



UEPB

**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS I**

**CENTRO DE CIÊNCIAS E TECNOLOGIA
DEPARTAMENTO DE COMPUTAÇÃO**

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA EM SAÚDE

DANIELLA LIMA DE CARVALHO

**APLICAÇÃO DE REDES NEURAIS RECORRENTES PARA PREVISÃO DE
SÉRIES TEMPORAIS**

**CAMPINA GRANDE
2023**

DANIELLA LIMA DE CARVALHO

**APLICAÇÃO DE REDES NEURAIS RECORRENTES PARA PREVISÃO DE
SÉRIES TEMPORAIS**

Trabalho de Dissertação apresentado ao Programa de Pós-graduação em Ciência e Tecnologia em Saúde da Universidade Estadual da Paraíba, como requisito para à obtenção do título de Mestre em Ciência e Tecnologia em Saúde

Área de concentração: Tecnologia em Saúde.

Orientador: Prof. Dr. Paulo Eduardo e Silva Barbosa

**CAMPINA GRANDE
2023**

É expressamente proibido a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano do trabalho.

C331a Carvalho, Daniella Lima de.
Aplicação de redes neurais recorrentes para previsão de séries temporais [manuscrito] / Daniella Lima de Carvalho. - 2023.
82 p. : il. colorido.

Digitado.
Dissertação (Mestrado em Profissional em Ciência e Tecnologia em Saúde) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2023.
"Orientação : Prof. Dr. Paulo Eduardo e Silva Barbosa, Coordenação do Curso de Computação - CCT. "
1. Aprendizado de máquina. 2. Redes neurais. 3. Série temporal. I. Título

21. ed. CDD 006.3

DANIELLA LIMA DE CARVALHO

APLICAÇÃO DE REDES NEURAIS RECORRENTES PARA PREVISÃO DE SÉRIES TEMPORAIS

Dissertação apresentada ao Programa de Pós-Graduação em Ciência e Tecnologia em Saúde da Universidade Estadual da Paraíba como requisito para obtenção do título de Mestre em Ciência e Tecnologia em Saúde.

Dissertação aprovada em: 28/08/2023

BANCA EXAMINADORA:



Prof. Dr. Paulo Eduardo e Silva Barbosa
Universidade Estadual da Paraíba (UEPB)



Profa. Dra. Kezia de Vasconcelos Dantas
Universidade Estadual da Paraíba (UEPB)

Prof. Dr. Carlos Eduardo Santos Pires
Universidade Federal de Campina Grande (UFCG)

AGRADECIMENTOS

Agradeço a Deus, em Sua infinita graça, por me conceder saúde, sabedoria e perseverança para enfrentar este desafio.

Aos meus amados pais, Joelson e Lilian, deixo minha eterna gratidão. Seu amor e apoio incondicional foram essenciais para meu desenvolvimento pessoal e profissional. Cada palavra de incentivo, cada gesto de carinho e cada sacrifício que vocês fizeram por mim, me deram forças para alcançar meus objetivos.

Também gostaria de agradecer ao meu irmão, Arthur, por sua amizade. Nossas longas conversas foram fundamentais para me sustentar em momentos de dúvida, cansaço e incerteza.

Não posso deixar de agradecer aos meus orientadores, pelo conhecimento compartilhado, pela paciência e pelo apoio constante. Suas valiosas contribuições foram essenciais para a realização deste trabalho.

Além disso, gostaria de estender meus agradecimentos à empresa Light por disponibilizar os dados e recursos necessários para a condução desta pesquisa.

Por fim, gostaria de agradecer a todos os amigos, colegas e pessoas que, de alguma forma, contribuíram para este trabalho.

RESUMO

A previsão de séries temporais é um tema que tem se tornado cada vez mais popular nas últimas décadas, graças às suas diversas aplicações em várias áreas do conhecimento e ao crescimento constante da quantidade de dados que é produzida a cada fração de segundo por uma infinidade de dispositivos ao redor do mundo. Existe uma ampla gama de métodos de previsão, cada um com propriedades específicas que devem ser consideradas na escolha de um método adequado para cada cenário de aplicação. Nos últimos anos, os modelos de aprendizado de máquina vêm ganhando destaque e se estabelecendo como sérios concorrentes aos modelos estatísticos clássicos, com destaque para as redes neurais recorrentes, que possuem uma espécie de memória, capaz de reter informações passadas e utilizá-las para prever valores futuros. Este trabalho propõe-se a investigar o desempenho de modelos neurais recorrentes frente a abordagens mais tradicionais na modelagem de séries temporais em dois cenários de aplicação que utilizam dados reais, com base em métricas de precisão da previsão. No primeiro cenário, investigou-se a efetividade desses modelos em aproximar os resultados obtidos na computação de índices de variabilidade de frequência cardíaca por meio de dados advindos de sensores de fotopletismografia àqueles alcançados por sensores de eletrocardiograma. Em um segundo cenário de aplicação, o desempenho desses modelos foi avaliado na previsão do volume de chamadas de emergência recebidas pelo serviço de atendimento ao consumidor de uma distribuidora de energia elétrica. Em ambos os cenários, o desempenho dos modelos neurais recorrentes foi superior aos modelos estatísticos, indicando que eles podem ser uma escolha apropriada para a previsão de séries temporais em diversas áreas.

Palavras-Chave: Aprendizado de máquina; Redes Neurais Recorrentes; Previsão; Série Temporal.

ABSTRACT

Time series forecasting is a topic that has become increasingly popular in recent decades, thanks to its diverse applications in various areas of knowledge and the constant growth in the amount of data that is produced every second by an infinity of devices around the world. There is a wide range of forecasting methods, each with specific properties that must be considered when choosing a suitable method for each application scenario. In recent years, machine learning models have gained prominence and established themselves as serious competitors to classical statistical models, especially recurrent neural networks, which have a kind of memory capable of retaining past information and using it to predict future values. This work proposes to investigate the performance of recurrent neural models against more traditional approaches in time series modeling in two different application scenarios, based on forecast accuracy metrics. The first scenario investigated the effectiveness of these models in approximating the results obtained in computing heart rate variability indices through data coming from photoplethysmography sensors to those achieved by electrocardiogram sensors. In a second application scenario, the performance of these models was evaluated in forecasting the volume of calls received by the call center of an electricity distribution company. In both scenarios, the performance of recurrent neural models was superior to statistical models, indicating that they can be an appropriate choice for time series forecasting in several areas.

Keywords: Machine Learning; Recurrent Neural Networks; Forecasting; Time Series.

LISTA DE ILUSTRAÇÕES

Figura 1 – Características do componente de tendência em séries temporais.....	16
Figura 2 – Sazonalidade em uma série temporal	17
Figura 3 – Componente residual de uma série temporal.....	17
Figura 4 – Função de Autocorrelação.....	19
Figura 5 – Arquitetura de uma Rede Neural simples.....	23
Figura 6 – Arquitetura de uma RNN tradicional e de uma LSTM.....	25
Figura 7 – Pirâmide populacional global de 1950 a 2019, com projeção para 2050	30
Figura 8 – Fluxograma da metodologia	41
Figura 9 – Análise gráfica dos componentes da série temporal do cenário 1.....	42
Figura 10 – Análise gráfica dos resíduos da série temporal do cenário 1.....	42
Figura 11 – Gráfico ACF do cenário 1.....	43
Figura 12 – Comparação dos métodos de interpolação	46
Figura 13 – Divisão dos dados para treino e teste.....	48
Figura 14 – Processo de ajuste dos hiper parâmetros	49
Figura 15 – Estrutura dos modelos neurais do cenário 1.....	50
Figura 16 – Seleção do número de épocas.....	51
Figura 17 – Modelo TBATS no cenário 1.....	52
Figura 18 – Desempenho dos métodos de correção.....	53
Figura 19 – Série temporal original do cenário 2.....	54
Figura 20 – Análise gráfica dos resíduos da série temporal do cenário 2.....	55
Figura 21 – Análise gráfica dos componentes da série temporal do cenário 2	56
Figura 22 – Gráfico ACF do cenário 2.....	56
Figura 23 – Teste ADF do cenário 2.....	57

Figura 24 – Teste ADF do cenário 2 após a aplicação dos métodos de estacionarização.....	57
Figura 25 – Suavização Exponencial no cenário 2	58
Figura 26 – Modelo TBATS no cenário 2.	59
Figura 27 – ARIMA no cenário 2	59
Figura 28 – Estrutura dos modelos neurais do cenário 2	60
Figura 29 – SDNN para Kubios e SMH.....	61
Figura 30 – RMSSD para Kubios e SMH.....	61
Figura 31 – pNN50 para Kubios e SMH	62
Figura 32 – Ajuste dos modelos neurais e de regressão linear aos dados.....	64
Figura 33 – Detecção de Picos.....	65
Figura 34 – Anomalias detectadas pelo método KNN.....	65

LISTA DE TABELAS

Tabela 1 – Teste ADF do cenário.....	43
Tabela 2 – RMSE dos modelos no cenário 1.....	51
Tabela 3 – Teste ADF do cenário 2.....	57
Tabela 4 – Teste ADF do cenário 2 após a aplicação dos métodos de estacionarização.....	58
Tabela 5 – Teste t pareado.....	62
Tabela 6 – RMSE dos modelos no cenário 2.....	64

LISTA DE ABREVIATURAS E SIGLAS

ACF	Função de Autocorrelação
ADF	Teste de Dickey-Fuller Aumentado
ANEEL	Agência Nacional de Energia Elétrica
ANN	Rede Neural Artificial
ECG	Eletrocardiograma
IBI	Intervalo entre batidas
KNN	<i>K-Nearest Neighbours</i>
LSTM	Memória de Curto e Longo Prazo
MSE	Erro Quadrático Médio
PPG	Fotopletismografia
pNN50	Porcentagem de IBIs que diferem por mais de 50ms do IBI anterior
RNN	Rede Neural Recorrente
RMSE	Raiz do Erro Quadrático Médio
RMSSD	Raiz quadrada média da diferença de IBIs sucessivos
SAC	Serviço de Atendimento ao Consumidor
SDNN	Desvio padrão do IBI
SNA	Sistema Nervoso Autônomo
SUS	Sistema Único de Saúde
UEPB	Universidade Estadual da Paraíba
UFCG	Universidade Federal de Campina Grande
VFC	Variabilidade de Frequência Cardíaca

SUMÁRIO

1	INTRODUÇÃO	12
2	OBJETIVOS	14
2.1	Objetivos específicos	14
2.1.1	Cenário 1	14
2.1.2	Cenário 2	14
3	REFERENCIAL TEÓRICO.....	15
3.1	Séries Temporais	15
3.1.1	<i>Componentes de uma série temporal.....</i>	15
3.1.1.1	<i>Tendência</i>	15
3.1.1.2	<i>Sazonalidade</i>	16
3.1.1.3	<i>Variações cíclicas.....</i>	17
3.1.1.4	<i>Flutuações irregulares.....</i>	17
3.1.2	<i>Classificações de uma série temporal.....</i>	18
3.1.2.1	<i>Estacionaridade.....</i>	18
3.1.2.2	<i>Autocorrelação</i>	19
3.2	Aprendizado profundo para previsão de séries temporais	20
3.3	Redes neurais.....	22
3.3.1	<i>RNN.....</i>	24
3.3.2	<i>LSTM.....</i>	24
3.4	Métricas de avaliação de desempenho para modelos de previsão de séries temporais.....	26
3.4.1	<i>Raiz do Erro Quadrático Médio (RMSE).....</i>	26
3.4.2	<i>Erro Médio Absoluto (MAE).....</i>	27
3.4.3	<i>Coeficiente de Determinação (R^2)</i>	27
3.4.4	<i>Erro Percentual Absoluto Médio (MAPE).....</i>	27
4	Estudos de Caso.....	28
4.1	<i>Variabilidade de frequência cardíaca como biomarcador da saúde de idosos.....</i>	28
4.1.1	<i>Envelhecimento populacional e o desafio ao sistema de saúde</i>	30
4.1.2	<i>Variabilidade de frequência cardíaca e suas métricas no domínio do tempo</i>	32

4.1.3	<i>Variabilidade de frequência cardíaca e o envelhecimento</i>	33
4.1.4	<i>Tecnologias para medir VFC</i>	34
4.1.5	<i>Viabilidade de uso do PPG como substituto do ECG na análise da VFC</i>	36
4.2	<i>Volume de chamadas recebidas pelo Serviço de Atendimento ao Consumidor de uma distribuidora de energia elétrica</i>	37
4.2.1	<i>A importância da previsão do número de chamadas para a gestão...</i>	38
4.2.2	<i>Os desafios e os avanços na previsão do volume de chamadas</i>	39
5	METODOLOGIA	40
5.1	<i>Variabilidade de frequência cardíaca como biomarcador da saúde de idosos</i>	41
5.1.1	<i>Análise preliminar dados</i>	
5.1.2	<i>Preparação e treinamento dos dados</i>	
5.2	<i>Volume de chamadas recebidas pelo Serviço de Atendimento ao Consumidor de uma distribuidora de energia elétrica.....</i>	54
5.2.1	<i>Análise preliminar dos dados</i>	54
5.2.2	<i>Preparação e treinamento dos dados</i>	58
6	RESULTADOS E DISCUSSÕES	60
6.1	<i>Variabilidade de frequência cardíaca como biomarcador da saúde de idosos.....</i>	60
6.2	<i>Volume de chamadas recebidas pelo Serviço de Atendimento ao Consumidor de uma distribuidora de energia elétrica</i>	63
7	CONCLUSÃO	66
	REFERÊNCIAS	68
	APÊNDICE A – DADOS	80

1 INTRODUÇÃO

A análise preditiva é uma técnica estatística que usa métodos de aprendizado de máquina e mineração de dados para prever resultados futuros prováveis com base em padrões encontrados em dados históricos existentes. Tal estratégia tem se tornado cada vez mais popular nos últimos anos, com aplicações nas mais diversas áreas de conhecimento (MAIER e DANDY, 2000), permitindo que organizações e pesquisadores explorem grandes quantidades de dados, desvendando padrões e identificando tendências para fazer previsões precisas e tomar decisões de maneira proativa.

Por sua vez, a previsão de séries temporais é uma subárea da análise preditiva que considera uma dimensão temporal, sendo necessária em qualquer aplicação onde o tempo seja uma variável relevante. Nesse contexto, embora sejam consideradas ferramentas muito recentes, as redes neurais oferecem uma solução robusta, que vem ganhando cada vez mais espaço e figuram entre as abordagens mais bem sucedidas na previsão de séries temporais em diversas aplicações (HUANG et al., 2007). Apesar de seu bom desempenho, as redes neurais não são adequadas para toda e qualquer aplicação, dadas as diferentes especificidades e necessidades de cada caso. Em vista disso, este trabalho se propõe a investigar o desempenho de uma das arquiteturas mais populares para modelagem de séries temporais, as Redes Neurais Recorrentes (RNN), em dois cenários de aplicações reais, comparando seus resultados com os de abordagens mais tradicionais (KIDGER et al., 2020; YUNPENG et al., 2017). Para isto, serão considerados um modelo mais tradicional de RNN e uma variação conhecida como Memória de Curto e Longo Prazo, do inglês *Long Short-Term Memory* (LSTM).

Em um primeiro estudo de caso, investigou-se a efetividade da utilização desses modelos em viabilizar a computação de índices de Variabilidade de Frequência Cardíaca (VFC), um indicador sensível e antecipado de comprometimentos na saúde (VANDERLEI et al., 2009), utilizando dados fisiológicos de 10 pacientes idosos obtidos através de sensores fotopletismografia (PPG) encontrados em dispositivos vestíveis, como substitutos para os índices usualmente calculados por meio de sensores de eletrocardiograma (ECG), com o objetivo de mitigar a falta de precisão dos dados advindos dos dispositivos vestíveis.

No segundo estudo de caso, o desempenho desses modelos foi avaliado utilizando dados de uma outra série temporal para prever o volume de chamadas de emergência recebidas pelo Serviço de Atendimento ao Consumidor (SAC) de uma distribuidora de energia elétrica, com base em seu histórico de chamadas e dados climáticos, a fim de aferir a robustez e o poder de generalização desses algoritmos.

