



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO DE JOINVILLE
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE SISTEMAS
ELETRÔNICOS

VICTOR EBERHARDT MENEGON

**APRENDIZADO DE MÁQUINA APLICADO À DETECÇÃO DE FIBRILAÇÃO ATRIAL
UTILIZANDO SENSOR DE FOTOPLETISMOGRAFIA EM MICROCONTROLADOR
EMBARCADO**

Joinville
2026

Victor Eberhardt Menegon

**APRENDIZADO DE MÁQUINA APLICADO À DETECÇÃO DE FIBRILAÇÃO ATRIAL
UTILIZANDO SENSOR DE FOTOPLETISMOGRAFIA EM MICROCONTROLADOR
EMBARCADO**

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

Orientador: Prof. Anderson Wedderhoff Spengler, Dr.

Joinville
2026

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Eberhardt Menegon, Victor
APRENDIZADO DE MÁQUINA APLICADO À DETECÇÃO DE FIBRILAÇÃO
ATRIAL UTILIZANDO SENSOR DE FOTOPLETISMOGRAFIA EM
MICROCONTROLADOR EMBARCADO / Victor Eberhardt Menegon ;
orientador, Anderson Spengler, 2025.
93 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Campus Joinville, Programa de Pós-Graduação em
Engenharia de Sistemas Eletrônicos, Joinville, 2025.

Inclui referências.

1. Engenharia de Sistemas Eletrônicos. 2. Fibrilação
Atrial. 3. Fotopletismografia. 4. Sistemas Embarcados. 5.
Aprendizado de Máquina. I. Spengler, Anderson. II.
Universidade Federal de Santa Catarina. Programa de Pós
Graduação em Engenharia de Sistemas Eletrônicos. III. Título.

Victor Eberhardt Menegon

Aprendizado de máquina aplicado à detecção de Fibrilação Atrial utilizando sensor de fotopleletismografia em microcontrolador embarcado

O presente trabalho em nível de Mestrado foi avaliado e aprovado, em 16 de outubro de 2025, pela banca examinadora composta pelos seguintes membros:

Prof. Anderson Wedderhoff Spengler, Dr.

UFSC

Prof. Lucas Weihmann, Dr.

UFSC

Prof. Rodrigo Moreira Bacurau, Dr.

Unicamp

Certificamos que esta é a versão original e final do trabalho de conclusão que foi julgado adequado para obtenção do título de Mestre em Engenharia de Sistemas Eletrônicos.

Coordenação do Programa de
Pós-Graduação

Prof. Anderson Wedderhoff Spengler, Dr.

Orientador

Joinville, 2026.

Este trabalho é dedicado a minha família que me apoiou em todos os momentos.

AGRADECIMENTOS

Obrigado principalmente a Deus por ter me guiado e capacitado em todos os momentos. Obrigado a minha esposa, Carina, por sempre estar ao meu lado e ao meu pai por ter incentivado imensamente nessa jornada. Muito obrigado ao professor Anderson pela orientação e por todo o suporte.

RESUMO

A Fibrilação Atrial (FA) é uma arritmia cardíaca que acomete 1-2% da população e, a sua presença, aumenta a probabilidade do indivíduo desenvolver um quadro clínico de derrame, podendo ser fatal. O monitoramento contínuo através de dispositivos como relógios inteligentes representa uma alternativa promissora aos métodos tradicionais, como o eletrocardiograma. Este estudo desenvolve e valida um modelo de aprendizado de máquina otimizado para a detecção de FA a partir de sinais simulados de fotopletismografia (PPG). Foram utilizados 4400 sinais de PPG simulados e processados em janelas de 10 segundos, foram também comparadas diferentes abordagens de aprendizado de máquina, como arquiteturas clássicas com engenharia e seleção de características e de aprendizado profundo. O modelo de Redes Neurais Convolucionais (CNN), projetado com enfoque na viabilidade de implementação da solução em sistemas embarcados, atingiu valores superiores sobre a abordagem de referência (*Random Forest*), alcançando um F1-Score de 0,71 e uma Área Sob a Curva ROC (AUC) de 0,9232. Os resultados validam a arquitetura CNN como o melhor compromisso entre alta performance preditiva e a exequibilidade em um dispositivo com recursos computacionais limitados.

Palavras-chave: Fibrilação Atrial. Arritmia Cardíaca. Aprendizado de Máquina. Sistemas Embarcados. Fotopletismografia.

ABSTRACT

Atrial Fibrillation (AF) is a cardiac arrhythmia that affects 1-2% of the population, and its presence increases the individual's probability of developing a clinical stroke, which can be fatal. Continuous monitoring through devices such as smartwatches represents a promising alternative to traditional methods, like the electrocardiogram. This study develops and validates an optimized machine learning model for AF detection from simulated photoplethysmography (PPG) signals. Using 4400 simulated PPG signals processed in 10-second windows, different machine learning approaches were also compared, such as classic architectures with feature engineering and selection, and deep learning. The Convolutional Neural Network (CNN) model, designed with a focus on the feasibility of implementing the solution in embedded systems, achieved superior results over the reference approach (Random Forest), reaching an F1-Score of 0.71 and an Area Under the ROC Curve (AUC) of 0.9232. The results validate the CNN architecture as the best compromise between high predictive performance and feasibility on a device with limited computational resources.

Keywords: Atrial Fibrillation. Heart Arrhythmia. Machine Learning. Embedded Systems. Photoplethysmography.

LISTA DE FIGURAS

Figura 2.1 – Posicionamento de ECG de 12 derivações (UNIVERSITY OF ROCHESTER MEDICAL CENTER ROCHESTER, 2024)	25
Figura 2.2 – Sinais capturados por ECG com 12 derivações (JENKINS; GERRED, 2017)	26
Figura 2.3 – Ciclo Cardíaco (AZIZ; AHMED; ALOUINI, 2021)	27
Figura 2.4 – Ciclo Cardíaco através de PPG	28
Figura 4.1 – Fluxograma da metodologia adotada, desde a geração dos dados até a validação embarcada.	47
Figura 5.1 – Amostra de sinal PPG simulado em Ritmo Sinusal (RS). Notar a periodicidade regular e a morfologia consistente dos pulsos, características de um ritmo cardíaco normal.	70
Figura 5.2 – Amostra de sinal PPG simulado com Fibrilação Atrial (FA). Observa-se a clara irregularidade tanto no intervalo entre os pulsos quanto na amplitude dos picos, padrões que o modelo de aprendizado de máquina visa detectar.	71
Figura 5.3 – Mapa de calor da correlação de Pearson entre as características extraídas.	75
Figura 5.4 – Curvas de Precisão, Sensibilidade e F1-Score em função do limiar de decisão para o modelo <i>Random Forest</i> . O limiar ótimo, que maximiza o F1-Score, está indicado pela linha vertical tracejada.	77
Figura 5.5 – Curvas de Precisão, Sensibilidade e F1-Score em função do limiar de decisão para o modelo MLP. A análise mostra o ponto de corte ideal para maximizar o F1-Score, ajustando o modelo para seu melhor desempenho.	77
Figura 5.6 – Curvas de Precisão, Sensibilidade e F1-Score em função do limiar de decisão para o modelo CNN	78
Figura 5.7 – Curvas de Precisão, Sensibilidade e F1-Score em função do limiar de decisão para o modelo híbrido CNN-LSTM.	79
Figura 5.8 – Comparativo das curvas ROC e seus respectivos valores de AUC para os melhores modelos de cada abordagem no conjunto de teste.	82

LISTA DE ABREVIATURAS E SIGLAS

RS	Ritmo Sinusal	21
FA	Fibrilação Atrial	21
ECG	Eletrocardiograma	21
PPG	Fotopletismografia	21
VFC	Variabilidade da Frequência Cardíaca	29
LDA	Análise Discriminante Linear	30
PCA	Análise de Componentes Principais	30
FFT	Transformada Rápida de Fourier	30
VPG	Pletismograma de Velocidade	30
APG	Pletismograma de Aceleração	30
PPI	Intervalo Pulso-a-Pulso	30
RFE	Eliminação recursiva de características	30
MLP	Perceptron Multicamadas	30
MI	Informação Mútua	32
ANOVA	Análise de Variância	33
CNN	Redes Neurais Convolucionais	38
Adam	Estimativa adaptativa de momentos	40
SDNN	Desvio Padrão dos Intervalos NN	54
RMSSD	Raiz quadrada da média das diferenças quadráticas sucessivas	54
LSTM	Memória de Curto e Longo Prazo	62
RNN	Rede Neural Recorrente	62
QAT	Treinamento Consciente de Quantização	62
AUC-ROC	Área sob a curva característica de operação do receptor	64
MACC	Operação Multiplicação-Adição	81

