 05 de Outubro de 2021.
- 54 UOL. *Enchente, queda, ataque cardíaco: 6 vezes em que o Apple Watch salvou vidas*. Disponível em: <<https://www.uol.com.br/tilt/noticias/redacao/2021/05/02/enchente-acidente-infarto-seis-vezes-em-que-o-apple-watch-salvou-vidas.html>>. Acesso em: 05 de Outubro de 2021.
- 55 TIMES, T. N. Y. *Fitbits Detect Lasting Changes After Covid-19*. Disponível em: <<https://www.nytimes.com/2021/07/07/health/covid-fitbit-wearables.html#click=https://t.co/rQmsTny6Qh>>. Acesso em: 05 de Outubro de 2021.

- 56 PFEIZER. *FIBRILAÇÃO ATRIAL*. Disponível em: <<https://www.pfizer.com.br/sua-saude/seu-coracao/fibrilacao-atrial/>>. Acesso em: 05 de Outubro de 2021.
- 57 UOL. *Oxímetro da Apple é preciso para pacientes em hospitais, diz estudo da USP*. Disponível em: <https://www.uol.com.br/tilt/noticias/redacao/2021/09/30/oximetro-do-apple-watch-e-tao-bom-quanto-hospitalares-diz-estudo-da-usp.amp.htm?__twitter_impression=true/>. Acesso em: 05 de Outubro de 2021.
- 58 LI, X.; DUNN, J.; SALINS, D.; ZHOU, G.; ZHOU, W.; ROSE, S. M. S.-F.; PERELMAN, D.; COLBERT, E.; RUNGE, R.; REGO, S.; SONECHA, R.; DATTA, S.; MCLAUGHLIN, T.; SNYDER, M. P. Digital health: Tracking physiomes and activity using wearable biosensors reveals useful health-related information. *PLOS Biology*, Public Library of Science, v. 15, n. 1, p. 1–30, 01 2017. Disponível em: <<https://doi.org/10.1371/journal.pbio.2001402>>.
- 59 KOURTIS, L.; REGELE, O.; WRIGHT, J.; JONES, G. Digital biomarkers for alzheimer’s disease: the mobile/wearable devices opportunity. *npj Digital Medicine*, v. 2, 12 2019.
- 60 CUMMINS, P.; SERRUYS, P. Sensors, wearables and devices in the e-age: tomorrow’s world today. *EuroIntervention: journal of EuroPCR in collaboration with the Working Group on Interventional Cardiology of the European Society of Cardiology*, v. 10, p. 1373, 04 2015.
- 61 OLIVEIRA, A.; LUCAS, T.; IQUIAPAZA, R. What has the covid-19 pandemic taught us about adopting preventive measures? *Texto e Contexto Enfermagem*, v. 29, 04 2020.
- 62 TOZATO, C.; FERREIRA, B.; DALAVINA, J.; MOLINARI, C.; ALVES, V. Cardiopulmonary rehabilitation in post-covid-19 patients: case series. *Revista Brasileira de terapia intensiva*, v. 33, p. 167–171, 01 2021.
- 63 LIMA, F. E.; ALBUQUERQUE, N.; FLORENCIO, S.; FONTENELE, M.; QUEIROZ, A.; LIMA, G.; FIGUEIREDO, L.; AMORIM, S.; BARBOSA, L. Intervalo de tempo decorrido entre o início dos sintomas e a realização do exame para covid-19 nas capitais brasileiras, agosto de 2020. *Epidemiologia e Serviços de Saúde*, v. 30, 11 2020.
- 64 ZHU, T.; WATKINSON, P.; CLIFTON, D. Smartwatch data help detect covid-19. *Nature Biomedical Engineering*, v. 4, p. 1125–1127, 12 2020.
- 65 SETHURAMAN, N.; JEREMIAH, S. S.; RYO, A. Interpreting Diagnostic Tests for SARS-CoV-2. *JAMA*, v. 323, n. 22, p. 2249–2251, 06 2020. ISSN 0098-7484. Disponível em: <<https://doi.org/10.1001/jama.2020.8259>>.
- 66 LU, T.-C.; FU, C.-M.; MA, M.; FANG, C.-C.; TURNER, A. Healthcare applications of smart watches: A systematic review. *Applied Clinical Informatics*, v. 7, p. 850–869, 09 2016.
- 67 DÖRR, M.; NOHTURFFT, V.; BRASIER, N.; BOSSHARD, E.; DJURDJEVIC, A.; GROSS, S.; RAICHLE, C. J.; RHINISPERGER, M.; STÖCKLI, R.; ECKSTEIN, J. The watch af trial: Smartwatches for detection of atrial fibrillation. *JACC: Clinical Electrophysiology*, v. 5, n. 2, p. 199–208, 2019. Disponível em: <<https://www.jacc.org/doi/abs/10.1016/j.jacep.2018.10.006>>.
- 68 LI, X.; DUNN, J.; SALINS, D.; ZHOU, G.; ZHOU, W.; ROSE, S. M. S.-F.; PERELMAN, D.; COLBERT, E.; RUNGE, R.; REGO, S.; SONECHA, R.; DATTA, S.; MCLAUGHLIN, T.; SNYDER, M. Digital health: Tracking physiomes and activity using wearable biosensors reveals useful health-related information. *PLOS Biology*, v. 15, p. e2001402, 01 2017.