A popularidade do uso das RNNs na previsão de dados de séries temporais advém de sua capacidade de capturar dependências e padrões temporais nos dados, além da diversidade de suas aplicações (DU et al., 2021; YU et al., 2022; BABAEV et al., 2019). No primeiro cenário de aplicação deste trabalho, a viabilização da computação de índices de VFC por meio de sensores PPG, permitiu que profissionais de saúde acompanhassem e rastreassem as mudanças na VFC de maneira remota e contínua, ajudando a identificar possíveis problemas de saúde. Já no segundo cenário, as RNNs foram utilizadas para analisar e extrair padrões e tendências de dados históricos para prever o volume futuro de chamadas de emergência, visando fornecer informações importantes para que os gerentes das centrais de atendimento pudessem fazer um planejamento antecipado de acordo com a demanda prevista, permitindo contratar e alocar pessoal de forma adequada, otimizando recursos e melhorando o atendimento ao cliente. Ambos os cenários ilustram a importância das RNNs na previsão de séries temporais para uma variedade de aplicações do mundo real e seu potencial para otimizar essas operações.

As descobertas e metodologias empregadas no primeiro cenário foram publicadas no periódico *Sensors* (RODRIGUES et al., 2022). Já o segundo cenário de aplicação foi desenvolvido como parte de um projeto de pesquisa da Agência Nacional de Energia Elétrica (ANEEL) desenvolvido pela Universidade Estadual da Paraíba (UEPB) e pela Universidade Federal de Campina Grande (UFCG) em parceria com a Light SESA. Essa parceria permitiu que o trabalho fosse desenvolvido com base em dados reais, ressaltando a sua aplicabilidade prática.

Os objetivos da pesquisa são apresentados no próximo capítulo. O referencial teórico é apresentado no terceiro capítulo, que apresenta os conceitos e teorias relevantes para este estudo. O quarto capítulo apresenta os estudos de caso conduzidos nesta pesquisa, que envolvem a aplicação de modelos de aprendizado profundo para previsão de séries temporais em dois domínios diferentes. O quinto capítulo discute a metodologia de pesquisa adotada neste trabalho. O sexto capítulo apresenta os resultados obtidos para cada estudo de caso; aqui, o desempenho dos

modelos de aprendizado profundo é comparado com os métodos tradicionais de previsão de séries temporais em termos de desempenho. Por fim, o último capítulo resume os resultados e conclusões da pesquisa.

2 OBJETIVOS

Avaliar o desempenho de modelos neurais recorrentes com o de abordagens mais tradicionais para modelagem de séries temporais, sob a ótica da Raiz do Erro Quadrático Médio, do inglês *Root Mean-Squared Error* (RMSE), em dois cenários de aplicação reais com características semelhantes, como a não estacionariedade e a presença de autocorrelação nos dados.

2.1 Objetivos específicos

2.1.1 Cenário 1

Avaliar o desempenho dos modelos de previsão no ajuste dos dados de frequência cardíaca advindos de sensores PPG aos dados obtidos a partir de sensores ECG na computação de índices de VFC, verificando a viabilidade da utilização de dispositivos vestíveis para o cálculo desses índices.

2.1.2 Cenário 2

Avaliar o desempenho desses modelos na previsão do volume de chamadas emergenciais reais recebidas pelo SAC de uma distribuidora de energia elétrica.

3 REFERENCIAL TEÓRICO

Neste capítulo, discutem-se quatro tópicos principais: séries temporais, aprendizado profundo para previsão de séries temporais, redes neurais e métricas para a avaliação de desempenho.

A primeira seção introduz o conceito de séries temporais, detalhando seus componentes e classificações. Em seguida, na segunda seção, investiga-se os conceitos de aprendizado profundo aplicados a séries temporais, fornecendo uma visão geral dos seus princípios básicos. Já a terceira seção detalha os conceitos de redes neurais recorrentes, suas arquiteturas, vantagens e limitações. Por fim, a quarta seção aborda métricas populares para a avaliação de desempenho dos modelos de previsão, destacando o motivo da adoção do RMSE.

3.1 Séries Temporais

Uma série temporal pode ser vista como um conjunto de observações de uma variável feitas sequencialmente ao longo do tempo (CHATFIELD, 2016). Elas podem ser classificadas de acordo com uma infinidade de atributos e são descritas pela combinação de quatro componentes principais: tendência, sazonalidade, variações cíclicas e flutuações irregulares (MENDENHALL, 1993; BOX et al., 2015).

O processo de análise da série temporal e seus atributos possibilita isolar esses componentes e quantificar sua influência sobre os dados observados, permitindo que esses padrões possam ser projetados na previsão. Os componentes das séries temporais, seus atributos e classificações são detalhados a seguir.

3.1.1 Componentes de uma série temporal


3.1.1.1 Tendência

A tendência representa um movimento suave e regular de uma série temporal, podendo ser entendida como um padrão de longo prazo que não se repete, sendo positiva quando a série temporal mostra um padrão ascendente e negativa se o padrão for descendente. Uma linha de tendência também pode ser classificada como linear ou não linear. Ela é dita linear quando o conjunto de observações se

assemelham a uma linha reta, indicando que algo está aumentando ou diminuindo a uma taxa constante e não linear quando isso não acontece.

Essas variações na tendência impactam diretamente na previsão, fornecendo informações sobre a direção e magnitude das mudanças observadas nos dados ao longo do tempo, sendo também crucial para seleção de um modelo de previsão adequado. Se os dados apresentarem uma tendência linear, por exemplo, um modelo de regressão linear simples pode ser uma boa opção, enquanto uma tendência não-linear pode exigir um modelo mais complexo, como uma rede neural. Na Figura 1 são ilustradas as diferentes classificações desse componente de uma série temporal, exemplificando uma tendência linear ascendente e uma tendência não linear descendente.

Figura 1 – Características do componente de tendência em séries temporais. A) Exemplo de uma tendência linear ascendente. B) Exemplo de uma tendência não linear descendente




Fonte: Elaborada pelo autor, 2023.

3.1.1.2 Sazonalidade

A sazonalidade descreve um padrão repetitivo que ocorre na série temporal com uma mesma frequência em um determinado período do ano, mês, semana, dia ou horário, como ilustrado na Figura 2. Ela pode ser observada em diversos tipos de dados de séries temporais, sendo especialmente comum em dados meteorológicos, onde pode-se observar mudanças climáticas ao longo das estações do ano, e em dados de varejistas, haja vista o aumento usual das vendas em certas datas comemorativas.

Trata-se de um componente importante na previsão de séries temporais, que pode ter um impacto significativo em sua precisão.

Figura 2 – Sazonalidade em uma série temporal.


Fonte: Elaborada pelo autor, 2023.

3.1.1.3 *Variações cíclicas*

As variações cíclicas, também conhecidas como ciclos, podem ser definidas como qualquer padrão que mostra oscilações com uma longa duração, mas que não ocorrem em um período fixo. A duração de um ciclo varia de acordo com o dado que está sendo estudado, mas geralmente corresponde a um período de no mínimo um ano. Como esse componente ocorre em intervalos de tempo longos, geralmente anos ou décadas, não é comum vê-lo na prática.

3.1.1.4 *Flutuações irregulares*

As flutuações irregulares ou resíduos, são um componente aleatório e imprevisível presente em toda série temporal, como ilustrado na Figura 3. Na previsão de séries temporais, o objetivo é modelar todos os componentes até que o único componente que permanece inexplicável seja o componente residual.

Figura 3 – Componente residual de uma série temporal.

Fonte: Elaborada pelo autor, 2023

3.1.2 Classificações de uma série temporal

As séries temporais podem ser classificadas como contínuas ou discretas. Uma série temporal é dita contínua quando as observações são feitas continuamente ao longo do tempo, sendo considerada discreta se as observações são feitas apenas em momentos específicos. Elas também podem ser classificadas como uni-variada, quando contém dados de observação acerca de uma única variável, ou multivariadas, quando a série apresenta mais de uma variável dependente do tempo (ADHIKARI e AGRAWAL, 2013).

3.1.2.1 Estacionariedade

Uma série temporal é considerada estacionária quando sua média, variância e covariância permanecem aproximadamente constantes ao longo do tempo, fazendo com que a série apresente uma aparência plana, sem flutuações. Caso contrário, a série é dita não-estacionária, sendo esse o caso para a grande maioria das séries temporais.

Para determinar se uma série temporal é estacionária ou não, um método amplamente utilizado é o Teste de Dickey-Fuller Aumentado, do inglês *Augmented Dickey-Fuller Test* (ADF), que testa a presença de uma raiz unitária na série temporal. A raiz unitária é uma característica presente em séries temporais não estacionárias, que indica que a série temporal não é estável ao longo do tempo e apresenta tendência ou algum outro padrão não-aleatório. A hipótese nula do teste ADF é que a série temporal possui uma raiz unitária, a hipótese alternativa é que a série é estacionária. Se a estatística do teste for menor que o valor crítico, rejeita-se a hipótese nula, concluindo-se que a série é estacionária. Caso contrário, não se pode rejeitar a hipótese nula, o que sugere que a série é não estacionária (MUSHTAQ, 2011).

Várias técnicas de previsão pressupõem a estacionariedade dos dados para um melhor funcionamento, tornando muitas vezes necessária a aplicação de técnicas de pré-processamento de dados para estacionarização da série. Duas abordagens populares de estacionarização são o *detrending*, que consiste na remoção da tendência presente na série temporal e a diferenciação, que remove os padrões


sazonais ou cíclicos presentes na série temporal. Essas duas abordagens também podem ser combinadas entre si, oferecendo maior robustez

3.1.2.2 Autocorrelação

A autocorrelação refere-se ao grau de similaridade entre uma determinada série temporal e uma versão anterior dela mesma, em intervalos de tempo sucessivos. Em outras palavras, a autocorrelação mede a relação entre o valor presente de uma variável e quaisquer valores passados da mesma variável.

Um método frequentemente utilizado para verificar se uma série temporal apresenta autocorrelação ou não é a Função de Autocorrelação, em inglês *Auto-Correlation Function* (ACF), que mede a força e direção da relação linear entre a variável atual e seus valores passados (BOX et al., 2015).

Figura 4 – Função de Autocorrelação. A) Numa série temporal com Autocorrelação. B) Numa série temporal sem Autocorrelação.



Fonte: Elaborada pelo autor, 2023.

A Figura 4 apresenta o gráfico da ACF cujas barras que representam os coeficientes de correlação de uma variável para diferentes valores anteriores dela mesma, conhecidos como *lags*. O *lag* zero representa a correlação da série temporal com ela mesma, que sempre é 1. A área em azul representa o intervalo de confiança e é um indicador do limite de significância, de modo que qualquer valor dentro dessa área é estatisticamente próximo de zero. Se o gráfico ACF mostrar coeficientes de correlação fora do intervalo de confiança para algum *lag*, então existe autocorrelação nos dados, o que pode ser um indicativo da presença de padrões de dependência temporal nos dados. A presença de *lags* fora do intervalo de confiança indica a

presença de correlações significativas em *lags* específicos, mas não fornece informações sobre a magnitude dessas correlações. Sendo assim, o fato de haver mais *lags* fora do intervalo de confiança não indica uma maior autocorrelação, em vez disso, indica que há uma maior dependência das observações atuais em relação às observações passadas ou futuras na série com relação a esses *lags* específicos.

Trata-se de um método amplamente utilizado para descobrir tendências e padrões em dados de séries temporais. A autocorrelação também é crucial para a escolha do modelo preditivo, já que modelos de previsão, como o Modelo Autorregressivo Integrado de Médias Móveis, do inglês *AutoRegressive Integrated Moving Average* (ARIMA) e o Modelo de Sazonalidade Trigonométrica, Transformação Box-Cox, Erros ARMA, Tendências e Componentes Sazonais, do inglês *Trigonometric seasonality, Box-Cox transformation, ARMA errors, Trend and Seasonal components* (TBATS) levam em consideração a autocorrelação para fazer previsões.

3.2 Aprendizado profundo para previsão de séries temporais

A previsão de séries temporais corresponde a uma técnica que consiste na aplicação de algoritmos sob um conjunto de dados históricos com o objetivo de prever e projetar tendências e resultados futuros (SHMUELI e LICHTENDAHL, 2016). Um modelo de previsão de séries temporais assume que existe algum padrão recorrente nos dados ou que os padrões da variável de interesse estão relacionados com variáveis independentes, ou seja, podem ser explicadas em termos de outras variáveis.

Existem diferentes métodos de previsão de séries temporais, sendo os modelos estatísticos os mais tradicionalmente utilizados, por tratar-se de técnicas mais simples e bem estabelecidas (NOR et al., 2017). Eles são fortemente baseados na variação temporal dentro da série e costumam funcionar melhor com séries temporais univariadas. Esses métodos tratam apenas do comportamento linear dos dados e dentre suas abordagens mais populares estão os modelos autorregressivos, como o ARIMA, e os modelos de suavização, como o Holt-Winters (UMER et al., 2018). Modelos de suavização de dados removem valores discrepantes de um conjunto de dados de séries temporais a fim de facilitar a identificação de padrões, tendências e componentes cíclicos, enquanto os modelos autorregressivos especificam que a

variável de saída depende linearmente de seus próprios valores anteriores e de um termo estocástico. Também existem modelos que combinam as duas abordagens, como o TBATS.

Outra abordagem popular para a previsão de séries temporais são os algoritmos de aprendizado de máquina, que vão desde métodos mais simples como os modelos de regressão a técnicas mais complexas envolvendo conceitos de aprendizado profundo, como as RNNs e LSTMs. O aprendizado profundo é uma subárea do aprendizado de máquina na qual as redes neurais compõem a base do algoritmo. Uma das principais vantagens do aprendizado profundo para previsão de séries temporais é sua capacidade de aprender automaticamente padrões e relacionamentos complexos nos dados, que podem ser difíceis de capturar usando métodos estatísticos tradicionais, sendo capazes de lidar com dados não-lineares, ao contrário do que acontece nos modelos estatísticos.

Nos últimos anos, vários estudos demonstraram a eficácia do aprendizado profundo para a previsão de séries temporais. Athiyarath et al. (2020) realizaram uma abrangente comparação de diversos métodos de aprendizado profundo com métodos tradicionais de previsão de séries temporais. Para isso, avaliou-se o desempenho desses métodos em três conjuntos de dados com características e aplicações distintas, concluindo que, de maneira geral, os modelos de aprendizado profundo superam os métodos tradicionais em termos de precisão e erro de previsão. Em outro estudo, Zhang et al. (2018) aplicaram técnicas de aprendizado profundo para prever os preços das ações das principais empresas estadunidenses, superando os modelos estatísticos mais tradicionais.

Apesar de serem métodos mais robustos, os algoritmos de aprendizado profundo nem sempre são a melhor alternativa. Como em qualquer outro método, existem vários desafios inerentes ao uso dessas técnicas, como a necessidade da disponibilidade de um alto poder computacional e de grandes quantidades de dados para um melhor funcionamento do modelo, além de um longo tempo de treinamento para alguns modelos, uma ampla gama de parâmetros a serem ajustados e potenciais problemas com *overfitting*, que ocorre quando o modelo se ajusta muito bem ao conjunto de dados utilizados no treinamento, mas se mostra ineficaz para prever novos resultados.

Não existe um modelo único que funcione em todas as situações, já que cada abordagem possui diferentes especificidades, de forma que nenhuma delas pode ser

considerada como melhor do que outra sem que se leve em conta o cenário de aplicação. Sendo assim, comparar o desempenho de diferentes abordagens é fundamental para garantir um bom resultado.

3.3 Redes Neurais

Como dito anteriormente, existem muitos tipos de modelos de previsão de séries temporais, cada um com seus pontos fortes e fracos. Com métodos autorregressivos, por exemplo, adicionar variáveis independentes é uma tarefa custosa, uma vez que esses modelos são projetados para prever uma variável dependente com base em seus próprios valores passados, sem depender de outras variáveis. Já quando se interpreta a série temporal como um problema de regressão, apesar de simplificar a adição dessas variáveis, torna-se mais complexo o mapeamento dos componentes da série temporal, isso porque ao tratar a série temporal como uma função contínua, ignora-se a natureza sequencial dos dados ao longo do tempo, dificultando a captura desses padrões (NOR et al., 2017).


Nesse contexto, as redes neurais aparecem como uma alternativa que ataca as limitações das duas estratégias, estando aptas a trabalhar com diversas variáveis, contando também com mecanismos para capturar características cíclicas e sazonais. Trata-se de um modelo computacional robusto, capaz de lidar com limitações comuns aos modelos clássicos, como padrões não-lineares e dados multivariados.