SUMÁRIO

1	INTRODUÇÃO	21
1.1	OBJETIVOS	22
1.1.1	Objetivo Geral	22
1.1.2	Objetivos Específicos	22
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	O CICLO CARDÍACO E A AFERIÇÃO DOS SINAIS ELÉTRICOS	25
2.1.1	Eletrocardiograma	25
2.1.2	Fotopletismografia	26
2.1.3	Arritmia Cardíaca e Fibrilação Atrial	28
2.1.4	Relações entre ECG e PPG	29
2.2	APRENDIZADO DE MÁQUINA	29
2.2.1	Abordagem Clássica: Engenharia de Características Manuais	30
2.2.1.1	Extração de Características	31
2.2.1.2	Métodos de Seleção de Características	32
2.2.1.3	Modelos Classificadores Tabulares	35
2.2.1.3.1	<i>Perceptron Multicamadas (MLP)</i>	35
2.2.1.3.2	<i>Random Forest</i>	37
2.2.2	Abordagem com Aprendizado Profundo	38
2.2.2.1	Redes Neurais Convolucionais (CNN) para Séries Temporais	38
2.2.2.2	<i>Long-Short Term Memory (LSTM)</i> para Análise Sequencial	38
2.2.2.3	Arquiteturas Híbridas (CNN-LSTM)	39
2.2.3	Técnicas de Treinamento e Otimização	39
2.2.3.1	Tratamento de Dados Desbalanceados	40
2.2.3.2	Otimizador Adam	40
2.2.3.3	Prevenção de Sobreajuste e Otimização da Taxa de Aprendizado	40
3	ESTADO DA ARTE	43
4	MATERIAIS E MÉTODOS	47
4.1	GERAÇÃO DE DADOS	48
4.2	DIVISÃO DO CONJUNTO DE DADOS E ESTRATÉGIA DE VALIDAÇÃO	48
4.3	BALANCEAMENTO DE CLASSES COM SMOTE	49
4.4	ABORDAGEM 1: MODELAGEM COM ENGENHARIA DE CARACTERÍSTICAS MANUAIS	49
4.4.1	Extração de características	50
4.4.1.1	Características Estatísticas do Sinal Bruto	50
4.4.1.2	Características de Frequência do Sinal Normalizado (FFT)	51
4.4.1.3	Características da Velocidade do Sinal (VPG)	53
4.4.1.4	Características da Aceleração do Sinal (APG)	53

4.4.1.5	Características Morfológicas do Pulso	54
4.4.1.6	Características de Variabilidade do Pulso (PPI)	54
4.4.2	Seleção de características	55
4.4.3	Modelos Classificadores da Abordagem Clássica	56
4.4.3.1	<i>Perceptron Multicamadas</i> (MLP)	56
4.4.3.2	<i>Random Forest</i>	58
4.5	ABORDAGEM 2: MODELO DE APRENDIZADO PROFUNDO PURO	59
4.5.1	Preparação dos Dados Sequenciais	59
4.5.2	Arquitetura Puramente Convolucional (CNN)	60
4.6	ABORDAGEM 3: INVESTIGAÇÃO DE PERFORMANCE COM ARQUITE- TURA HÍBRIDA	61
4.6.1	Arquitetura Híbrida CNN-LSTM: Análise de Dependências Temporais com LSTM	62
4.7	OTIMIZAÇÃO DE MODELO PARA AMBIENTE EMBARCADO	62
4.7.1	Conversão para Ponto Flutuante (float16) com <i>half-precision</i>	62
4.7.2	Investigação da Quantização para Inteiros (int8)	63
4.8	MÉTRICAS DE AVALIAÇÃO	64
4.8.1	Métricas de Performance Preditiva	64
4.8.2	Métricas de Custo Computacional	65
4.9	FERRAMENTAS E AMBIENTE COMPUTACIONAL	66
5	RESULTADOS	69
5.1	GERAÇÃO DE DADOS	69
5.2	ANÁLISE DE CORRELAÇÃO E SELEÇÃO DE CARACTERÍSTICAS	72
5.2.1	Conexão com os Métodos de Seleção de Características	73
5.3	APRENDIZADO DE MÁQUINA	75
5.3.1	Resultados da Abordagem 1: Modelo Clássico	75
5.3.2	Resultados da abordagem 2: Modelo otimizado de aprendizagem profunda com CNN	77
5.3.3	Resultado da abordagem 3: Arquitetura Híbrida com CNN-LSTM	78
5.4	RESULTADOS DA OTIMIZAÇÃO DO MODELO PARA AMBIENTE EMBAR- CADO	79
5.4.1	Análise da Quantização para Inteiros com 8-bits	79
5.4.2	Análise da Conversão para ponto flutuante com 16-bits	80
5.5	RESULTADOS DA PERFORMANCE EMBARCADA	81
5.6	ANÁLISE COMPARATIVA E CONCLUSÃO DOS RESULTADOS	81
6	CONCLUSÃO	85
6.1	RESPOSTA AOS OBJETIVOS ESPECÍFICOS	85
6.2	TRABALHOS FUTUROS	86
	REFERÊNCIAS	89

1 INTRODUÇÃO

Dentre as diversas doenças cardíacas, a arritmia se caracteriza por apresentar algum grau de irregularidade nos batimentos cardíacos por no mínimo 30 segundos, ou seja, o coração não segue o chamado Ritmo Sinusal (RS). A mais comum entre as arritmias, é a Fibrilação Atrial (FA), a qual acomete cerca de 1-2% da população em geral (CAMM et al., 2010).

Diferentemente das contrações prematuras do coração, nas quais o coração contrai antes do momento esperado quando comparado ao RS, na FA o átrio do coração fibrila fazendo com que o sangue não seja bombeado corretamente, criando o risco do surgimento de coágulos, podendo levar a infartos e até a morte. Alguns outros sintomas causados pela FA são fadiga, palpitações, dispnéia, hipotensão, síncope e/ou insuficiência cardíaca (JANUARY et al., 2014).

O surgimento dessa doença se dá pela deterioração cardíaca causada por algumas condições como obesidade, disfunções da tireoide, hipertensão, idade, entre outras (CAMM et al., 2010). Alguns fatores são significativos para o desenvolvimento de FA como gênero, idade e infarto do miocárdio anteriormente. Por exemplo, homens aumentaram a presença de 4.9% para 17,1% quando os pacientes já tiveram infarto do miocárdio (WOLF et al., 1996). Quando um paciente desenvolve FA, ela pode se iniciar com caráter paroxístico, ou seja, um descompasso agudo no batimento cardíaco surge e some repentinamente. Com o passar do tempo, esta característica deteriora a saúde do coração, podendo tornar-se em FA permanente, não permitindo que o ritmo do coração se converta novamente para RS (MSD MANUAL, 2023).

Tradicionalmente a detecção de FA se dá através de eletrocardiograma (ECG), porém como mencionado anteriormente, muitas vezes no seu estado inicial, o FA é raro e rápido, dificultando ou até mesmo impossibilitando que a doença seja detectada durante um ECG de rotina, em que não é realizada a aquisição dos sinais do coração por um longo período de tempo.

Como solução, vários estudos foram realizados utilizando o sensor de fotople-tismografia (PPG), visto que diversos relógios inteligentes comerciais possuem este sensor. O sensor funciona em conjunto com LEDs verdes, os quais emitem luz em direção a pele do paciente. Durante o ciclo cardíaco, os vasos sanguíneos se dilatam e contraem, fazendo com que a refração do feixe luminoso se altere. O sensor então capta essa variação relacionada a variação no bombeamento sanguíneo (VOISIN et al., 2018). Desta maneira o paciente pode ter o coração monitorado em todos os instantes por quanto tempo seja necessário, além de ser um método menos invasivo, visto que o ECG exige o posicionamento de 12 eletrodos no corpo do paciente.

Um dos desafios da utilização do PPG em relógio inteligente é a presença de artefatos de movimento, os quais nada mais são que anormalidades na medição do

sinal causadas por movimentos. Outro desafio são as limitações de memória e processamento de um microcontrolador, o que torna de suma importância o balanço entre a acuracidade do modelo e sua implementação com o menor número de parâmetros e menor custo computacional no processamento das medições possíveis.

Diante desses desafios, a principal contribuição deste trabalho é o desenvolvimento e a validação de uma metodologia otimizada para a criação de um modelo de aprendizado de máquina, baseado em Redes Neurais Convolucionais (CNN), que representa o melhor compromisso entre alta performance preditiva e a viabilidade de implementação em um microcontrolador de baixo custo para a detecção de Fibrilação Atrial. O estudo demonstra a superioridade da abordagem de aprendizado profundo em comparação com a engenharia de características clássica e valida sua eficácia em um ambiente de sistemas embarcados com recursos limitados.

Para atingir este objetivo, a dissertação está estruturada da seguinte forma: o Capítulo 2 apresenta a fundamentação teórica sobre o ciclo cardíaco, o sinal de fotopletoislografia e as técnicas de aprendizado de máquina utilizadas. O Capítulo 3 revisa os trabalhos relevantes na área, contextualizando a presente pesquisa. O Capítulo 4 detalha toda a metodologia experimental, desde a geração de dados sintéticos até a arquitetura dos modelos e as métricas de avaliação. Os resultados obtidos são apresentados e analisados no Capítulo 5. Por fim, o Capítulo 6 discute as conclusões do trabalho e propõe direções para pesquisas futuras.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Propor e avaliar arquiteturas de aprendizado de máquina para a detecção de Fibrilação Atrial via sinais de fotopletoislografia, com foco em sistemas embarcados. Busca-se identificar e validar o modelo que oferece o melhor compromisso entre alta performance preditiva e a viabilidade de implementá-lo em um sistema embarcado com restrições de capacidade computacional.

1.1.2 Objetivos Específicos

Desenvolvimento e comparação de algoritmos em um ambiente controlado visando:

1. Investigar se características baseadas na variabilidade do pulso (PPI), como a raiz quadrada da média dos quadrados das diferenças (RMSSD) e entropia amostral, apresentarão maior poder discriminativo para a classificação de FA em comparação com características puramente morfológicas, o que será quantificado através de métodos de seleção de características como o RFE.