- 69 WONG, C. K.; HO, D. T. Y.; TAM, A. R.; ZHOU, M.; LAU, Y. M.; TANG, M. O. Y.; TONG, R. C. F.; RAJPUT, K. S.; CHEN, G.; CHAN, S. C.; SIU, C. W.; HUNG, I. F. N. Artificial intelligence mobile health platform for early detection of covid-19 in quarantine subjects using a wearable biosensor: protocol for a randomised controlled trial. *BMJ Open*, British Medical Journal Publishing Group, v. 10, n. 7, 2020. ISSN 2044-6055. Disponível em: <<https://bmjopen.bmj.com/content/10/7/e038555>>.
- 70 HELLEWELL, J.; ABBOTT, S.; GIMMA, A.; BOSSE, N. I.; JARVIS, C. I.; RUSSELL, T. W.; MUNDAY, J. D.; KUCHARSKI, A. J.; EDMUNDS, W. J.; GROUP, C. nCoV working; FUNK, S.; EGGO, R. M. Feasibility of controlling 2019-ncov outbreaks by isolation of cases and contacts. *medRxiv*, Cold Spring Harbor Laboratory Press, 2020. Disponível em: <<https://www.medrxiv.org/content/early/2020/02/11/2020.02.08.20021162>>.
- 71 NATARAJAN, A.; SU, H.-W.; HENEGHAN, C. Assessment of physiological signs associated with covid-19 measured using wearable devices. *npj Digital Medicine*, v. 3, 12 2020.
- 72 OLIPHANT, T. E. Python for scientific computing. *Computing in Science & Engineering*, IEEE, v. 9, n. 3, p. 10–20, 2007.
- 73 AYER, V. M.; MIGUEZ, S.; TOBY, B. H. Why scientists should learn to program in python. *Powder Diffraction*, Cambridge University Press, v. 29, n. S2, p. S48–S64, 2014.
- 74 MCKINNEY, W. pandas: a foundational python library for data analysis and statistics.
- 75 OLIPHANT, T. E. *A guide to NumPy*. [S.l.]: Trelgol Publishing USA, 2006. v. 1.
- 76 MATPLOTLIB. *Matplotlib: Visualization with Python*. Disponível em: <<https://matplotlib.org/>>. Acesso em: 05 de Outubro de 2021.
- 77 STATSMODELS. *statistical models, hypothesis tests, and data exploration*P. Disponível em: <<https://www.statmodels.org/stable/index.html>>. Acesso em: 05 de Outubro de 2021.
- 78 PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.
- 79 KOTSIANTIS, S. B.; KANELLOPOULOS, D.; PINTELAS, P. E. *Data Preprocessing for Supervised Learning*. 2006.
- 80 GARCIA, S.; RAMÍREZ-GALLEGO, S.; LUENGO, J. e; AL. et. *Big data preprocessing: methods and prospects*. 2016.
- 81 FELIX, E. A.; LEE, S. P. *Systematic literature review of preprocessing techniques for imbalanced data*. 2019.
- 82 FAMILI, A.; SHEN, W.-M.; WEBER, R.; SIMOUDIS, E. *Data Preprocessing and Intelligent Data Analysis*. 1996.
- 83 BROWNLEE, J. *How to Identify and Remove Seasonality from Time Series Data with Python*. 2016. Acesso em: 30/10/2021. Disponível em: <<https://machinelearningmastery.com/time-series-seasonality-with-python/>>.
- 84 ROUSSEEUW, P. J.; DRIESSEN, K. V. *A Fast Algorithm for the Minimum Covariance Determinant Estimator*. 1999.

- 85 ALAM, M. *Machine learning for anomaly detection: Elliptic Envelope*. Disponível em: <<https://towardsdatascience.com/machine-learning-for-anomaly-detection-elliptic-envelope-2c90528df0a6>>. Acesso em: 05 de Outubro de 2021.
- 86 BHAGAT, H.; PRIYA, S.; ADITYA, K. *Outlier Detection Based on Machine Learning Techniques*. 2020.
- 87 DURAJ, A.; SZCZEPANIAK, P. Outlier detection in data streams — a comparative study of selected methods. *Procedia Computer Science*, v. 192, p. 2769–2778, 01 2021.
- 88 AFZAL, S.; AFZAL, A.; AMIN, M.; SALEEM, S.; ALI, N.; SAJID, M. *A Novel Approach for Outlier Detection in Multivariate Data*. 2021.
- 89 LIASHCHYNSKYI, P.; LIASHCHYNSKYI, P. *Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS*. 2019.
- 90 HILLMER, S. C.; TIAO, G. C. *An ARIMA-Model-Based Approach to Seasonal Adjustment*. 1982.
- 91 HARVEY, A.; KOOPMAN, S. J.; RIANI, M. The modeling and seasonal adjustment of weekly observations. *Journal of Business & Economic Statistics*, Taylor Francis, v. 15, n. 3, p. 354–368, 1997. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/07350015.1997.10524713>>.