Uma rede neural é um tipo de algoritmo de aprendizado de máquina modelado de acordo com a estrutura e o funcionamento do cérebro humano. Consiste em nós interconectados, chamados de neurônios, que são organizados em camadas. Cada neurônio recebe uma entrada de outros neurônios na camada anterior, processa essa entrada, por meio de uma função específica, e então envia um sinal de saída para outros neurônios na próxima camada.

A arquitetura de uma rede neural normalmente consiste em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, como consta na Figura 5. A camada de entrada recebe os dados brutos, os processa e passa para a próxima camada. A camada oculta consiste em uma ou várias camadas de neurônios, cada uma conectada a camada anterior, onde realiza-se a maior parte da computação e processamento da rede, aplicando-se várias operações matemáticas aos dados de

entrada para extrair padrões. Por fim, a camada de saída gera as previsões com base nos dados de entrada e nos padrões aprendidos.

Figura 5 – Arquitetura de uma Rede Neural simples.



Fonte: Elaborada pelo autor, 2023.

Uma rede neural aprende por meio do processo de treinamento, onde ela ajusta os pesos das conexões entre os neurônios para minimizar a diferença entre as saídas previstas e as saídas corretas dos dados de treinamento, em um processo guiado pela otimização da função de perda, que consiste em uma medida de quão bem o modelo está performando em uma tarefa específica. Durante o processo de treinamento, os pesos da rede neural são ajustados para que a rede aprenda a mapear as entradas para as saídas com precisão. Normalmente isso é feito por meio de uma técnica conhecida como retro propagação, em que o erro entre a saída prevista e a saída real é utilizado para atualizar os pesos da rede. O objetivo do processo de treinamento é minimizar o erro entre a saída prevista e a saída real, melhorando assim a precisão das previsões (MANDIC & CHAMBERS, 2001).

As subseções a seguir se aprofundarão em duas arquiteturas de redes neurais recorrentes amplamente utilizadas para a previsão de séries temporais, as RNNs tradicionais e as LSTMs, fornecendo uma visão mais detalhada de seu funcionamento e aplicações.

3.3.1 RNN

Uma RNN é um modelo de rede neural proposto em meados da década de 1980 (RUMELHART et al., 1986) para modelagem de séries temporais, com uma estrutura muito semelhante à de um modelo neural mais simples, tendo como diferencial a capacidade de reter informações sobre o passado, permitindo-lhe descobrir correlações temporais entre eventos que estão distantes uns dos outros. É um tipo especial de rede neural adaptada para trabalhar com dados de séries temporais ou dados que envolvem sequências.

As redes neurais comuns destinam-se a trabalhar apenas com dados independentes uns dos outros. No entanto, se tivermos dados em uma sequência de modo que um ponto nos dados dependa de um ponto anterior, torna-se necessário incorporar as dependências entre esses pontos. Pensando nisso, as RNNs contam com um mecanismo de memória de curto-prazo, conhecido como estado oculto, que as permite armazenar os estados ou informações das entradas anteriores e utilizá-los para fazer uma nova previsão.

A arquitetura de uma RNN apresenta uma estrutura em *loop*, com cada *loop* correspondendo a um intervalo de tempo. A cada intervalo de tempo, a rede recebe uma entrada, calcula uma saída com base em seu estado atual e na entrada recebida e atualiza seu estado oculto para reter informações sobre as entradas anteriores por meio de retro propagação. A saída final da rede é gerada por uma combinação das saídas de cada uma das etapas de tempo.


Embora as RNNs sejam consideradas um modelo simples e poderoso, com excelentes resultados em uma ampla gama de aplicações, na prática é difícil treiná-las adequadamente, sendo especialmente difícil lidar com dependências de longo prazo, um problema conhecido como gradiente de fuga e de explosão (BENGIO et al., 1994), que ocorre quando sequências longas de dados precisam ser aprendidas.

3.3.2 LSTM

Uma solução para o problema do gradiente de fuga e explosão encontrado nas RNNs tradicionais foi proposta por Hochreiter e Schmidhuber (1997), a LSTM. Trata-se de uma variante da RNN que conta com um estado adicional ao estado oculto

existente nas RNNs, chamado de estado da célula, que fornece ao modelo uma memória de longo prazo, como ilustrado na Figura 6 (MASINI et al., 2021).

Figura 6 – Arquitetura de uma RNN tradicional e de uma LSTM.



Fonte: Adaptado de (YASRAB e POUND, 2020).

Em termos estruturais, o que difere a LSTM da RNN é que, ao invés de ter uma única camada em cada módulo (parte da rede projetada para realizar uma tarefa específica), ela apresenta várias camadas interagindo umas com as outras; nela o estado da célula e o estado oculto contêm informações, que são reguladas por mecanismos conhecidos como portões de entrada, de saída e de esquecimento através das funções de ativação. O portão de entrada controla o fluxo de informações para dentro da célula, enquanto o portão de saída controla o fluxo de informações para o exterior, ajudando a decidir quanta informação do estado atual da célula vai para o próximo estado. Por sua vez, o portão de esquecimento decide quais informações do estado anterior da célula devem ser retidas. Já as funções de ativação são componentes fundamentais nas redes neurais que determinam se um neurônio específico será ativado com base nas entradas que recebe. São elas que introduzem a não-linearidade nas saídas das camadas da rede, permitindo que o modelo aprenda relações complexas nos dados.

A LSTM apresenta uma arquitetura bastante flexível e robusta, sendo sua maior desvantagem o grande número de parâmetros que precisam ser ajustados para que

a rede funcione de forma eficiente, o que torna esse um modelo computacionalmente caro.

Em resumo, as RNNs e suas variações apresentam um bom desempenho em tarefas de previsão de séries temporais devido à sua capacidade de capturar padrões temporais complexos e dependências nos dados. No entanto, esses modelos apresentam algumas limitações, como problemas com *overfitting*, que ocorrem especialmente ao lidar com conjuntos de dados muito pequenos ou quando os dados contêm anomalias, além de questões como um custo computacional alto. Embora esse tipo de abordagem tenda a requerer grandes quantidades de dados e a remoção das anomalias para um treinamento eficaz, ainda é possível considerar sua aplicação nesses cenários. Para combater essas limitações, é possível utilizar técnicas de regularização e optar por arquiteturas mais simples que possuam menos parâmetros. Isso pode ajudar a evitar o *overfitting* e a lidar melhor com a escassez de dados e a presença de anomalias.

3.4 Métricas de avaliação de desempenho para modelos de previsão de séries temporais

Para avaliar a eficácia dos modelos de previsão diferentes métricas de avaliação de desempenho podem ser empregadas, de acordo com as características particulares do problema em questão e com os aspectos de desempenho que se deseja avaliar. Neste capítulo, discutiremos algumas das métricas mais populares para avaliar modelos de previsão em séries temporais (MOOD et al., 1973; MURPHY, 2012).

3.4.1 Raiz do Erro Quadrático Médio (RMSE)

O RMSE é uma métrica amplamente utilizada para avaliar a qualidade das previsões dos modelos de aprendizado de máquina, que mede a diferença entre os valores previstos e os valores reais, levando em consideração a magnitude desses erros.

Trata-se de uma métrica de erro que penaliza previsões mais distantes dos valores reais, pois eleva ao quadrado as diferenças entre eles. Isso faz com que erros maiores tenham um impacto mais significativo na métrica. Ele é dado na mesma

escala que a variável independente e, portanto, a interpretação do seu valor só pode ser avaliada dentro do seu conjunto de dados; mas de maneira geral, quanto mais próximo o RMSE estiver de 0, mais preciso será o modelo.

3.4.2 Erro Médio Absoluto (MAE)

Outra métrica comum para avaliar modelos de previsão em séries temporais é o Erro Médio Absoluto, do inglês, *Mean Absolute Error* (MAE). O MAE calcula a média das diferenças absolutas entre as previsões do modelo e os valores reais, sendo menos sensível a valores extremos do que o RMSE, já que não eleva as diferenças ao quadrado. Um valor baixo de MAE indica que o modelo está fazendo previsões mais precisas, enquanto um valor mais alto indica que o modelo está cometendo erros maiores em suas previsões. Apesar de ser mais fácil de interpretar que o RMSE, uma vez que é dado em unidades absolutas, o MAE trata todos os erros com o mesmo peso, o que é uma desvantagem quando se quer penalizar erros maiores de forma mais significativa.

3.4.3 Coeficiente de Determinação (R^2)

O coeficiente de determinação, também conhecido como R^2 , calcula a proporção da variabilidade total nos dados que é explicada pelo modelo. Seu valor varia de 0 a 1, onde 0 indica que o modelo não explica nenhuma variabilidade e 1 indica que o modelo explica perfeitamente a variabilidade nos dados. De modo que, quanto mais próximo de 1, melhor o modelo se ajusta aos dados.

Embora tenha uma interpretação mais direta que o RMSE e permita a comparação do desempenho de um modelo considerados bases de dados distintas, O R^2 concentra-se na variância explicada pelo modelo e não leva em consideração o tamanho dos erros, podendo ter um valor alto mesmo quando o modelo faz previsões imprecisas, desde que a variabilidade seja explicada.

3.4.4 Erro Percentual Absoluto Médio (MAPE)

O Erro Percentual Absoluto Médio, do inglês, *Mean Absolute Percentage Error* (MAPE) é uma métrica que calcula a média das porcentagens absolutas das

diferenças entre as previsões feitas pelo modelo e os valores reais. É particularmente útil quando se deseja avaliar a precisão das previsões em termos de porcentagem, o que facilita a interpretação. Quanto menor for o MAPE, melhor a previsão. Um MAPE de 0% indica uma previsão perfeita, com os valores previstos sendo idênticos aos valores reais.

O MAPE apresenta algumas desvantagens, como o fato de não lidar bem não com valores zero e não penalizar erros maiores, o que limita sua aplicação em algumas situações.

No contexto de séries temporais, o RMSE é frequentemente adotado por sua sensibilidade aos erros de previsão. Como fornece uma penalização mais forte para erros significativos, o RMSE é uma escolha apropriada quando a minimização de erros graves é crítica. Além disso, o RMSE é menos sensível a outliers do que outras métricas, o que o torna uma escolha robusta quando os dados contêm valores extremos que podem distorcer a avaliação do desempenho do modelo. Neste sentido, o RMSE foi adotado nesse estudo a fim de direcionar esforços para melhorar as previsões considerando cenários onde a precisão é fundamental e erros significativos podem ter consequências substanciais.

No capítulo seguinte, são apresentados dois estudos de caso que mostram o uso de RNNs na previsão de séries temporais, destacando seus pontos fortes e limitações em diferentes domínios de aplicação.

4 ESTUDOS DE CASO

4.1 Variabilidade de frequência cardíaca como biomarcador da saúde de idosos

De acordo com dados do *World Population Prospects*, publicado pela ONU (2019), até 2050 uma em cada seis pessoas no mundo terá mais de 65 anos; atualmente são uma em cada 11. As projeções também mostram que o número de pessoas com 80 anos ou mais deve triplicar nos próximos 30 anos, enquanto a expectativa de vida aumentará em cerca de 19 anos. O envelhecimento populacional é um fenômeno mundial, com implicações significativas em diversos setores da sociedade, atingindo em especial o setor de saúde, haja vista a associação do

processo de envelhecimento com o desenvolvimento de determinadas doenças e incapacidades (MORAES, 2008).

O impacto gerado pelo crescimento da população idosa traz consigo uma demanda cada vez maior por serviços e equipamentos de saúde, bem como a necessidade de uma assistência especializada, com o desenvolvimento de técnicas e metodologias que proporcionem um atendimento diferenciado a população de idade mais avançada (SAAD, 2016); nesse sentido, a adoção de tecnologias aplicadas à saúde se faz cada vez mais presente e necessária, especialmente no contexto da pandemia de COVID-19, onde o isolamento social acelerou a necessidade da adoção de estratégias de monitoramento remoto. Através do uso de dispositivos vestíveis, por exemplo, pode-se monitorar de forma remota dados fisiológicos dos usuários, viabilizando a avaliação contínua de informações cruciais na previsão de condições de saúde adversas.

Um importante indicador de comprometimentos na saúde é a VFC, que compreende as oscilações nos intervalos de tempo entre batimentos cardíacos consecutivos, chamados de intervalos R-R ou intervalos entre batidas (IBI), que refletem as modificações na frequência cardíaca em função da atuação conjunta do Sistema Nervoso Autônomo (SNA) simpático e parassimpático (MCCRATY e SHAFFER, 2015). Trata-se de uma medida simples e não-invasiva que pode ser empregada na análise da modulação autonômica sob diferentes condições fisiológicas e patológicas (VANDERLEI et al, 2009), podendo ser incorporada à prática clínica como um importante recurso na avaliação da saúde do indivíduo.

Para realizar a análise da VFC são necessários os dados do IBI. Esses dados compõem uma série temporal e, tradicionalmente, são extraídos de gravações de ECG, uma vez que esses dispositivos são capazes de capturar sinais mais abrangentes do que os sensores PPG presentes nos dispositivos vestíveis, detectando o IBI de forma mais confiável. Contudo, os dados do IBI podem ser extraídos também de gravações dos sensores de PPG, através do cálculo do intervalo de tempo entre pulsações sucessivas. Apesar de menos precisa, a medição feita por meio dos sensores PPG é menos intrusiva e incômoda, além de permitir que essa seja feita por longos períodos de tempo e com um baixo custo (JEYHANI et al., 2015; LU et al., 2009).


Nesse contexto, essa aplicação do trabalho investigou a efetividade da utilização de técnicas de aprendizado de máquina e análise de dados para viabilizar

a computação de índices de VFC utilizando dados obtidos através da análise de PPG como substitutos para os índices tradicionalmente calculados por meio de ECG, definindo um método para a aproximação dessas medições, a fim de mitigar a falta de precisão dos dados obtidos pelos sensores PPG.

4.1.1 Envelhecimento populacional e o desafio ao sistema de saúde

O declínio da fecundidade e o aumento da expectativa de vida caracterizam uma transição demográfica que está ocorrendo em todo o mundo, o aumento da proporção de idosos na população.

Figura 7 – Pirâmide populacional global de 1950 a 2019, com projeção para 2050



Fonte: Elaborada pelo autor, 2022. Baseada em dados extraídos do *World Population Prospects 2019* (ONU - United Nations, 2019).

A pirâmide populacional da Figura 7 retrata a densidade demográfica da população mundial segmentada por faixa etária e sexo. Quando há altas taxas de natalidade e mortalidade, cria-se uma forma triangular nítida no gráfico, como acontece no ano de 1950. Com o passar dos anos, à medida que a população envelhece, graças ao decaimento dessas taxas, a pirâmide populacional torna-se mais larga na parte superior. A população mundial com 60 anos ou mais, mais que o dobrou em 2019 quando comparada a 1980, quando havia cerca de 382 milhões idosos em todo o mundo, atingindo a marca de 1 bilhão de pessoas. As projeções indicam que esse número deve duplicar novamente até 2050, quando deve chegar a quase 2,1 bilhões de pessoas.

Ainda que o envelhecimento populacional tenha começado em países desenvolvidos, como o Japão onde cerca de 28% da população tem mais de 60 anos, agora são os países em desenvolvimento que estão experimentando uma maior mudança. Atualmente, dois terços da população mundial com mais de 60 anos vivem em países em desenvolvimento. Em 2050, estima-se que 8 em cada 10 das pessoas idosas do mundo viverão nessas regiões (ONU, 2019). No Brasil, a expectativa do Instituto Brasileiro de Geografia e Estatística (IBGE) é de que em 2050 aproximadamente 30% da população terá acima de 60 anos, em 2019 eram cerca de 15.7% (IBGE, 2018).

Embora o envelhecimento possa ser considerado como um marcador de êxito para um país, uma vez que resulta do aumento da qualidade de vida dos cidadãos, trata-se de um processo que traz consigo uma série de alterações fisiológicas inevitáveis, que limitam a funcionalidade e autonomia do indivíduo (MINISTÉRIO DA SAÚDE, 2006), impactando negativamente em diversos setores da sociedade como na economia, com a diminuição da população economicamente ativa e questões no orçamento do sistema previdenciário; no planejamento urbano, com questões de acessibilidade, uma vez que muitos idosos tem a mobilidade reduzida; e sobretudo na saúde, pública e suplementar, uma vez que os idosos sofrem em larga escala com doenças crônicas como hipertensão e diabetes, que demandam um acompanhamento médico contínuo, além de apresentarem enfermidades que exigem exames mais sofisticados e custosos (ZANON et al., 2014).