2. Investigar se abordagens de aprendizado profundo alcançarão uma Área Sob a Curva ROC (AUC) significativamente superior à da abordagem clássica de aprendizado de máquina, quando ambas são treinadas e avaliadas sob as mesmas condições de dados
3. Investigar se modelo final, após otimização e conversão para um formato embarcado (TFLite), manterá sua alta performance enquanto atinge um tamanho (em kilo bytes) e uma latência de inferência (em milisegundos) compatíveis com a implementação em um microcontrolador de baixo custo.

Para manter o estudo controlado, optou-se por utilizar dados sintéticos de alta fidelidade e inicialmente sem a presença de artefato de movimentos. O objetivo desta abordagem é, por tanto, estabelecer uma referência de performance dos algoritmos a fim de validar a capacidade dos algoritmos de detectar a presença de FA a partir de um sinal fisiologicamente puro. A investigação da robustez desses modelos a ruídos e artefatos do mundo real é definida como uma etapa subsequente e um trabalho futuro.

2 FUNDAMENTAÇÃO TEÓRICA


2.1 O CICLO CARDÍACO E A AFERIÇÃO DOS SINAIS ELÉTRICOS

2.1.1 Eletrocardiograma

Para um melhor entendimento da saúde cardiovascular de um indivíduo, o exame mais comumente utilizado pelos médicos é o eletrocardiograma, o qual consiste na leitura dos sinais elétricos gerados durante o ciclo cardíaco a fim de gerar as contrações das câmaras cardíacas. Esta leitura é possível ao se posicionar eletrodos em diversas partes da pele do paciente, como pode ser visto uma referência para um ECG com 12 derivações na Figura 2.1. Como as derivações possibilitam o monitoramento do coração por diversos ângulos, cada parte do órgão é coberto por alguns eletrodos, por exemplo a parede anterior utiliza os resultados de V1 a V4.

O resultado do ECG, então, é um conjunto de ondas e intervalos, os quais representam individualmente um ângulo do coração durante o ciclo cardíaco, como pode ser visto na Figura 2.2.


Figura 2.1 – Posicionamento de ECG de 12 derivações (UNIVERSITY OF ROCHESTER MEDICAL CENTER ROCHESTER, 2024)



Como o exame monitora o ciclo cardíaco, o sinal gerado possui diferentes estágios, os quais possibilitam a verificação de diferentes etapas do funcionamento do órgão. A Figura 2.3, demonstra a decomposição de um sinal medido em que a onda P, por exemplo, indica a despolarização atrial, enquanto o complexo QRS representa a despolarização ventricular. O intervalo QT é uma medida do tempo entre a despolarização e a repolarização ventricular, e sua duração pode fornecer informações sobre a função elétrica do coração.

A interpretação do ECG requer habilidades específicas e conhecimento deta-

Figura 2.2 – Sinais capturados por ECG com 12 derivações (JENKINS; GERRED, 2017)




lhado da fisiologia cardíaca. Os médicos analisam a forma, a amplitude e a duração das ondas e intervalos no traçado para diagnosticar uma ampla variedade de condições cardíacas. Por exemplo, uma elevação do segmento ST pode indicar um infarto agudo do miocárdio, enquanto uma arritmia pode ser identificada por alterações nos padrões de ondas.

2.1.2 Fotopletismografia

Outro tipo de sensoriamento muito utilizado é o fotopletismografia, a qual é uma técnica não invasiva de baixo custo amplamente utilizada para monitorar as variações no volume de sangue em vasos sanguíneos periféricos, como os dedos das mãos ou dos pés. Esta técnica utiliza basicamente uma fonte luminosa e um fotodetector na superfície da pele, combinados de tal maneira de que quando a fonte luminosa emite luz, os vasos sanguíneos a refletem de acordo com o volume de sangue e o fotodetector adquire a luz refletida. Logo, quando o coração bombeia sangue para os tecidos, há uma variação no volume de sangue circulando pelos vasos sanguíneos, neste caso os aumentando e, assim, fazendo com que a absorção e reflexão da luz pela hemoglobina varie. Essas variações na absorção de luz são capturadas pelo fotodetector e convertidas em um sinal elétrico. Este sinal, então, é processado para fornecer informações sobre a frequência cardíaca, a variação desta, a pressão arterial e outras medidas fisiológicas. (CASTANEDA et al., 2018)

A PPG já é amplamente utilizada na medicina para monitoramento contínuo

Figura 2.3 – Ciclo Cardíaco (AZIZ; AHMED; ALOUINI, 2021)

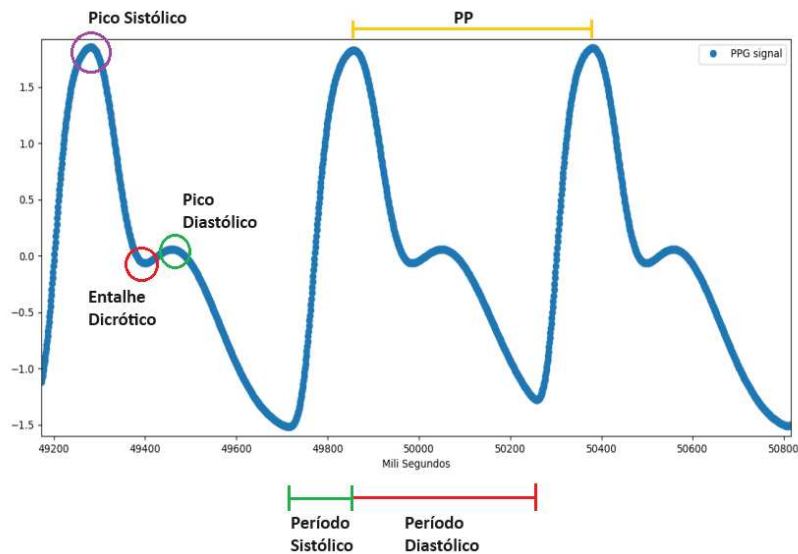


de pacientes em unidades de terapia intensiva, para a avaliação da função vascular em pacientes com doenças cardiovasculares e a avaliação do fluxo sanguíneo periférico em pacientes com condições como doença arterial periférica e diabetes. Agora vem sendo utilizada em dispositivos como relógios inteligentes para monitoramento cardíaco contínuo.

O sinal gerado e lido é capaz de representar algumas características do funcionamento do coração como pode ser visto na Figura 2.4. O período sistólico consiste no momento em que o coração está contraindo, tendo pico de pressão no chamado pico sistólico. Logo após esse período, encontra-se o entalhe dicrótico, o qual é universalmente utilizado para determinar o fim do período sistólico. Ao fim deste, inicia-se o período de relaxamento da musculatura cardíaca, período diastólico, o qual possui seu maior ponto de pressão no pico diastólico até que culmina no vale. (GAMRAH et al., 2013)

Deve-se perceber que o sinal do PPG reflete batimentos cardíacos, assim como pode também refletir outras grandezas físicas e comportamentos do coração, como por exemplo, pode-se identificar arritmias, caso perceba-se que o bombeamento não segue um ritmo sinusal, como também pode-se identificar o ritmo respiratório e entre outros.

Figura 2.4 – Ciclo Cardíaco através de PPG



Tipo	Características
FA Paroxística	Tem fim em 1 semana espontaneamente ou com intervenção médica. Episódios podem acontecer com certa frequência.
FA Persistente	FA com persistência maior que 1 semana.
FA Persistente de longa duração	FA persistente por mais de 1 ano.
FA Permanente	Termo utilizado quando paciente e junta médica decidem parar tratamentos para retornar o coração a um ritmo sinusal.

Tabela 2.1 – Tipos de FA e suas características (CAMM et al., 2010)

2.1.3 Arritmia Cardíaca e Fibrilação Atrial

O coração tem seu movimento regulado normalmente em um ritmo sinusal em que se mantém praticamente constantes a duração dos ciclos e seus picos, sem mudanças abruptas, no entanto, o coração de um indivíduo pode se comportar de maneira arritmica, apresentando algum grau de irregularidade, podendo acontecer de maneira espontânea e passageira, como também de maneira crônica, evidenciando, assim, uma doença. Dentre as formas de arritmia, uma das mais perigosas e ocorrentes é a fibrilação atrial, à qual acomete cerca de 1-2% da população em geral com estimativa para dobrar em 50 anos. (CAMM et al., 2010) A FA pode ainda ser dividida em algumas características, como pode ser visto na Tabela 2.1

A FA ocorre quando anormalidades estruturais e/ou eletrofisiológicas alteram o

PPG	ECG
Pico Sistólico	Pico R
Vale Diastólico	Pico P
Período Sistólico	Intervalo PR
Intervalo Pico-a-Pico	Intervalo RR
Período Diastólico	Intervalo RP

Tabela 2.2 – Correlação PPG e ECG

tecido atrial, promovendo a formação e/ou propagação de impulsos anormais. Essas anormalidades são causadas por diversos mecanismos fisiopatológicos, de modo que a FA representa um fenótipo final comum para múltiplas vias e mecanismos de doenças que ainda não são completamente compreendidos.