De acordo com dados do IBGE, foram gastos 225.89 bilhões de reais com saúde pública no Brasil em 2019; sendo que o custo médio de internação de um idoso no Sistema Único de Saúde (SUS) é cerca de 30% maior do que a de adultos com idade entre 25 e 59 anos, segundo dados do Ministério da Saúde. Tendo em vista as projeções de aumento dessa população nos próximos anos, esses custos devem crescer exponencialmente.

As alterações na estrutura populacional em decorrência do envelhecimento são nítidas e irreversíveis. Nesse sentido, a adoção de políticas públicas e um maior investimento em medidas preventivas que provenham uma assistência contínua e multidisciplinar faz-se necessária para mitigar os custos e impactos dessas mudanças, assegurando também a saúde e o bem-estar da população idosa.

4.1.2 Variabilidade de frequência cardíaca e suas métricas no domínio do tempo

A VFC é uma medida das flutuações de tempo entre cada batimento do coração em comparação ao ritmo cardíaco médio. Essa variação é controlada pelo SNA, que regula a maioria das funções internas do corpo, sobretudo nossa frequência cardíaca e pressão arterial, com o objetivo de gerar respostas fisiológicas adequadas diante mudanças ambientais internas e externas, de modo que sempre se mantenha a homeostase (CANNON, 1932). O SNA é subdividido em simpático e parassimpático, também conhecidos como mecanismo de luta ou fuga e de resposta ao relaxamento, respectivamente. O sistema nervoso simpático prepara o organismo para responder a situações de estresse, sendo ativado durante a prática de exercícios, em situações de excitação emocional ou sob certas condições patológicas; ele age estimulando a produção de adrenalina, acelerando os batimentos cardíacos, aumentando a pressão arterial, a secreção de suor e dilatando a pupila e os bronquíolos. Em contrapartida, o sistema nervoso parassimpático atua predominantemente durante o repouso, diminuindo a frequência cardíaca, aumentando a secreção das glândulas salivares e pancreáticas, e contraindo as pupilas e os bronquíolos. Já a diminuição da pressão arterial é regulada pela diminuição do estímulo simpático, que permite a vasodilatação (GORDAN et al., 2015).

Em resumo, o sistema nervoso simpático gerencia o aumento da frequência cardíaca e da pressão arterial em situações de emergência, enquanto o sistema nervoso parassimpático coordena a resposta ao relaxamento, controlando a desaceleração da frequência cardíaca. A variação normal da frequência cardíaca depende do equilíbrio entre os sistemas simpático e parassimpático. Uma alta VFC é um indício de boa adaptabilidade do sistema cardíaco a mudanças intrínsecas e extrínsecas, como estresse e a prática de atividade física (FOURNIÉ et al., 2021), caracterizando um indivíduo saudável com mecanismos de controle autônomo funcionando de maneira adequada. Por outro lado, uma baixa variabilidade é um indicador de adaptabilidade anormal e insatisfatória do SNA, caracterizando um mau funcionamento fisiológico no indivíduo (VANDERLEI et al., 2009). Com isso, a redução da VFC surge como um fator de risco para problemas de saúde, atuais ou futuros, incluindo uma enorme variedade de patologias, como doenças cardiovasculares (CARNETHON et al., 2002; HUIKURI, 1995), respiratórias (PARK et al., 2008) e

neurológicas (ZULLI et al., 2005; BUITRAGO-RICAURTE et al., 2020; FORTE et al., 2019).

A VFC pode ser avaliada por diferentes métodos, sendo o mais simples e mais utilizado as medidas no domínio do tempo (HUIKURI et al., 2009), cujos índices podem ser obtidos a partir da análise estatística do IBI e mensuram a quantidade de variabilidade nessas medições em várias escalas. O desvio padrão do IBI (SDNN) é a medida mais utilizada de VFC, seguida pela raiz quadrada média da diferença de IBIs sucessivos (RMSSD). Outro padrão comumente utilizado é o pNN50, que representa a porcentagem de IBIs que diferem por mais de 50ms do IBI anterior (KEMPER et al., 2007). O SDNN representa a atividade simpática e parassimpática, mas não permite distinguir se as alterações na VFC se devem ao aumento do tônus simpático ou à diminuição do tônus parassimpático. Já o RMSSD e o pNN50 fornecem medidas confiáveis da atividade parassimpática (VANDERLEI et al., 2009).

Todos os índices de VFC descritos acima, exceto o pNN50, possuem unidades de tempo medidas em milissegundos (ms) e, portanto, são medidas de variabilidade do IBI, não de frequência cardíaca. Todavia, frequência cardíaca e IBI são recíprocos entre si, de acordo com a seguinte equação:

$$FC = 60000 \div IBI \quad (1)$$

Na Equação 1, a frequência cardíaca (FC) é dada em batimentos por minuto (bpm) e o IBI em milissegundos (ms) (CHABOT et al., 1991). Comparada aos testes tradicionais, a análise da VFC por meio de suas métricas no domínio do tempo é um método simples, reprodutível e não invasivo para detectar precocemente o comprometimento autonômico (EVRENGÜL et al., 2005).

4.1.3 Variabilidade de frequência cardíaca e o envelhecimento

Com o progresso do envelhecimento populacional, surge a necessidade de identificar indicadores confiáveis que reflitam o estado de saúde do indivíduo. Desta forma, a VFC desponta como um dos principais indicadores em estudo, haja vista a associação do envelhecimento com a diminuição da capacidade autonômica (UMETANI et al., 1998), sendo o SNA um dos principais sistemas reguladores afetados pelo envelhecimento (BISHOP et al., 2010).

A VFC é objeto de interesse de estudos há vários anos; os primeiros relatos de investigação de sua aplicação clínica datam de meados da década de 1960 (BILLMAN, 2011), sendo cada vez maior o interesse em sua aplicação clínica. Um estudo realizado com 1.906 indivíduos saudáveis com idades entre 25 e 74 anos analisou a VFC em medições de ECG com 5 minutos de duração para avaliar os impactos da idade e gênero na VFC (VOSS et al., 2015). Os resultados mostraram que com o passar da idade os índices de VFC no domínio do tempo diminuem. Além disso, o estudo conclui que os homens normalmente têm uma VFC menor do que as mulheres dentro das mesmas faixas etárias.

Segundo um estudo longitudinal realizado ao longo de um período de 10 anos com 4.414 participantes inicialmente com idades entre 44 e 69 anos, as mudanças na VFC com o avançar da idade não se devem unicamente às alterações patológicas, muito embora essas alterações tenha um impacto mais expressivo na diminuição da VFC e ocorram naturalmente com o processo de envelhecimento em decorrência da queda da modulação autonômica cardíaca que ocorre com esse processo (JANDACKOVA et al., 2016).

Há evidências cada vez maiores de que uma série de doenças são acompanhadas por uma diminuição da VFC, embora os índices de VFC não distingam entre os diferentes tipos de enfermidades (YOUNG e BENTON, 2018). Estudos como esses sugerem que mudanças na VFC fornecem de fato um indicador preciso e antecipado de comprometimentos na saúde, estejam eles associados ao envelhecimento ou não.

4.1.4 Tecnologias para medir a VFC

Quando falamos em monitoramento da frequência cardíaca, duas tecnologias principais são utilizadas: ECG e PPG. Os sensores ECG vêm em várias formas e são considerados o padrão-ouro para medição de frequência cardíaca (BAYOUMY et al., 2021). Em ambiente hospitalar, o dispositivo utilizado para detectar a VFC é o eletrocardiógrafo, um dispositivo de ECG que mede a atividade elétrica do coração utilizando sensores que são colocados no peitoral do paciente. Outra opção amplamente utilizada pelos profissionais de saúde é o Holter, um monitor ECG portátil que é colocado na cintura do paciente para rastrear a VFC de forma contínua por períodos de tempo mais longos, com o propósito de identificar distúrbios no ritmo

cardíaco enquanto o paciente exerce atividades do dia a dia. Apesar de serem exames não invasivos e eficientes, aceitos como métodos padrão-ouro para monitoramento e análise da VFC, tanto o eletrocardiógrafo quanto o *Holter* apresentam algumas desvantagens, como alto custo do aparelho, queda na qualidade das gravações em pacientes com tremor ou pacientes idosos com a pele fragilizada (PÉREZ-RIERA et al., 2017). Outra limitação é a necessidade de um técnico especializado para interpretar os resultados, aumentando ainda mais os custos e diminuindo a escala de aplicabilidade (GERGIOU et al., 2018). Além disso, a colocação de diversos eletrodos no paciente torna a utilização incomoda, inviabilizando o uso regular.

Fora do ambiente hospitalar, os dispositivos mais comuns são as cintas cardíacas e os relógios inteligentes. A tecnologia adotada pelas cintas cardíacas varia. Neste estudo, foi utilizada a cinta cardíaca Polar H10, que conta com um sensor ECG. Os monitores de cinta torácica fornecem monitoramento preciso e contínuo do ritmo cardíaco, mas são menos atraentes para a maioria dos consumidores do que outras opções de dispositivos vestíveis, como os relógios inteligentes, devido a suas funções limitadas e ao volume do aparelho, que torna o uso a longo prazo inconveniente (BAYOUMY et al., 2021).

No caso dos relógios, a frequência cardíaca é medida através de sensores ópticos PPG que utilizam uma luz infravermelha de baixa intensidade para detectar alterações no fluxo sanguíneo controladas pela atividade cardíaca. Como a luz é mais fortemente absorvida pelo sangue do que por outros tecidos biológicos, as mudanças no fluxo sanguíneo podem ser detectadas pelos sensores PPG como mudanças na intensidade da luz.

Os sensores ECG apresentam uma clara vantagem sobre PPG para monitoramento de frequência cardíaca com relação à precisão. A imprecisão do PPG é causada por uma série de fatores distintos, tais como variações na luz ambiente, artefatos de movimento, tom de pele, idade, sexo, obesidade, respiração, pulsação venosa e temperatura corporal (FINE et al., 2021). Em contrapartida, os sensores PPG são mais baratos e fáceis de usar, já que não requerem o uso de eletrodos úmidos sobre o peito, podendo ser facilmente integrados em relógios inteligentes e outros dispositivos vestíveis (SIDDHARTH et al., 2019), possibilitando o monitoramento remoto e contínuo dos pacientes.

4.1.5 Viabilidade de uso do PPG como substituto do ECG na análise da VFC

Haja vista a importância da VFC como marcador da saúde do indivíduo, e as vantagens quanto à usabilidade, integração e custo apresentadas pelos sensores PPG, o estudo da confiabilidade da qualidade de sinal dos sensores PPG tornou-se de grande interesse científico, tecnológico e comercial (NARDELLI et al., 2020).

A utilização de sensores PPG para a análise de VFC é promissora. Georgiou et al. (2018) realizaram uma ampla revisão sistemática onde demonstraram que dispositivos vestíveis podem detectar VFC com 85% de precisão em condições de repouso, considerando uma população saudável. Todavia, essa precisão decai consideravelmente quando consideramos um cenário não-estacionário ou uma população de idade mais avançada, haja vista as mudanças significativas no equilíbrio autonômico nessas circunstâncias.

Já Nardelli et al. (2020) destacam as diferentes abordagens utilizadas para aferir a confiabilidade da VFC derivada dos sensores PPG como substituta a VFC extraída dos sensores ECG. Segundo os autores, uma estratégia frequentemente adotada por diversos estudos consiste em comparar as séries de IBIs diretamente, utilizando medidas de correlação estatística. Outra estratégia comum foi a de comparar os valores obtidos pelos dois sensores para as métricas nos domínios do tempo. Independente da abordagem adotada, os resultados foram similares àqueles encontrados por Georgiou et al. (2018); a maioria dos estudos relataram que em condições ideais, considerando indivíduos jovens, saudáveis e em estado de repouso, a adoção dos sensores PPG para medição da VFC fornece bons resultados. Todavia, quando são consideradas populações de idades distintas, com comorbidades ou incluídas tarefas envolvendo a prática de atividade física e estressores mentais, surge uma discrepância maior entre os resultados obtidos pelos diferentes sensores.

Nesse sentido, diversos estudos buscam investigar mais a fundo os fatores que afetam a qualidade dos sinais PPG adquiridos, propondo soluções para mitigar seus impactos. Diferentes métodos para melhorar a precisão da detecção da FC com PPG vêm sendo explorados pelos pesquisadores (BENT et al., 2020; LEE et al., 2019; LAHDENOJA et al., 2016; KRISHNAN et al., 2010; DAS et al., 2016; TEKMO, 2017), com muitas abordagens voltadas à redução do impacto de artefatos de movimento, já que esta é considerada uma das principais fontes de ruído (AYGUN e JAFARI, 2020). Trabalhos amplamente citados na literatura usam técnicas de processamento de sinal

para atacar esse problema como em (CHAN e ZHANG, 2002; LEE e ZHANG, 2003; KIM e YOO, 2006). Também são populares abordagens usando dados de acelerômetro (FUKUSHIMA et al., 2012; LEE et al., 2019), mostrando melhorias significativas na precisão, particularmente quando esses dados são combinados com dados de giroscópio (CASSON et al., 2016).

Embora haja muitos estudos voltados a mitigar artefatos considerados de maior impacto, as pesquisas indicam que até mesmo pequenos erros no sinal podem causar grandes imprecisões na medição da VFC (PETELCZYC et al., 2020), a pressão com a qual o relógio está em contato com a pele, por exemplo, pode resultar em ruído caso o dispositivo esteja muito frouxo ou muito apertado (SIDOROV et al., 2016). Ainda que muito progresso tenha sido feito nos últimos anos, a precisão de dispositivos PPG em comparação a métodos clássicos como o ECG ainda está em avaliação (GEORGIOU et al, 2018).

4.2 Volume de chamadas recebidas pelo Serviço de Atendimento ao Consumidor de uma distribuidora de energia elétrica

Para atender de forma proativa as reclamações relacionadas ao fornecimento de energia e fornecer um serviço eficaz aos clientes, as empresas de distribuição de energia precisam de agilidade e assertividade no atendimento. Garantir que os atendentes tenham informações que os ajudem a atender clientes, agendar serviços e despachar equipes de campo de forma eficaz é um fator chave para a eficiência operacional.

Nesse contexto, os modelos de previsão foram utilizados nessa linha da pesquisa para estimar a quantidade de chamadas que serão recebidas diariamente pelo SAC da Light S.A., visando fornecer aos atendentes informações que os permitam tomar decisões com base na análise e interpretação de dados históricos, a fim de otimizar o processo de atendimento ao cliente e despacho da equipe, garantindo maior controle e eficiência na execução dos serviços.

A Light é formada por empresas dos segmentos de distribuição, geração e comercialização de energia, atuando há cerca de 115 anos em 31 municípios do Estado do Rio de Janeiro, atendendo mais de 4,5 milhões de clientes. O SAC do grupo conta com 45 operadores e recebe cerca de 1.200 chamadas por dia. Os dados fornecidos pela empresa para o desenvolvimento do trabalho compõem uma série

temporal com a quantidade de ligações recebidas diariamente pelo SAC da Light entre janeiro de 2018 e abril de 2021. Essa série temporal tem características de natureza similar aos dados de frequência cardíaca advindos do Fitbit, como pode-se observar nas análises preliminares conduzidas nas seções 5.1.1 e 5.2.1. É de se esperar que dados de séries temporais com características similares tenham um desempenho semelhante para o mesmo modelo preditivo, fazendo-se os ajustes necessários nos parâmetros de cada modelo. Sendo assim, os modelos preditivos neurais aplicados para o problema da VFC serão retreinados com esses novos dados, comparando seu desempenho com o do problema anterior.

4.2.1 A importância da previsão do volume de chamadas para gestão

As centrais de atendimento compõem a linha de frente de muitas organizações, desempenhando um papel fundamental em gerenciar o relacionamento dos clientes com a empresa, tendo como um dos seus principais objetivos assegurar uma boa experiência no atendimento (RIPA e CHEAIB, 2016). A satisfação do cliente é uma das principais prioridades de muitas empresas na atualidade (KARIMI et al., 2001). Trata-se de uma medida que determina quão bem os produtos ou serviços da empresa atendem às expectativas do cliente, sendo um dos indicadores mais importantes de intenção de compra e fidelidade do cliente, auxiliando assim a prever o crescimento e a receita do negócio (HILL e BRIERLEY, 2003). Desta forma, a gestão de centrais de atendimento é fundamental para que o serviço funcione de maneira eficiente, garantido a satisfação do cliente e o gerenciamento eficaz dos recursos.

A qualidade do serviço de atendimento das distribuidoras de energia elétrica é regulada pela ANEEL, que estabelece níveis de desempenho mínimo, impondo limites para fatores como o tempo de espera e a proporção de clientes que abandonam a ligação, sendo estes diretamente ligados ao nível de satisfação do cliente (FEINBERG et al., 2000). Nesse sentido, a previsão do volume de tráfego de chamadas recebidas é uma das principais ferramentas para o planejamento estratégico do serviço de atendimento, permitindo que os gestores administrem melhor recursos físicos e humanos, melhorando assim a qualidade de serviço e mantendo a eficiência operacional.

4.2.2 Os desafios e os avanços na previsão do volume de chamadas

A previsão de volumes futuros de chamadas é uma tarefa complexa e de vital importância para tomada de decisões operacionais dos SACs (IBRAHIM e ECUYER, 2011). Essa complexidade se deve ao fato da incerteza associada ao número de chamadas que será recebido, uma vez que esse valor pode ser influenciado por eventos externos, dependendo da natureza do problema. No caso das distribuidoras de energia elétrica, o volume de chamadas pode sofrer influência de fatores comumente associados à falta de energia, como o clima, falhas nos equipamentos, acidentes e erro humano (HAES ALHELOU et al., 2019).

Dada sua importância e complexidade, diversos autores têm buscado soluções para esse problema. Ibrahim et al. realizaram um estudo comparando o desempenho de diferentes métodos para previsão do volume de chamadas, incluindo modelos tradicionalmente utilizados para esse fim, como o modelo de suavização exponencial de Holt-Winters. As previsões foram feitas considerando intervalos de antecedência distintos, variando de meia hora até semanas. Para isso, foram utilizados dados reais do SAC de uma das maiores empresa do Canadá, coletados durante um período de 80 dias e divididos em duas filas, uma para clientes falantes da língua inglesa e outra para falantes do francês. O modelo que obteve o melhor resultado explora as correlações entre os processos de chegada das duas filas. Vale destacar que, independentemente do modelo em questão, o erro para previsões feitas para o mesmo dia é significativamente menor do que quando considera-se períodos maiores (IBRAHIM e ECUYER, 2011).

De maneira similar, Taylor (2007) comparou o desempenho de vários modelos de análise estatística em prever o volume de chamadas recebidas por um grande banco britânico, considerando intervalos de antecedência variando de meia hora a duas semanas. Uma característica importante que difere esse estudo do anterior, é que os dados utilizados apresentam sazonalidade. Os melhores resultados foram alcançados pelo ARIMA e pelo modelo de suavização de *Holt-Winters*.

Embora modelos estatísticos tradicionais ainda sejam amplamente utilizados, haja vista a simplicidade de sua implementação e interpretação de resultados, modelos de aprendizado de máquina estão ganhando cada vez mais espaço na previsão de séries temporais, especialmente quando estamos lidando com Big Data ou com séries temporais multivariadas (HYNDMAN e ATHANASOPOULOS, 2018).

Ebadi et al. (2016) empregaram uma rede neural híbrida Elman-NARX para prever volume de chamadas em um *call center* utilizando dados reais de uma empresa iraniana. Para avaliar o desempenho, os resultados obtidos foram comparados aos de uma rede neural mais simples, obtendo uma redução expressiva no Erro Quadrático Médio, do inglês *Mean Squared Error* (MSE).

Por sua vez, Mastorocostas et al. (2013) propõem e avaliam o desempenho de uma RNN por meio de uma extensa análise comparativa com uma série de modelos populares, incluindo modelos tradicionais, bem como abordagens difusas e outros modelos neurais. Para isso, foram utilizados dados de chamadas reais recebidas pelo atendimento de uma universidade grega. O modelo que obteve o melhor desempenho dentre os avaliados, em termos do RMSE, foi uma rede neural recorrente, conhecida em inglês pelo nome de *Blockchain-Enabled Deep Recurrent Neural Network* (BDRNN).

Em suma, enquanto os modelos estatísticos têm sido a abordagem tradicional para prever o volume de chamadas, o uso dos modelos neurais tem mostrado superioridade em diversos trabalhos. Os modelos neurais podem capturar melhor os padrões complexos nos dados, fornecendo previsões mais precisas em comparação com os modelos estatísticos. No entanto, ainda existem vários desafios que precisam ser enfrentados, como a imprevisibilidade e natureza dinâmica atrelada à previsão do volume de chamadas e a modelagem de *outliers* e dias atípicos, como feriados, considerada um dos maiores desafios enfrentados pelos pesquisadores na atualidade (KOOLE, 2013). Este trabalho buscou mitigar parte desses problemas, incorporando a análise de aspectos sazonais presente em feriados na modelagem.

5 METODOLOGIA

Métodos estatísticos tradicionais, comumente utilizados em aplicações de séries temporais, tem como requisito fundamental que as séries temporais sejam estacionárias. Essa característica é imprescindível para o bom funcionamento da maioria dos modelos preditivos, pois torna as previsões mais confiáveis (CHATFIELD, 2003). Sendo assim, a estacionarização da série é necessária para que esses métodos possam ser aplicados, removendo qualquer autocorrelação. Todavia, esse processo não é efetivo em todos os casos e atrela alguma penalidade a previsão (MONTESINO POUZOLS e LENDASSE, 2010). Sendo assim, comparou-se a

desempenho de diferentes métodos preditivos, que dispensem ou não a etapa de pré-processamento para estacionarização da série, nos dois cenários apresentados. A estacionarização foi feita utilizando uma combinação dos métodos de *detrending* e diferenciação, sendo dispensada apenas nos dados utilizados para os modelos de aprendizado de máquina.

Antes de aplicar os modelos de previsão, foi realizada uma análise preliminar dos dados, cujo objetivo foi analisar os componentes de cada série temporal a fim de verificar suas características, buscando entender qual tipo de modelo preditivo poderia obter melhores resultados. Para isso, utilizou-se o Prophet¹, uma biblioteca Python criada pelo Facebook para prever dados de séries temporais com base em um modelo de regressão aditivo no qual as tendências não-lineares são ajustadas à sazonalidade, funcionando melhor com séries temporais que apresentam fortes aspectos sazonais.

A Figura 8 detalha a metodologia aplicada. Após as etapas de análise dos componentes da série temporal e pré-processamento, cada um dos modelos foi ajustado de acordo com seus hiper parâmetros específicos. Depois do treinamento, os modelos foram avaliados em termos de desempenho sob a ótica do RMSE. O processo detalhado de cada método está descrito nas subseções a seguir para cada um dos estudos de caso.

Figura 8 – Fluxograma da Metodologia.



Fonte: Elaborada pelo autor, 2022.

5.1 Variabilidade de frequência cardíaca como biomarcador da saúde de idosos

Foram coletados dados de 10 idosos, sendo 6 do sexo feminino e 4 do sexo masculino, caracterizados como saudáveis ou não, em situação de repouso. A coleta foi realizada de forma simultânea para os dois sensores, utilizando dispositivos Fitbit HR Inspire e Polar H10, num mesmo intervalo de tempo com duração de 15 minutos.


¹ Facebook Prophet: biblioteca de código aberto para previsão de séries temporais. Disponível em: <<https://facebook.github.io/prophet/>>.

Tradicionalmente, a VFC derivada dos sensores PPG é calculada a partir do sinal bruto desses sensores. De maneira geral, primeiramente são removidos os sinais ruidosos por meios de técnicas de filtragem e processamento de sinal. Em seguida, através de técnicas de detecção de picos são determinados os picos R do complexo QRS, que corresponde a parte do traçado do ECG que representa a ativação ventricular do coração. Por fim, são calculados os intervalos RR como os intervalos de tempo entre picos R sucessivos. O sinal bruto do PPG não é disponibilizado pelo Fitbit, cujos dados fornecidos consistem na série temporal da frequência cardíaca derivada do sinal bruto do PPG medindo-se o intervalo entre as pulsações. Sendo assim, para contornar essa limitação, foi necessário estruturar uma nova abordagem, que está descrita na seção 5.1.2. Já o dispositivo Polar fornece tanto o sinal bruto do ECG, quanto a frequência cardíaca.

5.1.1 Análise preliminar dos dados

Neste estudo de caso a análise realizada com o Prophet, cujo resultado está ilustrado na Figura 9, indicou que os dados não apresentam características sazonais; o que já era esperado dada a natureza desses dados, que compõem medições feitas em um curto espaço de tempo.


Figura 9 – Análise gráfica dos componentes da série temporal do cenário 1.



Fonte: Elaborada pelo autor, 2022.

Os erros residuais não apresentaram média próxima de zero, embora sigam uma distribuição normal centrada próximo a zero (Figura 10), o que indica que modelos similares ao utilizado pelo Prophet não são ideais para este cenário.


Figura 10 – Análise gráfica dos resíduos da série temporal do cenário 1.



Fonte: Elaborada pelo autor, 2022.

Para a análise de autocorrelação, realizada por meio do gráfico ACF, na Figura 11, observou-se que existem *lags* fora do intervalo de confiança, o que indica que os dados apresentam autocorrelação.

Figura 11 – Gráfico ACF do cenário 1.



Fonte: Elaborada pelo autor, 2022.

Em seguida, através do teste ADF (Tabela 1) verificou-se que os dados não são estacionários, uma vez que a estatística do teste é menor que o valor crítico para todos os níveis de confiança. Sendo assim, foi aplicada uma combinação dos métodos de *detrending* e diferenciação para estacionarizar a série temporal, a fim de viabilizar a aplicação dos métodos estatísticos de previsão.

Tabela 1 – Teste ADF do cenário 1.

Teste ADF	
Estatística do teste: -2.282	
p-valor: 0.178	
Valores críticos:	
1%: -3.502	– Os dados não são estacionários com 99% de confiança
5%: -2.893	– Os dados não são estacionários com 95% de confiança
10%: -2.538	– Os dados não são estacionários com 90% de confiança

Fonte: Elaborada pelo autor, 2022.

5.1.2 Preparação e treinamento dos dados

Os dados de frequência cardíaca adquiridos por meio de sensores ópticos PPG constituem uma série temporal que pode apresentar lacunas (dados faltantes) em decorrência de possíveis falhas na medição. A fim de garantir a integridade dos dados, faz-se necessário o preenchimento dessas lacunas, através da aplicação de um método de interpolação adequado. Para escolher o método mais adequado, o desempenho de onze abordagens de interpolação convencionais foi avaliado por meio

do RMSE, um dos critérios mais utilizados para avaliar o desempenho dos métodos de interpolação encontrados na literatura (LEPOT et al., 2017).

Para isso, introduziu-se lacunas nos dados de uma série temporal originalmente completa, obtida do Polar H10, preenchendo-as usando as diferentes técnicas, para então comparar os dados obtidos com aqueles retirados da série original, a fim de verificar qual técnica obteve melhor desempenho (PRATAMA et al., 2016). As técnicas utilizadas foram:


- *Mean Filling*: técnica que substitui os valores faltantes pelo valor médio da série;
- *Forward Fill*: método que preenche os valores faltantes propagando o valor da última observação válida adiante;
- *Backward Fill*: método que preenche os valores faltantes propagando o valor da próxima observação válida para trás;
- Interpolação linear: o método de interpolação linear ajusta uma linha de polinômios aos pontos próximos a lacuna usando uma fórmula linear para estimar os valores ausentes;
- Interpolação *spline* quadrática e cúbica: tipo de interpolação em que o interpolador é um tipo especial de polinômio denominado *spline*. Os polinômios splines são especialmente úteis em situações onde os dados têm flutuações irregulares. A ideia principal por trás desse método de interpolação é dividir o conjunto de dados em segmentos menores e ajustar um polinômio de grau baixo a cada segmento individual, de modo que esses polinômios se encaixem suavemente um no outro;
- *Piecewise Cubic Hermite Interpolating Polynomial* (PCHIP): método no qual a aproximação é feita por vários polinômios cúbicos *spline* menores, cada um aplicado a um intervalo específico entre os pontos de dados, com uma inclinação específica em cada extremidade, calculada usando as taxas de variação dos dados originais. A principal vantagem deste método é a sua capacidade de preservar a forma dos dados originais, evitando oscilações comuns em outros métodos de interpolação.
- Interpolação Akima: a interpolação Akima é uma técnica de interpolação *spline*, construída a partir de polinômios de terceira ordem e que utiliza informações

dos pontos de dados vizinhos para calcular os coeficientes desses polinômios, resultando em uma curva suave;

- Média móvel exponencialmente ponderada ou *Exponentially Weighted Moving Average* (EWMA): o EWMA estima os valores ausentes como uma média ponderada das observações históricas, atribuindo às observações mais antigas pesos menores que diminuem exponencialmente à medida em que os pontos de dados envelhecem;
- Interpolação por vizinho mais próximo: neste método, o valor imputado é igual ao do ponto conhecido mais próximo, de acordo com a distância Euclidiana;
- Média dos vizinhos mais próximos: essa abordagem preenche os valores ausentes com o valor médio dos k vizinhos mais próximos. Para selecionar o valor ótimo de k , que corresponde ao número de vizinhos considerados, utilizou-se uma abordagem gráfica conhecida como método do cotovelo, que compara o desempenho em função dos diferentes valores do parâmetro k , buscando um ponto de estabilização.

A Figura 12 mostra a série temporal original, destacando os valores faltantes em vermelho, e o resultado da interpolação para cada um dos métodos. Percebe-se que o método que obteve melhor resultado foi o PCHIP, com um RMSE de 1,14.

Figura 12 – Comparação dos métodos de interpolação.



Fonte: Elaborada pelo autor, 2022.

Em seguida, presumindo-se a existência de uma função desconhecida capaz de mapear uma entrada formada por dados PPG para uma saída composta por dados ECG, foram aplicados os algoritmos de previsão, buscando um modelo que apresente maior aproximação da função.

Os problemas de aprendizado supervisionado podem ser agrupados em problemas de regressão e classificação. Ambos têm como objetivo a construção de um modelo sucinto que consiga prever o valor da variável dependente a partir das variáveis de atributo. A diferença entre as duas tarefas está no fato de que o atributo dependente é numérico para regressão e categórico para classificação. A variável preditora (FC) não é contínua nem categórica, mas um número inteiro, que é um valor discreto. Para garantir que a melhor abordagem fosse escolhida, comparou-se o desempenho dos métodos de regressão com versões adaptadas para a tarefa de

regressão de métodos originalmente desenvolvidos para classificação, disponibilizados pela biblioteca scikit-learn²:


- Regressão logística multinomial: uma regressão logística é um modelo estatístico amplamente utilizado em problemas de classificação, no qual o objetivo é atribuir uma observação a uma de várias categorias com base em um conjunto de variáveis independentes;
- *K-Nearest Neighbors (KNN)*: método que atribui um valor a uma nova observação com base na média de seus vizinhos mais próximos;
- Árvore de decisão: uma estrutura em árvore na qual os dados são divididos continuamente de acordo com um determinado parâmetro, onde os nós internos representam as características do conjunto de dados, os ramos representam as regras de decisão e os nós folhas representam o resultado;
- *Random Forest*: método que cria um conjunto de árvores de decisão independentes, no qual cada árvore é treinada em uma amostra aleatória dos dados de treinamento, combinando essas previsões para obter um resultado mais robusto;
- AdaBoost: algoritmo de aprendizado de máquina que combina várias previsões de preditores mais simples em uma única previsão mais forte. Ele funciona de forma iterativa, dando mais peso as observações que foram classificadas incorretamente em etapas anteriores;
- Regressão linear: algoritmo que assume uma relação linear entre as variáveis de entrada e a saída, tentando modelar a relação entre as duas variáveis ajustando uma equação linear aos dados observados;
- Redes Neurais: RNN Padrão e LSTM.

Os dados das séries temporais foram divididos em treino e teste, com 75% dos dados sendo utilizados para treinamento dos modelos e os 25% restantes como conjunto de teste para avaliar o desempenho final dos modelos. A divisão foi estratificada por indivíduo para que pudéssemos posteriormente calcular as métricas de VFC de cada paciente.