2.1.4 Relações entre ECG e PPG

Para a detecção de arritmia cardíaca, pode-se realizar a análise da Variabilidade da Frequência Cardíaca (VFC), a qual se baseia na análise dos intervalos temporais entre batimentos cardíacos consecutivos. Tradicionalmente, essa análise é realizada utilizando o ECG, onde cada onda R representa a despolarização do miocárdio ventricular. No entanto, teoricamente, qualquer evento específico no ciclo cardíaco poderia ser utilizado para gerar um registro sequencial de batimentos cardíacos. (PANDA; PINISETTY; ROOP, 2022)

Ou seja, apesar do ECG estar presente nos mais diversos ambientes e ser o método de monitoramento cardíaco mais aceito, outros métodos podem ser utilizados para este fim, desde que o sinal gerado tenha características com alta correlação com alguma característica derivada de um sinal originado de um ECG. Diversas propostas de correlação podem ser feitas como proposto em (PANDA; PINISETTY; ROOP, 2022) para PPG, a qual pode ser vista na Tabela 2.2 e reforçando a substituição de um método pelo outro.

2.2 APRENDIZADO DE MÁQUINA

Dentre diversas áreas de atuação de engenharia, médica, análise de dados entre outras, inúmeras vezes se faz necessário o reconhecimento de padrões ou até mesmo a tomada de decisões de maneira automatizada para resolução de problemas, visando diminuir o índice de falha humana ou acelerar processos. Como principais soluções surgiram diversos modelos e técnicas de inteligência artificial. Dentre elas tem-se o aprendizado de máquina, o qual vem impulsionando diversos avanços tecnológicos baseando-se em uma variedade de conceitos e técnicas. Estes incluem a

geração e preparação de dados, a seleção de características relevantes, a aplicação de algoritmos de aprendizado apropriados e a avaliação criteriosa dos modelos resultantes. O aprendizado de máquina busca capacitar os sistemas computacionais para aprenderem de maneira autônoma a partir dos dados disponíveis, permitindo-lhes fazer previsões precisas, identificar tendências ocultas e adaptar seu comportamento com base nesse aprendizado.

Muitas vezes o processo de desenvolvimento segue algumas etapas comuns como a preparação de dados, a qual é essencial para garantir a qualidade e consistência dos dados utilizados no treinamento do modelo, o que impacta diretamente na precisão e confiabilidade das previsões ou decisões geradas. Além disso, pode-se escolher trabalhar com abordagens clássicas de aprendizado de máquina ou até mesmo de aprendizado profundo.

Na abordagem clássica, diversos dados são gerados ou coletados e, após serem pré-processados, ocorre a extração e seleção de características, as quais são de suma importância para identificar características relevantes para descrever o comportamento físico em que está se tentando criar um modelo para gerar previsões. Em seguida é realizada a escolha do modelo a ser treinado e o seu treinamento utilizando os dados baseados nas características escolhidas. Essa é uma etapa muito importante, pois diferentes problemas possuem diferentes estratégias que podem oferecer um melhor desempenho para o problema em questão. Após o treinamento, é feita a análise da performance das previsões do modelo para um conjunto de dados de validação e com base nos resultados encontrados, ajustes e correções são feitos buscando melhorar a performance do modelo.

Já no aprendizado profundo, o próprio modelo identifica as características que melhor descrevem o sinal em questão, não necessitando da etapa de extração e seleção manual de características, sendo que essa operação ocorre enquanto se treina o modelo, não sendo uma etapa extra. Esses conceitos serão aprofundados nas subseções a seguir. Comum as duas estratégias, tem-se por fim a implantação e monitoramento em produção do modelo.

2.2.1 Abordagem Clássica: Engenharia de Características Manuais

A abordagem clássica de aprendizado de máquina para a classificação de sinais fisiológicos segue um passo a passo bem estabelecido, que consiste em duas etapas principais: primeiro, a extração e seleção de um conjunto de características quantificáveis do sinal, já o segundo, o treinamento de um modelo classificador com base nessas características.

Após a geração dos dados, é necessário limitar o conjunto de variáveis que será utilizado pelo modelo a fim de se evitar que variáveis correlacionadas sejam utilizadas ao mesmo tempo sem necessidade ou até características sem relevância

para o fenômeno sejam utilizadas. Para isso, existem duas estratégias principais:

2.2.1.1 Extração de Características

A extração de características pode se dar através de algoritmos como a Análise de Componentes Principais (PCA) ou a Análise Discriminante Linear (LDA), os quais transformam as características originais reduzindo a dimensão do espaço, criando novas características que são combinações das originais. O objetivo é maximizar a variância (PCA) ou a separabilidade entre classes (LDA)(JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015), (THARWAT et al., 2017). Além desses métodos, pode-se escolher utilizar métodos de extração manual, como por exemplo pode-se calcular e analisar características do sinal bruto, do domínio da frequência do sinal normalizado, da velocidade e da aceleração do sinal, morfológicas e variabilidade do pulso. Cada uma destas categorias oferece uma perspectiva diferente sobre o sinal fisiológico e ao combiná-las, aumenta-se a probabilidade de conseguir encontrar algo que descreva o estado cardiovascular, assim, possibilitando a detecção de FA.

- Análise do Sinal Bruto (Domínio do Tempo) Esta é a categoria mais fundamental de análise, visto que as características extraídas descrevem propriedades mais básicas como média, mediana e desvio padrão, as quais fornecem uma visão geral da distribuição do sinal e tanto suas componentes AC como DC (ELGENDI, 2012). Outras métricas, como a assimetria e a curtose, são úteis também para a avaliação da qualidade do sinal, pois ruídos e artefatos de movimento tendem a alterar significativamente estas estatísticas (SOLTANE et al., 2022).
- Análise no Domínio da Frequência Após transformar o sinal do domínio do tempo para o domínio da frequência, através da Transformada Rápida de Fourier (FFT), é feita a análise do seu conteúdo espectral. Características como a frequência dominante e a sua amplitude identificam o ritmo fundamental do sinal, que em condições normais corresponde à frequência de pulso. Outras métricas, como o centroide espectral e a largura de banda espectral, ajudam a quantificar possíveis anomalias no sinal, visto que um sinal com ritmo sinusoidal, sem artefatos de movimento e ruído, terá a maior parte da sua distribuição de frequência ao entorno da componente DC do sinal, enquanto que um sinal mais ruidoso terá componentes em outras frequências(SEMMLow, 2018).
- Análise da Velocidade e Aceleração do Sinal (Derivadas) O sinal PPG representa a variação do volume de sangue, e suas derivadas fornecem informações cruciais sobre a dinâmica do fluxo sanguíneo.
 - Velocidade (VPG): A primeira derivada do sinal PPG, conhecida como Ple-tismograma de Velocidade (VPG), representa a taxa de variação do volume

sanguíneo. A inclusão desta característica é justificada por sua capacidade de destacar características morfológicas do sinal original, como a capacidade de contração do músculo cardíaco e a velocidade com que o sangue é bombeado para fora do coração (SUBOH et al., 2022). Como ela descreve a taxa de variação, picos, vales e o entalhe dicrótico tornam-se mais proeminentes. Isso fornece ao modelo uma visão explícita da dinâmica do fluxo sanguíneo, enriquecendo a representação do sinal e auxiliando na aprendizagem de padrões que podem ser sutis no sinal PPG bruto.

- Aceleração (APG): A segunda derivada, o Pletismograma de Aceleração (APG), mede a aceleração do fluxo sanguíneo. Por ser sensível a mudanças na curvatura da onda de PPG, é um indicador valioso da rigidez arterial e do envelhecimento vascular, no entanto, por ser a segunda derivada, tem risco maior de destacar ruídos presentes no sinal (AHN, 2015).
- Análise Morfológica Já esta análise tem como principal objetivo caracterizar o formato de cada pulso individual no sinal PPG. Características como a amplitude e a largura do pulso contêm informações fisiológicas importantes sobre processo de fornecimento de sangue para os tecidos do corpo e propriedades vasculares. A análise da variabilidade destas características de um pulso para o outro também pode ser um forte indicador de arritmias (ALLEN, 2007).
- Análise da Variabilidade do Intervalo Pulso-a-Pulso (PPI) Análoga à VFC, esta é a categoria de características que apresenta maior potencial para auxiliar na detecção de arritmias, pois como a FA é caracterizada por irregularidades caóticas nos batimentos cardíacos, o tempo decorrido entre pulsos consecutivos sofrerá uma alteração quando há a presença de tal condição. Métricas no domínio do tempo, como o desvio padrão dos PPIs e o RMSSD, quantificam esta variabilidade (SHAFFER; GINSBERG, 2017). Métricas não-lineares, como a Entropia Amostral, medem a complexidade e regularidade da série temporal de intervalos pulso-a-pulso (RICHMAN; MOORMAN, 2000). Finalmente, a análise no domínio da frequência dos intervalos PPI (bandas de baixa e alta frequência) fornece informações sobre a modulação do sistema nervoso autônomo (Task Force of The European Society of Cardiology and The North American Society of Pacing and Electrophysiology, 1996).

2.2.1.2 Métodos de Seleção de Características

Diferentemente da extração, a seleção de características não cria novas características, mas sim seleciona o subconjunto mais relevante das características extraídas para descrever o fenômeno físico. O objetivo é eliminar redundâncias e ruídos, resultando em modelos mais simples, rápidos e, muitas vezes, com maior poder de

generalização. Os métodos de seleção podem ser classificados em filtros, *wrappers* e embarcados, sendo que este estudo focou em ANOVA F-Test e Informação Mútua para o tipo filtro e Eliminação Recursiva de Característica para o *wrapper*.