² Scikit-learn: Biblioteca Python de aprendizado de máquina. Disponível em: <<https://scikit-learn.org/>>

Para obter uma representação mais precisa de quão bem o modelo pode funcionar em dados que não foram vistos antes, aplicou-se uma validação cruzada *k-fold* para o ajuste de hiper parâmetros. Com esse método, os dados foram divididos em dados de treinamento e validação por *k* vezes, cada vez para um subconjunto diferente dos dados, atribuindo uma pontuação ao modelo após cada iteração e calculando a média de todas as pontuações para obter uma melhor representação de como o modelo funciona. O valor adotado para *k* foi 5 e o processo de divisão de dados está detalhado na Figura 13.


Figura 13 – Divisão dos dados para treino e teste.



Fonte: Elaborada pelo autor, 2022.

Os hiper parâmetros dos algoritmos de aprendizado de máquina são coeficientes que permitem ao modelo adaptar seu comportamento a um conjunto de dados específico, otimizando os resultados. Com exceção da regressão linear, que não oferece muito espaço para ajuste, em inglês *tuning*, todos esses algoritmos possuem um conjunto diferente de hiper parâmetros. As curvas de validação (Figura 14) mostram o desempenho do modelo em relação a diferentes valores dos hiper parâmetros, onde o valor ideal para cada hiper parâmetro é aquele com o maior valor absoluto para o MSE, já que o scikit-learn, por convenção, adota o MSE negado.

Figura 14 – Processo de ajuste dos hiper parâmetros.




Fonte: Elaborada pelo autor, 2022.

O *tuning* para as redes neurais é um pouco diferente. Para esses modelos foi utilizado o *Grid Search*, uma técnica de otimização de hiper parâmetros que avalia o desempenho do modelo para diferentes combinações de hiper parâmetros, por meio de uma busca exaustiva. Os melhores resultados foram obtidos com 15 épocas, *batch size* de 64, MSE como função de perda e uma taxa de aprendizado 0,1. Mais detalhes sobre os modelos neurais como o número de camadas, neurônios e funções de ativação são descritos na Figura 15. Pode-se observar que o modelo LSTM adotado é composto por uma camada LSTM e duas camadas densas que possuem um

sigmoide como função de ativação e otimizador Adam. Também foram adicionados *dropouts*, uma técnica de regularização, entre as camadas para evitar *overfitting*. O modelo RNN, por sua vez, corresponde a uma RNN de camada única, com otimizador *rmsprop* e tangente hiperbólica como função de ativação.

Figura 15 – Estrutura dos modelos neurais do cenário 1.




Fonte: Elaborada pelo autor, 2022.

Em redes neurais, uma época é uma passagem por todo o conjunto de dados durante o processo de treinamento, na qual a rede neural ajusta seus pesos para otimizar seu desempenho. O número de épocas usadas no treinamento é um hiperparâmetro que determina quantas vezes a rede verá todo o conjunto de dados de treinamento. A escolha de um número apropriado de épocas é uma etapa importante do processo de *tuning*, crucial para que o modelo obtenha um bom desempenho em dados novos, uma vez que usar muitas épocas pode resultar em *overfitting*, além de aumentar o tempo de treinamento de maneira desnecessária. A Figura 16 apresenta os resultados fornecidos pelo Grid Search para a seleção do número de épocas, utilizando uma técnica conhecida como *Early Stopping*, na qual o treinamento é interrompido assim que a performance da rede deixa de apresentar melhorias ou começa a piorar. Pode-se observar que a partir de 15 épocas há uma estagnação da

métrica de desempenho, que nesse caso é a perda (*loss*), indicando que o treinamento atingiu um platô.

Figura 16 – Seleção do número de épocas.



Fonte: Elaborada pelo autor, 2022.

Depois de ajustar os hiper parâmetros e avaliar o desempenho médio do modelo com validação cruzada, avaliou-se o desempenho final do modelo. Para isso, os modelos foram treinados com 75% dos dados, com os hiper parâmetros ideais encontrados para cada modelo e depois comparados em termos de desempenho com os demais modelos por meio do RMSE conforme apresentado na Tabela 2.

Tabela 2 – RMSE dos modelos no cenário 1.

Modelo	RMSE
Regressão Logística	4,95
KNN	4,01
Árvore de decisão	4,07
Random Forest	3,83
AdaBoost	3,91
Regressão Linear	2,80
RNN	2,30
LSTM	2,23
TBATS	12,248


Fonte: Elaborada pelo autor, 2023.

Embora LSTM e RNN tenham um desempenho semelhante, a LSTM alcançou um RMSE mais baixo, com um valor de 2,23, o que implica que esse modelo pode se ajustar melhor ao conjunto de dados do que todos os outros modelos testados. Isso

significa que, em média, as previsões do modelo têm uma diferença de aproximadamente 2,23 unidades em relação aos valores reais da FC média, que no conjunto de dados em questão foi de 82. Esse resultado é consideravelmente satisfatório, uma vez que um RMSE de 2,23 é relativamente baixo em relação à média da FC de 82.

Também foram testados métodos autorregressivos e de suavização, todavia eles apresentaram um baixo desempenho e alto custo computacional. Para ilustrar os resultados obtidos por esses modelos, a Figura 17 mostra o ajuste dos dados previstos por um modelo TBATS, cujo RMSE foi de 12,248, um valor considerado alto haja vista o cenário de aplicação, a natureza dos dados e os resultados obtidos pelos outros modelos.

Figura 17 – Modelo TBATS no cenário 1.



Fonte: Elaborada pelo autor, 2023.

Uma vez que a série temporal estava completa, o IBI pôde ser calculado utilizando os dados de frequência cardíaca instantânea através da Equação 1. Posteriormente, os dados do IBI foram ajustados antes que fosse aplicado qualquer método de análise de VFC, uma vez que qualquer artefato na série temporal pode interferir significativamente na análise. Esse ajuste consiste na remoção de inconsistências como *outliers* (dados discrepantes) e batimentos ectópicos (batimentos cardíacos irregulares) (MORELLI et al., 2019). Para isto, foram utilizados os métodos propostos por Kamath e Fallen (1995), Acar et al. (2000), Karlsson et al. (2012) e Malik (1996), disponibilizados pela biblioteca Python *hrv-analysis*³. Cada um


³ A biblioteca "hrv-analysis" é uma ferramenta em Python para análise da VFC, desenvolvida por Robin Champseix e distribuída sob a licença GPLv3. Disponível em: < <https://pypi.org/project/hrv-analysis/> >.

desses métodos estabelece parâmetros específicos para definir o que caracteriza um outlier:

- Regra de Kamath: este método considera um batimento cardíaco anormal sempre que o IBI aumentou mais de 32,5% ou diminuiu mais de 24,5% quando comparado com o IBI anterior;
- Regra de Acar: IBIs que diferem em mais de 20% da média dos últimos nove IBIs são removidos;
- Regra de Karlsson: IBIs divergentes em mais de 20% da média do IBI anterior e seguinte são removidos;
- Regra de Malik: IBIs que diferem em mais de 20% do anterior são removidos.

Para escolher o melhor método de correção, todas as abordagens acima foram aplicadas a uma série de IBI obtida do Polar H10 e seus resultados comparados com os obtidos pelo método de correção utilizado pelo Kubios, que é considerado uma ferramenta padrão-ouro para o cálculo da VFC. Como não é possível recuperar a série IBI corrigida diretamente do Kubios, selecionou-se o método cujos índices de VFC se aproximaram mais dos calculados por ele. Os artefatos identificados foram substituídos por valores interpolados utilizando uma interpolação cúbica *spline*, procurando-se aproximar os resultados aos do Kubios, que adota o mesmo método de interpolação (TARVAINEN et al., 2021). Para avaliar o desempenho de cada método, calculou-se o R^2 , conforme mostra a Figura 18.

Figura 18 – Desempenho dos métodos de correção.



Fonte: Elaborada pelo autor, 2022.

O método adotado para este estudo foi a Regra de Kamath, que forneceu os resultados mais semelhantes aos de Kubios, apresentando resultados um pouco melhores que os outros métodos.

Após o ajuste do IBI, foram calculadas a média e o desvio padrão, para cada intervalo considerado, obtendo-se a partir daí os índices estatísticos que compõem a análise da VFC no domínio do tempo, o SDNN, RMSSD e pNN50.


5.2 Volume de chamadas recebidas pelo Serviço de Atendimento ao Consumidor de uma distribuidora de energia elétrica

Os dados fornecidos pela Light advêm de duas bases principais, uma com os dados do sistema que gerencia os despachos de emergência e outra com os dados do sistema de gestão comercial da empresa, e contêm informações relacionadas ao perfil do cliente, ligações anteriores e consumo de energia. O conjunto de dados original tem 66 colunas e 203.197 linhas. Ao todo foram 121.925 ligações, feitas por 48.612 clientes diferentes. Também foram utilizados dados meteorológicos da cidade do Rio de Janeiro coletados no mesmo período e disponibilizados pelo Instituto Nacional de Meteorologia (INMET).⁴

5.2.1 Análise preliminar dos dados

A Figura 19 apresenta a série temporal original das chamadas recebidas pela Light.

Figura 19 – Série temporal original do cenário 2.




Fonte: Elaborada pelo autor, 2022.

⁴ Para mais informações, ver: INSTITUTO NACIONAL DE METEOROLOGIA – INMET. Dados Meteorológicos: Banco de Dados Meteorológicos. Disponível em: <<https://portal.inmet.gov.br/>>.

A análise preliminar dos dados foi realizada utilizando o Prophet e seu modelo de regressão aditivo. Começando pela análise do componente residual, para garantir que não haja padrões faz-se necessário que os resíduos apresentem média e variância constantes. Na Figura 20 pode-se observar que os erros residuais apresentaram média próxima de zero e uma distribuição normal centrada em zero, isso sugere que o modelo está fazendo um bom trabalho em capturar os padrões subjacentes aos dados, sendo assim, espera-se que modelos similares também apresentem um bom resultado.

Figura 20 – Análise gráfica dos resíduos da série temporal do cenário 2.




Fonte: Elaborada pelo autor, 2022.

Uma média constante nos resíduos indica que o modelo não está superestimando ou subestimando os valores, enquanto uma variância constante indica que a variabilidade dos resíduos não está mudando ao longo do tempo.

Em seguida, na Figura 21, é possível observar que os dados apresentaram um componente sazonal forte e uma tendência não linear. Além disso, observou-se um padrão recorrente no volume de chamadas recebidas em certas datas comemorativas, com um aumento expressivo no número de atendimentos nos meses de verão e a maior parte das ligações sendo registradas nas segundas-feiras, com uma suave diminuição ao longo da semana e uma queda mais expressiva aos finais de semana.


Figura 21 – Análise gráfica dos componentes da série temporal do cenário 2.



Fonte: Elaborada pelo autor, 2022.


Quanto a autocorrelação, foi aplicado o ACF onde pôde-se observar (Figura 22) que alguns valores estão fora do intervalo de confiança, o que indica que os dados apresentam autocorrelação. Como foi visto no capítulo 5, métodos estatísticos tradicionais não costumam funcionar bem quando existe autocorrelação.

Figura 22 – Gráfico ACF do cenário 2.



Fonte: Elaborada pelo autor, 2022.

Prosseguindo com a análise, identificou-se por meio do teste ADF, das Figura 23 e Tabela 3, que os dados não são estacionários, considerando diferentes níveis de confiança.

Figura 23 – Teste ADF do cenário 2.


Fonte: Elaborada pelo autor, 2022.

Tabela 3 – Teste ADF do cenário 2.

Teste ADF	
Estatística do teste:	-2.115
p-valor:	0.239
Valores críticos:	
1%:	-3.435 – Os dados não são estacionários com 99% de confiança
5%:	-2.864 – Os dados não são estacionários com 95% de confiança
10%:	-2.568 – Os dados não são estacionários com 90% de confiança

Fonte: Elaborada pelo autor, 2022.

Para facilitar e aumentar a confiabilidade da previsão, os dados foram estacionarizados por meio de uma combinação dos métodos de *detrending* e diferenciação. Em seguida, o teste ADF foi aplicado novamente para confirmar que o processo de estacionarização funcionou corretamente, como está retratado na Figura 24 e na Tabela 4.

Figura 24 – Teste ADF do cenário 2 após a aplicação dos métodos de estacionarização.

Fonte: Elaborada pelo autor, 2022.

Tabela 4 – Teste ADF do cenário 2 após a aplicação dos métodos de estacionarização.

Teste ADF
Estatística do teste: -16.479
p-valor: 0
Valores críticos:
1%: -3.436 – Os dados são estacionários com 99% de confiança
5%: -2.864 – Os dados são estacionários com 95% de confiança
10%: -2.568 – Os dados são estacionários com 90% de confiança


Fonte: Elaborada pelo autor, 2022.

5.2.2 Preparação e treinamento dos dados

Primeiramente, os dados extraídos dos dois sistemas foram combinados em uma única base de dados consistente. A fim de padronizar os dados e facilitar a modelagem, foi realizada uma etapa de pré-processamento, para que fossem removidas quaisquer inconsistências que esses dados pudessem ter, convertendo-os em um formato legível para os algoritmos de aprendizado de máquina. As inconsistências encontradas consistem majoritariamente em leituras ausentes, erros de registro de datas e falta de uniformidade na nomenclatura.

Aqui, os modelos de aprendizado de máquina mais sofisticados foram comparados com os modelos estatísticos tradicionais, utilizando como métrica o RSME. Foram considerados os seguintes modelos estatísticos:


- Suavização Exponencial: método que realiza previsões com base nas médias ponderadas de observações passadas, no qual o peso associado a cada observação diminui de acordo com sua recência, ou seja, quanto mais recente a observação, maior seu peso na predição. O ajuste dos dados a esse modelo está ilustrado na Figura 25.

Figura 25 – Suavização Exponencial no cenário 2.

Fonte: Elaborada pelo autor, 2022.

- **TBATS:** o TBATS, é um método de previsão de séries temporais que combina uma série de outras abordagens. Primeiro, ele utiliza uma transformação Box-Cox para tornar os dados estacionários. Em seguida, decompõe os dados em componentes de tendência e sazonalidade usando funções trigonométricas. Por fim, os erros são modelados usando um modelo autorregressivo ARMA. Trata-se de um modelo eficaz para séries temporais com múltiplos padrões sazonais e tendências não lineares. A Figura 26 retrata o resultado da aplicação do modelo TBATS.


Figura 26 – Modelo TBATS no cenário 2.



Fonte: Elaborada pelo autor, 2022.

- **ARIMA:** técnica de modelagem estatística que inclui a diferenciação dos dados para torná-los estacionários, ajustando um modelo autorregressivo para capturar a correlação entre os *lags* e um modelo de média móvel para contabilizar os erros. A Figura 27 retrata o resultado da aplicação do modelo ARIMA.


Figura 27 – ARIMA no cenário 2.



Fonte: Elaborada pelo autor, 2022.

Para os modelos de aprendizado de máquina, o desempenho da RNN e da LSTM foi comparado a uma regressão linear simples. De modo similar ao cenário anterior, a LSTM foi estruturada com uma camada LSTM, duas camadas densas, uma função de ativação sigmoide e *dropouts* entre as camadas. Já o modelo RNN foi definido com uma única camada, como na Figura 28. O *tuning* foi feito utilizando o *Grid Search* e a melhor precisão foi alcançada para um *batch size* de 32, 20 épocas, otimizador Adam e uma taxa de aprendizado de 0,0005.

Figura 28 – Estrutura dos modelos neurais do cenário 2.



Fonte: Elaborada pelo autor, 2022.

6 RESULTADOS E DISCUSSÕES

Este capítulo apresenta uma análise detalhada dos resultados obtidos em cada cenário, bem como as implicações e as contribuições desses resultados para a aplicação de modelos de aprendizado de máquina em problemas de previsão de séries temporais.


6.1 Variabilidade de frequência cardíaca como biomarcador da saúde de idosos

No capítulo anterior, cada etapa da metodologia foi validada individualmente. Para validar o processo como um todo, comparou-se, por meio de um teste t pareado, os índices de VFC no domínio do tempo obtidos pela plataforma SMH usando os

dados coletados do Fitbit Inspire HR com os fornecidos pelo Kubios, para os dados do Polar H10. Os modelos também foram avaliados através do RMSE.


As Figuras 29, 30 e 31 mostram a distribuição de cada um dos índices de VFC escolhidos. A comparação dos *boxplots* para cada índice mostrou que os dados estão distribuídos de forma semelhante. As caixas se sobrepõem e as linhas medianas ficam dentro da sobreposição entre as caixas, indicando que não há diferença significativa entre os dois grupos.