- ANOVA F-Test Ao comparar a média da variância da característica entre cada classe, a Análise de Variância (ANOVA) busca determinar se a característica em questão é estatisticamente significativa sendo capaz de gerar a variação final no sinal para cada classe. Para ser feita tal análise, é realizado o chamado F-Test, o qual consiste no cálculo através da equação 2.1 a qual descreve a razão entre a variância entre as classes e a variância dentro das classes.

$$F = \frac{\text{variância entre as classes}}{\text{variância dentro das classes}} \quad (2.1)$$

Caso uma característica tenha uma variação baixa entre as duas classes, mantendo praticamente o mesmo valor de média, pode-se afirmar pelo ANOVA F-Test de que essa característica não precisa ser considerada no treinamento do modelo. Embora o ANOVA F-Test não tenha como premissa estatística formal a linearidade das características, é um método que tem resultados importantes para identificar características que melhor explicam a separação entre as classes.

O ANOVA F-Test é um teste do tipo univariado, logo não analisa a interação entre características, o que é na verdade uma deficiência da abordagem, visto que se duas características não explicam muito bem a separação entre classes, elas terão um valor F baixo e não serão consideradas no treinamento. Porém, se a interação entre elas é forte, elas deveriam ou poderiam ser consideradas no treinamento, mas como essa interação não é analisada, a informação será perdida. Apesar dos pontos mencionados, o ANOVA F-Test é um método estatístico computacionalmente eficiente e permite que diferentes análises sejam feitas.

O algoritmo faz a seleção de uma característica ao comparar as magnitudes de F, onde os maiores valores são selecionados. Uma elevada razão F indica que uma determinada característica explica muito bem a diferença entre as classes FA e RS, explicando muito melhor do que explica a variação dentro de cada classe. (JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015)

- Informação Mútua A Informação Mútua (MI) mede a dependência entre duas variáveis aleatórias. No contexto da seleção de características, ela quantifica a redução na incerteza sobre a classe (FA ou RS) ao se observar o valor de uma determinada característica. De tal maneira que mede quão bem uma característica descreve o comportamento físico.

A MI entre uma característica X e a classe Y é definida como:

$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (2.2)$$

Onde $p(x, y)$ é a distribuição de probabilidade conjunta de X e Y , e $p(x)$ e $p(y)$ são as distribuições de probabilidade marginais. Diferente do ANOVA F-Test, o MI tem capacidade de capturar relações não-lineares entre a característica e a classe. Quando apresenta valor igual a zero, está indicando que as variáveis são independentes, enquanto que um valor alto indica um forte grau de dependência. (VERGARA; ESTEVEZ, 2014)

- **Eliminação Recursiva de Característica** Como explicado anteriormente, o ANOVA F-Test e a Informação Mútua são técnicas que avaliam as características isoladamente e diferentemente destas, a Eliminação Recursiva de Característica (RFE) é um método de seleção multivariado do tipo envelope. (GUYON et al., 2002) Neste contexto, a técnica avalia a contribuição das características através também das interações de uma com as outras. O processo de avaliação se dá através de um modelo de aprendizado de máquina externo, sendo este iterativo e retroativo. O fluxo do processo é descrito abaixo:

1. No caso deste trabalho, um classificador *Random Forest* foi treinado com o conjunto inteiro de características. Este classificador calcula e classifica a relevância de cada característica para o fenômeno físico através da métrica de redução média de impureza baseada no critério Gini, o qual mede a probabilidade de uma classificação incorreta de uma amostra ser feita, caso a classificação fosse baseada apenas na distribuição de classes daquele subconjunto. O algoritmo seleciona as divisões que mais reduzem a probabilidade de erro nos nós resultantes.
2. A característica classificada com a menor relevância é removida.
3. O processo se repete recursivamente, utilizando cada vez o conjunto de características reduzido, até que o número definido de características como método de parada seja alcançado.

A premissa por trás deste método é de que ao avaliar as característica justamente em um modelo preditivo, buscando maximizar a performance deste a cada interação com as características disponíveis, tende-se a selecionar um subconjunto de características que combinados alcançam o objetivo de maximizar a performance do classificador, contudo isto vem com a implicação de se ter um custo computacional mais elevado do que métodos de filtro, como o ANOVA F-Test e MI, visto que deve-se treinar o modelo repetidamente.

2.2.1.3 Modelos Classificadores Tabulares

Uma vez que um subconjunto de características é selecionado e validado, ele é utilizado como entrada para treinar um modelo classificador. Para estabelecer uma referência robusta, foram investigados dois tipos de modelos com paradigmas de aprendizado distintos: uma rede neural artificial (MLP) e um modelo de *ensemble* (*Random Forest*).

2.2.1.3.1 Perceptron Multicamadas (MLP)

O Perceptron Multicamadas (MLP) é uma arquitetura de rede neural artificial de propagação direta. Sua estrutura consiste em uma camada de entrada, no caso de aprendizado de máquina somente uma camada oculta e uma camada de saída. Cada camada é composta por múltiplos neurônios e cada neurônio em uma camada é totalmente conectado a todos os neurônios da camada seguinte, formando uma rede densa.

A MLP se caracteriza principalmente pela sua capacidade de aprender relações não-lineares complexas no conjunto de dados através de duas operações principais, sendo elas uma transformação linear, a qual é uma soma ponderada de todas as entradas mais um viés. Esta operação é então seguida por uma função de ativação não-linear, como a Unidade Linear Retificada (ReLU), a qual a não-linearidade normalmente presente em padrões complexos (GOODFELLOW; BENGIO; COURVILLE, 2016a).

O treinamento do MLP é realizado através do algoritmo de retropropagação, onde o erro entre a previsão do modelo e o valor real é calculado e propagado de volta através da rede, ajustando iterativamente os pesos de cada conexão visando minimizar uma função de perda, como, por exemplo, a entropia cruzada binária no caso de problemas de classificação.

O Teorema da Aproximação Universal afirma que uma MLP com uma única camada oculta e um número suficiente de neurônios pode aproximar qualquer função contínua com um grau arbitrário de precisão (HORNIK; STINCHCOMBE; WHITE, 1989). Em virtude dessa capacidade, três modelos MLP foram implementados (cada um utilizando um método de seleção de características) como primeira abordagem deste trabalho para servir como uma potencial referência para comparação com métodos mais elaborados.

Uma arquitetura muito comum para modelos de MLP consiste na presença de camadas densas com funções de ativação ReLU, regularização L2 e *dropout* para prevenir sobreajuste.

A Unidade Linear Retificada (ReLU) é uma função de ativação muito utilizada em redes neurais profundas justamente pela simplicidade e eficiência computacional que entrega. Ela se comporta de tal maneira de que o valor de entrada é utilizado caso

ele seja positivo, caso o contrário, será considerado zero, o que pode ser visto na Eq. 2.3

$$f(x) = \max(0, x) \quad (2.3)$$

Como não satura para valores positivos e ainda zera valores negativos, esta estratégia permite que se reduza o problema do desaparecimento do gradiente ao fazer que para os valores positivos a derivada da função ReLU seja constante e igual à 1. Com isso, o gradiente do erro não é atenuado durante a retropropagação deste e garante que mesmo as camadas iniciais da rede sejam atualizadas com pesos significativos. Como o valor de erro se mantém significativo, os ajustes são feitos mais rapidamente, possibilitando uma convergência mais rápida. (GOODFELLOW; BENGIO; COURVILLE, 2016b).

Após a camada ReLU, tem-se o decaimento de peso, também conhecido como regularização L2 e é uma técnica, que visa reduzir o problema de sobreajuste, ou seja, em que o modelo é enviesado ao conjunto de dados de treinamento. Esta técnica penaliza a complexidade do modelo ao adicionar um termo de penalidade à função de perda da rede, o qual corresponde à Eq. 2.4

$$L'(w) = L(w) + \frac{\lambda}{2m} \sum_{i=1}^n w_i^2 \quad (2.4)$$

Onde $L(w)$ é a função de perda original, m é o número de amostras no conjunto de treinamento e λ controla a intensidade da penalização (BISHOP, 2006).

Ao minimizar função de perda original, o modelo é incentivado a manter seus pesos com magnitudes menores, visto que pesos grandes podem indicar um modelo mais complexo que potencialmente se ajuste ao ruído dos dados de treinamento. Portanto, a regularização L2 força a rede a aprender padrões mais simples e gerais, melhorando sua capacidade de generalização para dados não vistos (GOODFELLOW; BENGIO; COURVILLE, 2016b).

Por fim, tem-se a camada de *dropout*, a qual é uma proposta especificamente para redes neurais (HINTON et al., 2012), esta técnica de regularização opera removendo do treinamento aleatoriamente uma fração de neurônios do treinamento a cada interação. O objetivo é impedir que os neurônios se tornem co-dependentes, o que exige que a rede aprenda representações mais robustas. Como a remoção dos neurônios só acontece na etapa de treinamento, quando migra-se para a validação e real implementação, os pesos devem ser escalonados justamente para compensar o fato de que agora todos os neurônios estão ativos.

Essa abordagem pode ser vista como um método de *ensemble* implícito, onde múltiplas arquiteturas de rede são treinadas e combinadas em um único modelo, resultando em uma melhora significativa na generalização (HINTON et al., 2012; SRIVASTAVA et al., 2014a).