Figura 29 – SDNN para Kubios e SMH.




Fonte: Elaborada pelo autor, 2022.

Figura 30 – RMSSD para Kubios e SMH.



Fonte: Elaborada pelo autor, 2022.

Figura 31 – pNN50 para Kubios e SMH.

Fonte: Elaborada pelo autor, 2022

Haja vista que os dados consistem em observações pareadas feitas em um único grupo de pacientes, foi realizado um teste t pareado (Tabela 5) para determinar se as observações pareadas são significativamente diferentes umas das outras.

Tabela 5 – Teste t pareado.

Null Hypothesis: There is no difference in the means of the metric calculated by SMH		
Alternate Hypothesis: There is a difference in the means of the metric calculated by SMH		
Metric	t-value	p-value
SDNN	1.772	0.110
RMSSD	1.150	0.280
pNN50	0.025	0.980

Fonte: Elaborada pelo autor, 2023.

Considerando um nível de significância de 0,05, com nível de confiança de 95% e 9 graus de liberdade ($n - 1$), o valor crítico de t obtido da tabela de distribuição t foi 1,833. Para um nível de confiança de 99%, recomendado para aplicações em saúde, o valor crítico foi de 2,821.

A estatística t para o SDNN foi de 1,772, que é menor que o valor crítico para os níveis de confiança de 95% e 99%. O p-valor foi de 0,110, que é maior que o nível de significância, então aceita-se a hipótese nula de que não há diferença nas médias da métrica SDNN calculada pela SMH. Para RMSSD, a estatística t obtida foi de 1,150,

que também é menor que os valores críticos. O p-valor foi 0,280, ou seja, maior que o nível de significância, então aceita-se a hipótese nula de que não há diferença entre as médias. Por fim, para pNN50, a estatística t foi de 0,025, que também é menor que os valores críticos e o valor de p foi de 0,980, ou seja, maior que o nível de significância, portanto, aceita-se a hipótese nula.

Os resultados indicam que os índices de VFC no domínio do tempo estimados para os dados do Fitbit pelo SMH não foram estatisticamente diferentes daqueles obtidos para os dados do Polar H10 pelo Kubios, considerando indivíduos em repouso; tornando-o uma alternativa razoável para a estimativa da VFC quando a medição do ECG é impraticável.


Esta análise reforça as afirmações de Pinheiro et al. (2016) de que o PPG é uma alternativa viável para medições de intervalo de batimentos cardíacos para análise de VFC em indivíduos saudáveis em repouso com correlações significativas acima de 95% para características de domínio do tempo, fornecendo cobertura adicional para uma população maior, incluindo indivíduos com comorbidades.

Os achados deste estudo abrem oportunidades para medir e monitorar remotamente a variabilidade da frequência cardíaca, fornecendo uma estratégia adicional para identificação precoce de condições adversas de saúde, viabilizando a realização antecipada de intervenções apropriadas, que buscam promover a saúde da população idosa.

Em estudos futuros deve-se levar em consideração as limitações deste trabalho, como o tamanho da amostra e a ausência de medições feitas em condições de vida livre (caminhando, praticando exercícios e dormindo), pois os artefatos de movimento tornam a estimativa da FC a partir do PPG mais desafiadora.

6.2 Volume de chamadas recebidas pelo Serviço de Atendimento ao Consumidor de uma distribuidora de energia elétrica

Como pode ser observado na Figura 32, o modelo que parece se ajustar melhor aos dados é a RNN, o que pode ser comprovado ao analisar o RSME obtido por todos os modelos na Tabela 6.

Figura 32 – Ajuste dos modelos neurais e de regressão linear aos dados.

Fonte: Elaborada pelo autor, 2022.


Tabela 6 – RMSE dos modelos no cenário 2.

Modelo	RMSE
Suavização Exponencial	33,87
TBATS	30,45
ARIMA	33,93
Regressão Linear	35,37
RNN	24,21
LSTM	26,22


Fonte: Elaborada pelo autor, 2023.

Como era de se esperar pela análise preliminar feita na seção 5.2.1, os métodos estatísticos tradicionais não apresentaram um bom resultado. Apesar de apresentarem resultados significativamente melhores que os modelos estatísticos, o desempenho dos modelos neurais não é o ideal. Considerando que a média de chamadas de emergência recebidas diariamente foi de 74,54, um erro médio de 24,21 é considerado alto.

A fim de apontar uma possível causa para o baixo desempenho dos modelos neste cenário de aplicação, realizou-se uma análise de detecção de anomalias. Anomalias são pontos de dados que se desviam significativamente da sua distribuição normal, afetando a precisão e a confiabilidade dos modelos de previsão, introduzindo viés e ruído. Como pode ser observado na Figura 33, os dados apresentaram picos abruptos, que são considerados anômalos. Além disso, mais pontos anômalos foram encontrados utilizando-se o método KNN, que define como anomalias pontos que sejam significativamente diferentes de seus vizinhos mais próximos. Os pontos identificados como anomalias foram destacados em vermelho na Figura 34.

Figura 33 – Detecção de Picos.

Fonte: Elaborada pelo autor, 2022.

Figura 34 – Anomalias detectadas pelo método KNN.

Fonte: Elaborada pelo autor, 2022.

A presença de picos e anomalias nos dados deve-se à incerteza associada ao problema em questão, que sofre influência de fatores externos como falhas nos equipamentos e acidentes. Neste cenário, o uso de técnicas de pré-processamento de dados para detecção e remoção de *outliers* não seria viável, uma vez que prever o volume de chamadas em dias atípicos é mais importante do que em dias comuns. Isso porque o volume de chamadas recebidas em dias atípicos pode diferir significativamente do que normalmente é observado e se o SAC não estiver preparado para isso, poderia resultar em longos tempos de espera e clientes frustrados.

Uma possível solução para otimizar a desempenho dos modelos neste cenário é a incorporação de dados associados aos fatores externos conhecidos por influenciar o volume de chamadas de emergência, como dados dos sistemas de monitoramento da rede de distribuição de energia elétrica. Isso poderia ajudar o modelo a capturar melhor os padrões e tendências inerentes ao problema e obter um melhor desempenho.

7 CONCLUSÃO

A previsão de séries temporais tem se tornado cada vez mais importante devido à diversidade de aplicações e ao constante crescimento da quantidade de dados produzidos a cada segundo por uma variedade de dispositivos em todo o mundo. Com a ampla gama de métodos de previsão disponíveis, escolher o método adequado para cada cenário de aplicação é essencial para obter um bom desempenho. Nos últimos anos, os modelos de aprendizado de máquina ganharam popularidade e se estabeleceram como sérios concorrentes dos modelos estatísticos clássicos. Dentre eles, as redes neurais recorrentes têm mostrado grande potencial devido à sua capacidade de reter informações passadas e utilizá-las para prever valores futuros.

Este trabalho investigou o desempenho de modelos neurais recorrentes frente a abordagens mais tradicionais em dois cenários reais de aplicação: Variabilidade de frequência cardíaca como biomarcador da saúde de idosos e previsão do volume de chamadas recebidas por um SAC de uma distribuidora de energia elétrica. O desempenho dos modelos foi avaliado com base no RMSE, e os resultados mostraram que modelos neurais recorrentes tiveram um desempenho superior aos modelos estatísticos em ambos os cenários, sugerindo que eles podem ser uma opção adequada para previsão de séries temporais em vários domínios.

Trabalhos futuros podem se concentrar em avaliar seu desempenho em uma diversidade maior de cenários de aplicação, além de explorar arquiteturas mais complexas ou outros tipos de modelos de aprendizado de máquina, como RNNs com camadas adicionais ou Redes Neurais Convolucionais 1D, que podem ser eficazes na captura de padrões locais de séries temporais. Outra possibilidade é a adoção de uma abordagem híbrida, que combine os modelos neurais com os modelos mais tradicionais, podendo mitigar os desafios presentes em ambas as abordagens isoladas, unindo a capacidade das RNNs em capturar relações temporais complexas e não-lineares, com a habilidade dos modelos estatísticos em lidar com componentes sazonais e tendências.

Essa pesquisa contribui para a crescente relevância dos modelos neurais no campo da previsão de séries temporais, destacando seu potencial superior em relação aos métodos estatísticos tradicionais. À medida que continuamos a explorar e aprimorar essas técnicas, surgem possibilidades interessantes para avanços na

utilização de modelos de aprendizado de máquina para a previsão de séries temporais, abrindo portas para inovações e aplicações em diversas áreas.

REFERÊNCIAS

ACAR, B., SAVELIEVA, I., HEMINGWAY, H., MALIK, M. **Automatic ectopic beat elimination in short-term heart rate variability measurement.** Comput Methods Programs Biomed. 2000 Oct;63(2):123-31. doi: 10.1016/s0169-2607(00)00081-x. PMID: 10960745.

ADHIKARI, R., AGRAWAL, R. **An introductory study on time series modeling and forecasting.** arXiv preprint arXiv:1302.6613, 2013.

ATHIYARATH, S., Paul, M., KRISHNASWAMY, S. (2020). **A Comparative Study and Analysis of Time Series Forecasting Techniques.** SN Computer Science, 1(3). doi:10.1007/s42979-020-00180-5

AYGUN A., GHASEMZADEH H., JAFARI R., **"Robust Interbeat Interval and Heart Rate Variability Estimation Method from Various Morphological Features Using Wearable Sensors"** in IEEE Journal of Biomedical and Health Informatics, vol. 24, no. 8, pp. 2238-2250, Aug. 2020, doi: 10.1109/JBHI.2019.2962627.

BABAEV, D., SAVCHENKO, M., TUZHILIN, A., UMERENKOV, D. 2019. **E.T.-RNN: Applying Deep Learning to Credit Loan Applications.** In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19). Association for Computing Machinery, New York, NY, USA, 2183–2190. <https://doi.org/10.1145/3292500.3330693>

BAYOUMY, K., GABER, M., ELSHAFFEEY, A. et al. **Smart wearable devices in cardiovascular care: where we are and how to move forward.** Nat Rev Cardiol 18, 581–599 (2021). <https://doi.org/10.1038/s41569-021-00522-7>

BENGIO Y, SIMARD P, FRASCONI P. **Learning long-term dependencies with gradient descent is difficult.** IEEE Trans Neural Netw. 1994;5(2):157-66. doi: 10.1109/72.279181. PMID: 18267787.

BENT, B., B. GOLDSTEIN, A., KIBBE, W., DUNN, J., **"Investigating sources of inaccuracy in wearable optical heart rate sensors"**, NPJ Digit. Med., vol. 3, no. 1, pp. 18, Dec. 2020

BILLMAN, GE. **Heart rate variability - a historical perspective**. Front Physiol. 2011 Nov 29;2:86. doi: 10.3389/fphys.2011.00086. PMID: 22144961; PMCID: PMC3225923.

BISHOP, N. A., LU, T., YANKNER, B. A. 2010. **Neural mechanisms of ageing and cognitive decline**. Nature 464 529–535. 10.1038/nature08983

BOX, G. E. P., JENKINS, G. M., REINSEL, G. C., LJUNG, G. M. 2015. **Time Series Analysis: Forecasting and Control**, 5th Edition.

BITRAGO-RICAURTE, N., CINTRA, F., SILVA, G., **Heart rate variability as an autonomic biomarker in ischemic stroke**. Arq. Neuro-Psiquiatr., São Paulo , v. 78, n. 11, p. 724-732, Nov. 2020 . Epub Dec 14, 2020. <https://doi.org/10.1590/0004-282x20200087>.

C. CHATFIELD, **The analysis of time series: an introduction**. Chapman and Hall/CRC, 2016

CANNON WB. **The Wisdom of the Body**. New York: W. W. Norton & Company; 1932. pp. 177–201.

CARNETHON, Mercedes R et al. **"Does the cardiac autonomic response to postural change predict incident coronary heart disease and mortality? The Atherosclerosis Risk in Communities Study."** American journal of epidemiology vol. 155,1 (2002): 48-56. doi:10.1093/aje/155.1.48

CASSON A. J., GALVEZ A. V. and JARCHI D., **"Gyroscope vs. accelerometer measurements of motion from wrist PPG during physical exercise"**, ICT Exp., vol. 2, no. 4, pp. 175-179, 2016

CHABOT, Denis & BAYER, Max & DE ROSS, André. (1991). **Instantaneous heart rates and other techniques introducing errors in the calculation of heart rate.** Canadian journal of zoology. 69. 1117-1120. 10.1139/z91-156.

CHAN K. W. and ZHANG Y. T., "**Adaptive reduction of motion artifact from photoplethysmographic recordings using a variable step-size LMS filter,**" SENSORS, 2002 IEEE, 2002, pp. 1343-1346 vol.2, doi: 10.1109/ICSENS.2002.1037314.

CHATFIELD C., **The Analysis of Time Series. An Introduction.** CRC Press, Jul. 2003, Sixth edition, ISBN: 1-58488-317-0

DAS S., PAL S. and MITRA M., "**Real time heart rate detection from PPG signal in noisy environment**", Proc. Int. Conf. Intell. Control Power Instrum. (ICICPI), pp. 70-73, Oct. 2016

DU J., VONG C. and CHEN C. L. P., **Novel Efficient RNN and LSTM-Like Architectures: Recurrent and Gated Broad Learning Systems and Their Applications for Text Classification**, in IEEE Transactions on Cybernetics, vol. 51, no. 3, pp. 1586-1597, March 2021, doi: 10.1109/TCYB.2020.2969705.

EBADI Jalal, M., HOSSEINI, M., & KARLSSON, S. (2016). **Forecasting incoming call volumes in call centers with recurrent Neural Networks.** Journal of Business Research, 69(11), 4811–4814. doi:10.1016/j.jbusres.2016.04.035

EVRENGÜL Harun, TANRIVERDI Halil, DURSONOGLU Dursun, KAFTAN Asuman, KURU Omur, UNLU Unal, KILIC Mustafa, **Time and frequency domain analyses of heart rate variability in patients with epilepsy**, Epilepsy Research, Volume 63, Issues 2–3, 2005, Pages 131-139, ISSN 0920-121.

FINE, J.; BRANAN, K.L.; RODRIGUEZ, A.J.; BOONYA-ANANTA, T.; AJMAL; RAMELLA-ROMAN, J.C.; MCSHANE, M.J.; COTÉ, G.L. **Sources of Inaccuracy in Photoplethysmography for Continuous Cardiovascular Monitoring.** Biosensors 2021, 11, 126

FORTE G, FAVIERI F, CASAGRANDE M. **Heart Rate Variability and Cognitive Function: A Systematic Review**. Front Neurosci. 2019 Jul 9;13:710. doi: 10.3389/fnins.2019.00710. PMID: 31354419; PMCID: PMC6637318.

FOURNIÉ C, CHOUCOU F, DALLEAU G, CADERBY T, CABRERA Q, VERKINDT C, **Heart rate variability biofeedback in chronic disease management: A systematic review**, Complementary Therapies in Medicine, Volume 60, 2021, 102750, ISSN 0965-2299

FUKUSHIMA H, KAWANAKA H, BHUIYAN MS, OGURI K. **Estimating heart rate using wrist-type Photoplethysmography and acceleration sensor while running**. Annu Int Conf IEEE Eng Med Biol Soc. 2012;2012:2901-2904. doi:10.1109/EMBC.2012.6346570

G. SHMUELI and K. C LICHTENDAHL. Jr, **Practical Time Series Forecasting with R: A Hands-On Guide**. Axelrod Schnall Publishers, 2016

GEORGIU K, LARENTZAKIS AV, KHAMIS NN, ALSUHAIBANI GI, ALASKA YA, and GIALLAFOU EJ. **Can wearable devices accurately measure heart rate variability? A systematic review**. Folia Med. (2018) 60:7–20. doi: 10.2478/foamed-2018-0012

GORDAN R, GWATHMEY JK, XIE LH. **Autonomic and endocrine control of cardiovascular function**. World J Cardiol. 2015 Apr 26;7(4):204-14. doi: 10.4330/wjc.v7.i4.204. PMID: 25914789; PMCID: PMC4404375.