2.2.1.3.2 *Random Forest*

Este modelo, o qual foi introduzido por (BREIMAN, 2001), é um método de aprendizado de máquina do tipo *ensemble* e se dá construindo uma infinidade de árvores de decisão durante a etapa de treinamento. As árvores de decisão se caracterizam por três pontos principais, sendo eles a raiz, os nós de decisão e as folhas. A raiz é o ponto inicial em que todo o conjunto de dados está presente, a partir dele diferentes nós vão sendo criados e cada um deles é responsável por pequenas decisões, até que se chegue na decisão final para cada árvore, as folhas. O *Random Forest* se caracteriza então como os processos de randomização para a construção de cada árvore e no sistema de votação majoritário de cada uma das árvores presentes na floresta para se concluir a classificação.

O processo de randomização para garantir a diversidade e a não-correlação entre as árvores de decisão na floresta, emprega duas técnicas principais:

- *Bootstrap Aggregating (Bagging)*: Cada árvore é treinada através de um subconjunto de dados, o qual foi amostrado aleatoriamente, ou seja, cada árvore é treinada um pouco diferente do que outra, possibilitando que cada árvore aprenda sob uma ótica diferente de uma outra árvore, reduzindo, assim, a variância do modelo, combatendo sobreajustes.
- *Seleção Aleatória de Atributos (Feature Bagging)*: Durante o processo de construção da árvore, na ramificação a partir de cada nó, apenas um subconjunto do total de características selecionadas é considerado. O subconjunto é escolhido de maneira aleatória e acaba por impedir que características muito fortes dominem a estrutura de todas as árvores, de tal maneira que exige que o modelo seja mais robusto ao se ter uma maior variedade de atributos sendo considerados em cada árvore e descorrelacionando as árvores entre si.

A previsão para uma nova amostra é feita passando-a por todas as árvores do *ensemble* e agregando os resultados através de uma votação majoritária. Por agregar as previsões de muitas árvores descorrelacionadas, o *Random Forest* tem uma alta resistência ao sobreajuste e a capacidade de lidar eficientemente com conjuntos de dados de alta dimensionalidade e com interações complexas entre as características. Devido a essas qualidades, este método é considerado uma das referências de mais alta performance para problemas de classificação com dados tabulares. Por essas características, o *Random Forest* também foi analisado para servir como uma potencial referência para comparação com métodos mais elaborados.

2.2.2 Abordagem com Aprendizado Profundo

Diferentemente da abordagem clássica, a qual depende da etapa inicial de engenharia e seleção de características, a modelagem com aprendizado profundo faz isso de maneira intrínseca, visto que nessa arquitetura o modelo aprende as representações e os padrões discriminatórios diretamente do sinal bruto ou minimamente processado, eliminando inclusive a necessidade de conhecimento aprofundado sobre o problema em questão para a definição de características. Este processo é conhecido como aprendizagem de representação e é uma das vantagens mais significativas das arquiteturas de redes neurais profundas (GOODFELLOW; BENGIO; COURVILLE, 2016a). Em outras palavras, assume-se que uma rede neural profunda, ao ser exposta a uma grande quantidade de dados, pode descobrir padrões mais complexos e/ou de maior poder preditivo do que aqueles definidos manualmente por um especialista humano.

2.2.2.1 Redes Neurais Convolucionais (CNN) para Séries Temporais

A CNN é a principal arquitetura para aprendizado de características de dados com estrutura de grade, como séries temporais. Neste caso, as camadas convolucionais atuam como filtros especializados que aprendem a identificar padrões locais e hierárquicos, o que por si só acaba por extrair automaticamente as características mais relevantes. O algoritmo se baseia em operações de convolução, onde que um filtro faz a convolução sobre a sequência de entrada e como o filtro é um vetor de pesos treináveis, o resultado da convolução é um produto escalar em cada posição

Cada filtro aprende a produzir uma alta ativação quando encontra um padrão específico no sinal, como a subida sistólica, o entalhe dicrótico ou uma anomalia na forma da onda. As primeiras camadas da rede aprendem a detectar padrões simples e de baixo nível. As camadas subsequentes combinam esses padrões para formar representações hierárquicas e cada vez mais complexas (KIRANYAZ et al., 2021).

2.2.2.2 *Long-Short Term Memory* (LSTM) para Análise Sequencial

Esta é um tipo de Rede Neural Recorrente (RNN) e é projetada justamente para superar o problema do desaparecimento do gradiente ao longo do tempo gerenciando o fluxo de informação temporal. Esta abordagem permite que o modelo aprenda e mantenha as informações por longos períodos de tempo, o qual é importante para a análise de sinais fisiológicos (HOCHREITER; SCHMIDHUBER, 1997). Esta capacidade é alcançada pela arquitetura interna do modelo com uma célula de memória e mais três portões, os quais nada mais são do que pequenas redes neurais, que aprendem sobre padrões de longo e curto prazo (GRAVES, 2012). Os três portões são descritos abaixo:

- **Portão de Esquecimento** A fim de decidir qual informação da célula de memória será descartada, este portão analisa a entrada atual e o estado oculto anterior (memória), influenciando principalmente o curto prazo. Neste trabalho, este portão tem como objetivo permitir que a rede não utilize informações de um ciclo cardíaco anterior que não são relevantes para o ciclo cardíaco atual, sendo responsável pela gestão do estado de memória de longo prazo da célula, permitindo que a rede se adapte a novas sequências e descarte contextos passados que não são mais pertinentes para a análise atual.
- **Portão de Entrada** Já este portão determina quais novas características ou informações devem ser armazenadas na célula de memória, identificando padrões que são tidos como relevantes pelas camadas convolucionais.
- **Portão de Saída** Por fim, este portão determina qual será a parte da célula de memória utilizada para gerar a saída da camada, ou seja, com base no estado atual da célula, uma versão filtrada da memória é utilizada para representar as informações mais relevantes da sequência.

A capacidade da LSTM de analisar os sinais do PPG e identificar desvios no padrão temporal é de grande importância, visto que, desta maneira, analisa-se ativamente a ordem e a relação entre as características não somente sob um ponto de vista estatístico, mas também com o comportamento físico (CHUNG et al., 2014).

2.2.2.3 Arquiteturas Híbridas (CNN-LSTM)

A estratégia explorada por essa arquitetura consiste em garantir que a CNN atue como extrator de características automáticas, aprendendo e identificando padrões morfológicos variados na forma de onda do sinal, transformando a longa sequência de entrada em uma sequência mais curta e rica em informação. Posteriormente essa sequência de características extraídas por ela é direcionada para a camada LSTM, a qual é então a responsável por analisar e aprender sobre as características ao longo prazo dentro do seu contexto temporal (PETMEZAS et al., 2021), ou seja, esta arquitetura se beneficia tanto da capacidade de extração de padrões espaciais da CNN quanto da capacidade de modelagem de memória da LSTM.

2.2.3 Técnicas de Treinamento e Otimização

Para garantir um treinamento robusto dos modelos de aprendizado profundo e maximizar sua capacidade de generalização para dados não vistos, algumas técnicas podem ser utilizadas, como o tratamento de dados desbalanceados, otimizador Adam, otimização da taxa de aprendizado, entre outros.

2.2.3.1 Tratamento de Dados Desbalanceados

Em problemas de diagnóstico médico, é comum que a classe que representa a ausência de uma patologia seja muito mais frequente do que a classe que representa a patologia, levando naturalmente a um desequilíbrio de classes. Isso pode enviesar o modelo a prever sempre a classe majoritária, por isso se faz de suma importância a correta manipulação dos dados antes que se comece o treinamento. Para mitigar este problema, foram exploradas duas técnicas:

- **Balanceamento de Pesos de Classe:** Modifica a função de perda durante o treinamento. Os erros cometidos na classificação de amostras da classe minoritária (FA) recebem uma penalidade maior, forçando o modelo a corrigir mais agressivamente os pesos para convergir na redução da função de perda. Neste caso, o peso é geralmente o inverso da frequência da classe (GOODFELLOW; BENGIO; COURVILLE, 2016a).
- **SMOTE (*Synthetic Minority Over-sampling Technique*):** Esta é uma técnica de sobreamostragem que tem como objetivo balancear a distribuição das classes através da criação de novas amostras sintéticas da classe minoritária. Esta técnica não simplesmente replica amostras existentes, mas na verdade o algoritmo seleciona aleatoriamente uma amostra da classe em questão entre o valor existente e um dos seus vizinhos mais próximos (CHAWLA et al., 2002). O SMOTE foi, portanto, investigado na metodologia como uma técnica para mitigar o desequilíbrio de classes observado no conjunto de dados, buscando melhorar a performance do modelo na classe minoritária (FA).

2.2.3.2 Otimizador Adam

O otimizador chamado Estimativa Adaptativa de Momentos (Otimizador Adam), acaba sendo a escolha padrão na maioria das aplicações de aprendizado profundo e foi utilizado para ajustar os pesos durante o treinamento da rede. Ele foi escolhido pois ele é um método de descida gradiente, possuindo, assim, taxas de aprendizado adaptativas para cada parâmetro, ou seja, parâmetros que tem um erro muito grande, recebem de uma grande correção, enquanto que parâmetros com erro pequeno, recebem uma pequena correção. Este método armazena as médias móveis exponenciais dos gradientes passados e gradientes quadrados passados (KINGMA; BA, 2014).