HAES ALHELOU H, HAMEDANI-GOLSHA ME, NJENDA TC, SIANO P. **A Survey on Power System Blackout and Cascading Events: Research Motivations and Challenges**. Energies. 2019; 12(4):682. <https://doi.org/10.3390/en12040682>

HILL, N., & BRIERLEY, J. (2003). **How to Measure Customer Satisfaction (2nd ed.)**. Routledge. <https://doi.org/10.4324/9781315253107>

HOCHREITER, Sepp & SCHMIDHUBER, Jürgen. (1997). Long Short-term Memory. *Neural computation*. 9. 1735-80. 10.1162/neco.1997.9.8.1735.

HUANG, B.Q. & RASHID, T. & KECHADI, T. (2007). **Multi-Context Recurrent Neural Network for Time Series Applications**. *Computational Intelligence - CI*.

HUIKURI HV, PERKIÖMÄKI JS, MAESTRI R, PINNA GD. **Clinical impact of evaluation of cardiovascular control by novel methods of heart rate dynamics**. *Philos Trans A Math Phys Eng Sci*. 2009 Apr 13;367(1892):1223-38. doi: 10.1098/rsta.2008.0294. PMID: 19324705.

HUIKURI HV. **Heart rate variability in coronary artery disease**. *J Intern Med*. 1995 Apr;237(4):349-57. doi: 10.1111/j.1365-2796.1995.tb01186.x. PMID: 7714457.

HYNDMAN, R. J., & ATHANASOPOULOS, G. (2018). **Forecasting: Principles and Practice**. (2nd ed.) OTexts. <https://otexts.org/fpp2/>

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Projeções da população: Brasil e unidades da federação**. 2. ed. rev. Rio de Janeiro: IBGE, 2018. 56 p. v. 40. ISBN 9788524044649. 56p.

IBRAHIM R., and ECUYER P. L., “**Forecasting Call Center Arrivals: A COMPARATIVE STUDY**,” no. 2010, pp. 1–33, 2011

JANDACKOVA VK, SCHOLLES S, BRITTO A, STEPTOE A. **Are Changes in Heart Rate Variability in Middle-Aged and Older People Normative or Caused by Pathological Conditions? Findings From a Large Population-Based Longitudinal Cohort Study**. *J Am Heart Assoc*. 2016 Feb 12;5(2):e002365. doi: 10.1161/JAHA.115.002365. PMID: 26873682; PMCID: PMC4802439.

JEYHANI, V., MAHDIANI, S., PELTOKANGAS, M., & VEHKAOJA, A. (2015). **Comparison of HRV parameters derived from photoplethysmography and**

electrocardiography signals. 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).

KAMATH M. V., FALLEN E. L. (1995). **Correction of the heart rate variability signal for ectopics and missing beats**, in **Heart Rate Variability**, eds M. Malik, Camm A. J. (Armonk, NY: Futura Publishing Co. Inc.), 75–85.

KARIMI, J., SOMERS, T. M., & GUPTA, Y. P. (2001). **Impact of Information Technology Management Practices on Customer Service**. *Journal of Management Information Systems*, 17(4), 125–158.

KARLSSON M, HÖRNSTEN R, RYDBERG A, WIKLUND U. **Automatic filtering of outliers in RR intervals before analysis of heart rate variability in Holter recordings: a comparison with carefully edited data**. *Biomed Eng Online*. 2012;11:2. Published 2012 Jan 11. doi:10.1186/1475-925X-11-2

KEMPER KJ, HAMILTON C, ATKINSON M. **Heart rate variability: impact of differences in outlier identification and management strategies on common measures in three clinical populations**. *Pediatr Res*. 2007;62(3):337-342. doi:10.1203/PDR.0b013e318123fbcc

KIDGER, Patrick et al. **Neural controlled differential equations for irregular time series**. *Advances in Neural Information Processing Systems*, v. 33, p. 6696-6707, 2020.

KIM B. S. and YOO S. K., "**Motion artifact reduction in photoplethysmography using independent component analysis**", *IEEE Trans. Biomed. Eng.*, vol. 53, no. 3, pp. 566-568, Mar. 2006.

KOOLE, G., 2013. **Call Center Optimization**. MG Books.

KRISHNAN R., NATARAJAN B. and WARREN S., "**Two-stage approach for detection and reduction of motion artifacts in photoplethysmographic data**", *IEEE Trans. Biomed. Eng.*, vol. 57, no. 8, pp. 1867-1876, Aug. 2010

L. YUNPENG, H. Di, B. JUNPENG and Q. YONG, **Multi-step Ahead Time Series Forecasting for Different Data Patterns Based on LSTM Recurrent Neural Network**, 2017 14th Web Information Systems and Applications Conference (WISA), Liuzhou, China, 2017, pp. 305-310, doi: 10.1109/WISA.2017.25.

LAHDENOJA A, HURNANEN, TADI M, PÄNKÄÄLÄ M and KOIVISTO T, **"Heart rate variability estimation with joint accelerometer and gyroscope sensing"**, Proc. Comput. Cardiol. Conf. (CinC), pp. 717-720, Sep. 2016

LEE C. M. and ZHANG Y. T., **"Reduction of motion artifacts from photoplethysmographic recordings using a wavelet denoising approach,"** IEEE EMBS Asian-Pacific Conference on Biomedical Engineering, 2003., 2003, pp. 194-195, doi: 10.1109/APBME.2003.1302650.

LEE H., CHUNG H. and LEE J., **"Motion artifact cancellation in wearable photoplethysmography using gyroscope"**, IEEE Sensors J., vol. 19, no. 3, pp. 1166-1175, Feb. 2019

LEPOT, M.; AUBIN, J.-B.; CLEMENS, F.H. **Interpolation in Time Series: An Introductory Overview of Existing Methods, Their Performance Criteria and Uncertainty Assessment**. Water 2017, 9, 796.

Liheng Zhang, Charu Aggarwal, and Guo-Jun Qi. 2017. **Stock Price Prediction via Discovering Multi-Frequency Trading Patterns**. In Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '17). Association for Computing Machinery, New York, NY, USA, 2141–2149. <https://doi.org/10.1145/3097983.3098117>

LU G, YANG F, TAYLOR JA, STEIN JF. **A comparison of photoplethysmography and ECG recording to analyse heart rate variability in healthy subjects**. J Med Eng Technol. 2009;33(8):634-41. doi: 10.3109/03091900903150998. PMID: 19848857.

MAIER, H. R., & DANDY, G. C. (2000). **Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications.** *Environmental Modelling & Software*, 15(1), 101–124. doi:10.1016/s1364-8152(99)00007-9

MALIK, M. (1996), **Heart Rate Variability.** *Annals of Noninvasive Electrocardiology*, 1: 151-181. <https://doi.org/10.1111/j.1542-474X.1996.tb00275.x>

MANDIC, Danilo; CHAMBERS, Jonathon. **Recurrent neural networks for prediction: learning algorithms, architectures and stability.** Wiley, 2001.

MASINI, R. P., MEDEIROS, M. C., & MENDES, E. F. (2021). **Machine Learning Advances for Time Series Forecasting.** *Journal of Economic Surveys*. doi:10.1111/joes.12429

MASTOROCOSTAS, Paris & HILAS, Constantinos & VARSAMIS, Dimitrios & DOVA, Stergiani. (2013). **A Recurrent Neural Network--based Forecasting System for Telecommunications Call Volume.** *Applied Mathematics & Information Sciences*. 7. 1643-1650. 10.12785/amis/070501.

MCCRATY R, SHAFFER F. **Heart rate variability: new perspectives on physiological mechanisms, assessment of self-regulatory capacity, and health risk.** *Glob Adv Health Med* (2015) 4:46–61. 10.7453/gahmj.2014.073

MENDENHALL, W.; REINMUTH, J.Ee BEAVER, R.J. (1993) **Statistics for Management and Economics.** Duxbury Press, California.

MINISTÉRIO DA SAÚDE, 2006. Disponível em: http://bvsms.saude.gov.br/bvs/saudelegis/gm/2006/prt2528_19_10_2006.html.

MONTESINO POUZOLS, Federico & LENDASSE, Amaury. (2010). **Effect of different detrending approaches on computational intelligence models of time series.** *Proceedings of the International Joint Conference on Neural Networks*. 1-8. 10.1109/IJCNN.2010.5596314.

MOOD, Alexander M., GRAYBILL, Franklin A. & BOES, Duane C. **Introduction to the Theory of Statistics**. 1973.

MORAES, E.N. (2008). **Processo de envelhecimento e bases da avaliação multidimensional do idoso**. In: Borges, A.P.A. & Coimbra, A.M.C. (Orgs.). Envelhecimento e Saúde da Pessoa Idosa, 155. Rio de Janeiro (RJ): EAD/ENSP.

MORELL D, ROSSI A, CAIRO M, CLIFTON DA. **Analysis of the Impact of Interpolation Methods of Missing RR-intervals Caused by Motion Artifacts on HRV Features Estimations**. Sensors (Basel). 2019 Jul 18;19(14):3163. doi: 10.3390/s19143163. PMID: 31323850; PMCID: PMC6679245.

MURPHY, Kevin P. **Machine Learning: A Probabilistic Perspective**. 2012. MIT Press.

MUSHTAQ, RIZWAN, **Augmented Dickey Fuller Test**. August 17, 2011. Available at: <http://dx.doi.org/10.2139/ssrn.1911068>

NARDELLI, M.; VANELLO, N.; GALPERTI, G.; GRECO, A.; SCILINGO, E.P. **Assessing the Quality of Heart Rate Variability Estimated from Wrist and Finger PPG: A Novel Approach Based on Cross-Mapping Method**. Sensors 2020, 20, 3156. <https://doi.org/10.3390/s20113156>

NOR, Maria Elena; SAFUAN, Hamizah Mohd; SHAB, Noorzehan Fazahiyah Md; ASRUL, Mohd, ABDULLAH, Affendi, MOHAMAD, Nurul Asmaa Izzati and LEE, Muhammad Hisyam. **Neural network versus classical time series forecasting models**. AIP Conference Proceedings 1842, 030027 (2017) <https://doi.org/10.1063/1.4982865>

ONU - United Nations, Department of Economic and Social Affairs, Population Division (2019). **World Population Prospects 2019: Highlights**. ST/ESA/SER.A/423

PARK DH, SHIN CJ, HONG SC, YU J, RYU SH, KIM EJ, SHIN HB, SHIN BH. **Correlation between the severity of obstructive sleep apnea and heart rate variability indices.** J Korean Med Sci. 2008 Apr;23(2):226-31. doi: 10.3346/jkms.2008.23.2.226. PMID: 18437004; PMCID: PMC2526439.

PÉREZ-RIERA AR, BARBOSA-BARROS R, DAMINELLO-RAIMUNDO R, et al. **Main artifacts in electrocardiography.** Ann Noninvasive Electrocardiol 2017; doi:10.1111/ anec.12494

PETELCZYC M., GIERALTOWSKI J. J., ZOGALA-SIUDEM B. and SIUDEM G., **"Impact of observational error on heart rate variability analysis"**, Heliyon, vol. 6, no. 5, May 2020

PINHEIRO, N.; COUCEIRO, R.; HENRIQUES, J.; MUEHLSTEFF, J.; QUINTAL, I.; GONCALVES, L.; CARVALHO, P. **Can PPG be used for HRV analysis?** In Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Orlando, FL, USA, 16–20 August 2016; pp. 2945–2949.

PRATAMA, Irfan & PERMANASARI, Adhistya & ARDIYANTO, Igi & INDRAYANI, Rini. (2016). **A review of missing values handling methods on time-series data.** 1-6. 10.1109/ICITSI.2016.7858189

RA FEINBERG, IS KIM, L HOKAMA, K DE RUYTER, C KEEN (2000), **Operational determinants of caller satisfaction in the call center**, International Journal of Service Industry Management

RIPA J. and CHEAIB R., **"Real-time call center call monitoring and analysis,"** Dec. 13 2016. US Patent 9,521,258

Rodrigues, E.; Lima, D.; Barbosa, P.; Gonzaga, K.; Guerra, R.O.; Pimentel, M.; Barbosa, H.; Maciel, Á. **HRV Monitoring Using Commercial Wearable Devices as a Health Indicator for Older Persons during the Pandemic.** Sensors 2022, 22, 2001. <https://doi.org/10.3390/s22052001>

RUMELHART, D., Hinton, G. & Williams, R. **Learning representations by back-propagating errors**. Nature 323, 533–536 (1986).

SAAD, PM. **Envelhecimento populacional: demandas e possibilidades na área de saúde**. Associação Brasileira de Estudos Populacionais; 2016

SIDDHARTH, A. N. PATEL, T. -P. JUNG and T. J. SEJNOWSKI, "**A Wearable Multi-Modal Bio-Sensing System Towards Real-World Applications**," in IEEE Transactions on Biomedical Engineering, vol. 66, no. 4, pp. 1137-1147, April 2019, doi: 10.1109/TBME.2018.2868759.

SIDOROV I. S., ROMASHKO R. V., KOVAL V. T., GINIATULLIN R. and KAMSHILIN A. A., "**Origin of infrared light modulation in reflectance-mode photoplethysmography**", PLoS ONE, vol. 11, no. 10, Oct. 2016

TARVAINEN, M.; LIPPONEN, J.; NISKANEN, J.; RANTA-AHO, P. **Kubios HRV Software: User's Guide**, Version 3. 5; Kubios Oy: Kuopio, Finland, 2021.

TAYLOR J. W., "**Forecasting Intraday Arrivals at a Call Center A Comparison of Univariate Time Series Methods for Forecasting Intraday Arrivals at a Call Center**," no. September 2015, 2007, doi: 10.1287/mnsc.1070.0786

TEMKO A., "**Accurate heart rate monitoring during physical exercises using PPG**", IEEE Trans. Biomed. Eng., vol. 64, no. 9, pp. 2016-2024, Sep. 2017

UMETANI K, SINGER DH, MCCRATY R, ATKINSON M. **Twenty-four hour time domain heart rate variability and heart rate: relations to age and gender over nine decades**. J Am Coll Cardiol. 1998;31(3):593-601. doi:10.1016/s0735-1097(97)00554-8

Usman M. Umer, Tuba Sevil, Güven Sevil, **Forecasting performance of smooth transition autoregressive (STAR) model on travel and leisure stock index**, The

Journal of Finance and Data Science, Volume 4, Issue 2, 2018, ISSN 2405-9188, <https://doi.org/10.1016/j.jfds.2017.11.00>

VANDERLEI LCM, PASTRE CM, HOSHI RA, CARVALHO TD, GODOY MF. **Basic notions of heart rate variability and its clinical applicability.** Braz J Cardiovasc Surg. 2009;24(2):205-217

VOSS A, SCHROEDER R, HEITMANN A, PETERS A, PERZ S (2015) **Short-Term Heart Rate Variability—Influence of Gender and Age in Healthy Subjects.** PLOS ONE 10(3): e0118308. <https://doi.org/10.1371/journal.pone.0118308>

YASRAB R, POUND M. (2020). **PhenomNet: Bridging Phenotype-Genotype Gap: A CNN-LSTM Based Automatic Plant Root Anatomization System.** 10.1101/2020.05.03.075184.

YOUNG, Hayley A.; BENTON, David **Heart-rate variability: a biomarker to study the influence of nutrition on physiological and psychological health?**, Behavioural Pharmacology: April 2018 - Volume 29 - Issue 2 and 3 - p 140-151 doi: 10.1097/FBP.0000000000000383

YU J, de Antonio A, VILLALBA-MORA E. **Deep Learning (CNN, RNN) Applications for Smart Homes: A Systematic Review.** Computers. 2022; 11(2):26. <https://doi.org/10.3390/computers11020026>

ZANON, Rodrigo Rafael, MORETTO, Antonio Carlos e RODRIGUES, Rossana Lott. **Envelhecimento populacional e mudanças no padrão de consumo e na estrutura produtiva brasileira.** Revista Brasileira de Estudos de População [online]. 2013, v. 30, pp. S45-S67.

ZULLI R, NICOSIA F, BORRONI B, AGOSTI C, PROMETTI P, DONATI P, DE VECCHI M, ROMANELLI G, GRASSI V, PADOVANI A. **QT dispersion and heart rate variability abnormalities in Alzheimer's disease and in mild cognitive impairment.** J Am Geriatr Soc. 2005 Dec;53(12):2135-9. doi: 10.1111/j.1532-5415.2005.00508.x. PMID: 16398898.

APÊNDICE A – DADOS

Acesso aos arquivos CSV contendo os dados brutos dos dispositivos vestíveis (Fitbit PPG e Polar ECG), disponível no GitHub: <https://github.com/daniellalima/mestrado-hrv>