2.2.3.3 Prevenção de Sobreajuste e Otimização da Taxa de Aprendizado

Para evitar que o modelo se especialize demais nos dados de treino e perca sua capacidade de generalização, foram utilizadas as seguintes técnicas de regularização e otimização:

- *dropout*, as quais foram inseridas antes e depois da camada densa intermediária. Durante o treinamento, elas desativam aleatoriamente uma parcela dos neurônios, o que acaba por forçar a rede a aprender representações mais robustas, aumentando o poder de generalização para dados não vistos (SRIVASTAVA et al., 2014b).
- Parada Antecipada: Através do monitoramento de alguma métrica de performance no conjunto de validação (neste trabalho, a AUC de validação), o treinamento é interrompido automaticamente quando essa métrica para de melhorar por um número definido de épocas (paciência), salvando o modelo em seu melhor estado de generalização.
- ReduceLROnPlateau: Também age através de alguma métrica de validação, caso esta não melhore por um número definido de épocas, a taxa de aprendizado do otimizador é reduzida por um fator. Isso permite que o modelo faça ajustes mais finos nos pesos quando se aproxima de um ponto ótimo na função de perda.

3 ESTADO DA ARTE

Como mencionado em (JANUARY et al., 2014) e (CAMM et al., 2010) o método padrão para detecção de FA seria o ECG, o qual por ser um exame que necessita de vários eletrodos conectados ao paciente, exige que seja realizado em ambientes hospitalares ou clínicos. Por outro lado, como a FA necessita de no mínimo 30 segundos para ser confirmada e ela possui muitas vezes caráter paroxístico, há poucas chances desta ser detectada em um procedimento pontual como o ECG. Outro fator negativo é que a utilização deste se dá de maneira reativa, ou seja, o diagnóstico se dá depois de o paciente já ter seu quadro clínico evoluindo para uma presença mais constante da FA a ponto de perceber que possa estar com algum problema de saúde. Caso o paciente pudesse monitorar seu coração ao longo de todos os dias, desde que usasse um relógio inteligente, esta detecção poderia ocorrer muito antes de o paciente até perceber que tem algum problema.

Devido à citada inviabilidade e desvantagem de se utilizar somente ECG para a detecção da FA, diversos estudos já foram realizados para o desenvolvimento de algoritmos e modelos para a detecção dessa condição utilizando PPG através de relógios inteligentes comerciais. Como por exemplo, em (VOISIN et al., 2018), dados de 81 pacientes foram coletados em um total de 4000 horas. O estudo se deu inicialmente separando dados em dois conjuntos, o primeiro com 29 pacientes com problemas de arritmia, os quais foram simultaneamente examinados utilizando ECG para serem usados como referência do modelo de aprendizado de máquina. O segundo conjunto de dados é baseado em dados coletados de 53 pacientes, os quais se autodeclararam como não tendo nenhum sintoma de arritmia e, portanto, não foram examinados com ECG em paralelo. Isto, no entanto, pode acarretar em medições de pacientes que possuem algum tipo de arritmia e por não saberem disso, ao se autodeclararem como sem arritmia, podem deteriorar a performance do modelo. Por fim, o modelo escolhido para a detecção de FA se baseia em uma rede neural convolucional de 50 camadas.

O estudo executado por (TISON et al., 2018) utiliza um modelo semi-supervisionado de 8 camadas, para isto, o estudo foi dividido em duas partes para o treinamento, o primeiro com coleta de dados de 9750 pessoas de maneira não supervisionada, entre as quais 347 tinham FA diagnosticada. A coleta se fez com uso de relógio inteligente e aplicativo comercial. Para validar tal etapa, algumas pessoas com somente FA foram examinadas com o modelo e ECG. A segunda etapa consistiu em utilizar o modelo gerado na 1ª etapa e agora treiná-lo de maneira supervisionada utilizando um aparelho comercial detector de FA, o qual consiste em um ECG de dois eletrodos. Neste estudo, não houve a análise de artefatos de movimento, visto que os dados foram coletados em pacientes em repouso. Pacientes com outros tipos de arritmia ou com uso de marcapasso foram excluídos do estudo.

O modelo desenvolvido por (ALIAMIRI; SHEN, 2018) consiste de dois modelos. Utilizando como entrada dados de um acelerômetro, o primeiro calcula a probabilidade da qualidade do sinal lido. Dependendo do resultado, os dados coletados pelo PPG são então utilizados pelo segundo modelo para a detecção de FA. A estratégia selecionada para treinamento é a supervisão, por isso medições com ECG são feitas em paralelo para se ter as anotações de fibrilação. O modelo para detecção de FA é um modelo híbrido de uma rede neural convolucional com uma rede neural recorrente. Os dados foram adquiridos em 19 pacientes e por possuírem mais dados de pacientes com FA do que com RS, os atributos foram compensados com ganhos, sendo que os de RS recebem um valor maior.

Enquanto os artigos citados até o momento fazem uso de poucas propriedades do sinal, como por exemplo intervalo RR (intervalo entre dois batimentos cardíacos) ou decompondo em diferentes *wavelets*, pode-se também utilizar outras propriedades estatísticas e matemáticas, como abordado por (FALLET et al., 2018). Nesta pesquisa, dezoito pacientes foram estudados durante a execução de ablações por cateter. Dados foram coletados por PPG e ECG. Além de utilizar um filtro FIR com janelamento de Hanning e cálculo do intervalo RR no pré-processamento, também foram calculadas características baseadas na forma de onda, como por exemplo comparativo da potência da frequência fundamental e primeira harmônica com a potência total, fase entre fundamental e primeira harmônica e entre outras. Também foram calculadas outras características com base no intervalo RR, como por exemplo a média deste, desvio padrão, maior raiz quadrada das diferenças quadráticas médias entre sucessivos intervalos RR e entre outras. Como no estudo realizado por (ALIAMIRI; SHEN, 2018), os dados que continham artefatos de movimento foram descartados. Por fim, o estudo desenvolveu um modelo baseado em um algoritmo de *Baggin* com *K-Fold* para validação com $k = 5$.

Porém nos últimos anos, algumas pesquisas começaram a utilizar arquiteturas de aprendizado profundo híbrido, as quais visam combinar os benefícios de diversos tipos de redes neurais para extrair o máximo de informação dos sinais cardíacos. Entre essas, pode-se ver em três artigos a presença de Redes Neurais Convolucionais (CNN) com Redes Neurais Recorrentes do tipo LSTM, a qual tem se destacado como o estado da arte para a classificação de sinais de ECG e PPG. No estudo desenvolvido por (ALAMATSAZ et al., 2024), alcançou-se uma acurácia superior a 98,24% com tal abordagem para a detecção de diferentes tipos de arritmia e em (PETMEZAS et al., 2021) a mesma arquitetura foi usada e atingiu-se sensibilidade acima de 97,87%. Abordando somente a análise do sinal PPG, (KUDO et al., 2023) desenvolveram um processo de treinamento completo utilizando arquiteturas aprendizado profundo para a detecção de FA, utilizando também uma CNN-LSTM, atingindo acurácia de 97% demonstrando a viabilidade e a alta performance da aplicação de modelos sequenci-

ais como a CNN-LSTM diretamente neste tipo de sinal. A escolha desta arquitetura como referência ótima nesta dissertação foi, portanto, diretamente fundamentada por esses estudos, com o objetivo de replicar e validar uma abordagem de ponta para a classificação de FA em um contexto de dados sintéticos, visando a implementação em um sistema embarcado.

Tabela 3.1 – Comparativo de Métodos e Resultados no Estado da Arte para Detecção de FA

Referência	Título do Trabalho	Método de ML/DL	Acurácia	Precisão	Sensibilidade	AUC
(VOISIN et al., 2018)	Ambulatory Atrial Fibrillation Monitoring...	Rede Neural Convolutacional (CNN) de 50 camadas	-	-	-	94,8%(85,5%)
(TISON et al., 2018)	Passive Detection of Atrial Fibrillation...	Rede Neural Convolutacional (CNN) semi-supervisionada	-	-	98%	97%
(ALIAMIRI; SHEN, 2018)	Deep learning based atrial fibrillation detection...	Modelo Híbrido (CNN + RNN)	98,19% -	-	-	99,67%
(FALLET et al., 2018)	Can one detect atrial fibrillation using a wrist-type...	Algoritmo de Bagging com features estatísticas	98,1%	-	99,7%	-
(ALAMATSAZ et al., 2024)	A lightweight hybrid CNN-LSTM explainable model...	Modelo Híbrido Leve (CNN-LSTM)	98,24%	-	68,6% -	-
(PETMEZAS et al., 2021)	Automated atrial fibrillation detection...	Modelo Híbrido (CNN-LSTM) com focal loss	-	-	97,87%	-
(KUDO et al., 2023)	A training pipeline of an arrhythmia classifier...	Pipeline de Deep Learning (incluindo CNN-LSTM)	87%	-	-	-

4 MATERIAIS E MÉTODOS

Neste capítulo, são detalhados os procedimentos metodológicos adotados para o desenvolvimento e a avaliação dos modelos de detecção de Fibrilação Atrial. A metodologia inicia com a geração dos dados sintéticos, seguida pela estratégia de divisão entre conjunto de dados de treinamento e validação. Logo após, as duas abordagens de modelagem investigadas são apresentadas. A primeira baseada em engenharia de características extraídas manualmente e que tiveram os resultados utilizados como referência e a segunda com aprendizagem de representação, ou seja, através dos dados brutos, aprender automaticamente representações informativas do sistema. Esta última abordagem visou superar os valores de referência definidos pelo primeiro método.

A metodologia adotada neste trabalho está sumarizada na Figura 4.1. O processo inicia-se com a geração de dados sintéticos controlados, passa pelo pré-processamento e balanceamento, bifurca-se nas abordagens de aprendizado clássico e profundo, e culmina na otimização para implementação no sistema embarcado.

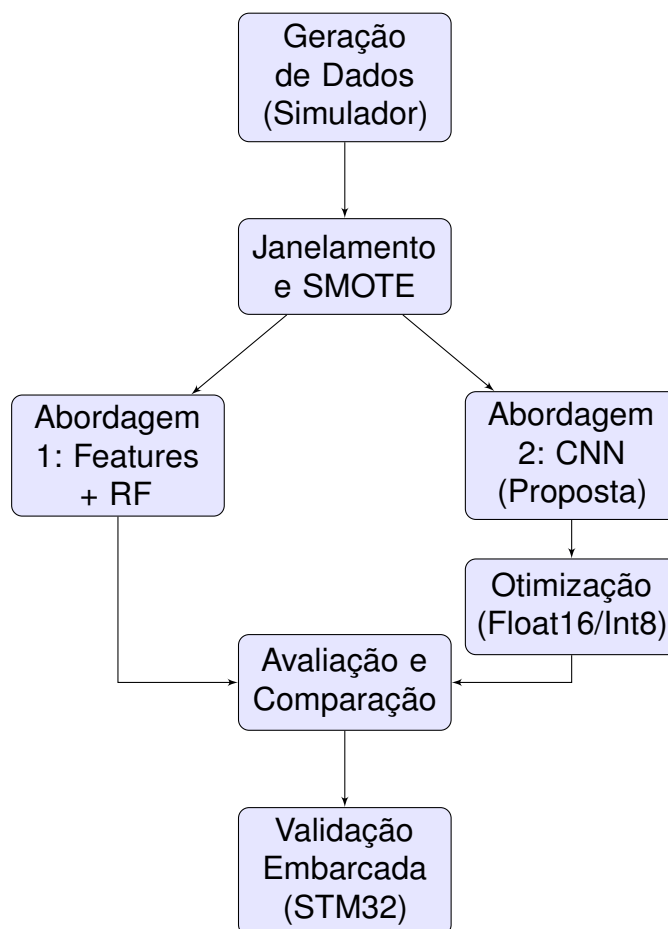


Figura 4.1 – Fluxograma da metodologia adotada, desde a geração dos dados até a validação embarcada.

4.1 GERAÇÃO DE DADOS

Devido à escassez de dados reais com anotações de RS ou FA, o desenvolvimento de detectores robustos acaba se tornando muitas vezes limitado. A fim de superar este fato, este trabalho utilizou um simulador de sinais fisiológicos (SOLOŠENKO et al., 2022) para gerar um conjunto de dados abrangente e representativo de diferentes características morfológicas e do sinal. A ferramenta de simulação foi desenvolvida para endereçar a falta de bancos de dados públicos com anotações confiáveis, permitindo a geração de dados de maneira controlada para o desenvolvimento e validação de algoritmos (PETRENAS et al., 2017; SOLOŠENKO et al., 2016; PALIAKAITÈ et al., 2021).

A simulação consiste na criação de sinais de ECG com base em dados anotados de fontes como o PhysioNet (GOLDBERGER et al., 2000), os quais foram posteriormente utilizados para alimentar um modelo que gera o sinal de PPG correspondente. Para representar as diferentes características fisiológica entre indivíduos, o simulador permite a geração de quatro morfologias de pulso distintas. Para este estudo, o simulador foi executado 1100 vezes, gerando um total de 4400 sinais de PPG com anotações sincronizadas por batimento, simulando uma frequência de aquisição de 100 Hz. Visando focar inicialmente na detecção do ritmo, os sinais foram gerados sem a adição de artefatos de movimento.

4.2 DIVISÃO DO CONJUNTO DE DADOS E ESTRATÉGIA DE VALIDAÇÃO

Antes de qualquer processamento, os dados gerados foram divididos em conjuntos de treinamento e validação, visando de tal maneira alcançar uma análise robusta dos modelos gerados e evitar vazamento de dados, ou seja, dados usados para o treinamento nunca sejam utilizados para validação. Os dados foram separados aleatoriamente em 80% para o conjunto de treinamento e 20% para o conjunto de validação. A separação assim feita simula como se 80% dos pacientes tivessem seus dados usados somente para treinamento e o restante dos pacientes fossem somente utilizados para validar os modelos.

Embora a definição clínica de um episódio de FA exija uma duração mínima de 30 segundos, visando uma análise computacional e aplicação em tempo real, uma janela deslizante de 10 segundos foi definida. O valor de tempo foi definido conforme o compromisso de que se tenham múltiplos batimentos cardíacos capturados, mas ainda mantendo uma baixa latência para a detecção da fibrilação em um sistema embarcado sem sobrecarregar o consumo de memória RAM. Como o mínimo exigido são 30 segundos, no sistema embarcado para alertar de fato a presença de FA, serão necessárias no mínimo 3 janelas seguidas com a presença detectada pelo modelo, emulando, assim, o critério clínico (CAMM et al., 2010; JANUARY et al., 2014). Concluindo, os

episódios de FA que não tenham duração ininterrupta de 30 segundos ou mais não foram considerados diagnósticos. Como é uma tarefa de aprendizado supervisionado, para uma janela de análise ser rotulada como FA, todas as amostras deveriam ter o marcador de presença como verdadeiro para ser considerado um episódio válido, sendo que janelas contendo transições entre ritmos foram descartadas.

4.3 BALANCEAMENTO DE CLASSES COM SMOTE

Como a maioria dos dados eram de ritmos sinusais, a distribuição de classes no conjunto de dados apresentou um grande desbalanceamento, ou seja, os modelos tiveram muito mais exemplos para aprender sobre o que é um ritmo sinusal do que uma fibrilação atrial. Este cenário, o qual é comum em dados de diagnóstico médico, é um desafio para os algoritmos de aprendizado de máquina, visto que um viés em favor da classe majoritária (RS) pode ser desenvolvido. No final, isso resulta em uma baixa capacidade de detecção da classe minoritária (FA), a qual acaba por elevar o número de falsos negativos.

Para mitigar este problema, tentou-se inicialmente somente alterar o peso de cada classe, em que FA teria um peso inversamente proporcional à razão entre o número de casos de RS e FA, como esta técnica não surtiu efeito, foi empregada a técnica SMOTE (*Synthetic Minority Over-sampling Technique*) (CHAWLA et al., 2002).

É importante destacar que a aplicação desse método foi feito somente no conjunto de dados de treinamento, de tal maneira que se manteve a distribuição dos conjuntos de dados de validação. Ao executar o processamento como descrito, evita-se o vazamento de dados e visa-se que a avaliação do modelo represente de fato a realidade e a generalização real se mantenha. Ao expor o modelo a uma mesma quantidade de dados para ambas as classificações, visa-se aprimorar a capacidade de aprender e reconhecer os padrões minoritários assim como os majoritários.

4.4 ABORDAGEM 1: MODELAGEM COM ENGENHARIA DE CARACTERÍSTICAS MANUAIS

A primeira abordagem a ser investigada utilizou da metodologia clássica de aprendizagem de máquina, a qual consiste na extração manual de características do sinal PPG. No caso desse estudo, deu-se a extração de diversos tipos como propriedades estatísticas, morfológicas e etc. Na sequência as características passaram por algoritmos de seleção a fim de que se utilize somente as características mais significativas para descrever o comportamento físico a ser modelado. O objetivo dessa abordagem era o de estabelecer uma referência mínima que poderia se alcançar.

4.4.1 Extração de características

Para cada uma das janelas de 10 segundos mencionadas anteriormente, trinta e uma características foram extraídas, de tal maneira que o sinal bruto do PPG foi transformado em um formato tabular que poderia ser injetado para treinamento dos modelos. Essas características foram projetadas para capturar diferentes aspectos do sinal, desde suas propriedades estatísticas básicas até informações complexas sobre a dinâmica cardiovascular. Elas são agrupadas em características estatísticas, morfológicas e derivativas, e são definidas a seguir.

4.4.1.1 Características Estatísticas do Sinal Bruto

Estas características descrevem a distribuição da amplitude do sinal PPG, p_i , dentro de uma janela com N amostras.

- Média da Amplitude Representa a intensidade média do sinal durante a janela, correspondendo à componente DC do sinal PPG. Este é influenciado pela composição da pele, pressão de contato do sensor, condições de iluminação no ambiente e volume de sangue. Alterações desse valor em sinais provindos da medição de um paciente ao longo do tempo podem ser causadas por artefatos de movimento ou até mesmo mudança nos padrões de respiração (ELGENDI, 2012).

$$\mu_{PPG} = \frac{1}{N} \sum_{i=1}^N p_i \quad (4.1)$$

Onde μ_{PPG} é a média, N o número de amostras e p_i a i -ésima amostra do sinal.

- Mediana da Amplitude É a tendência central da amplitude do sinal e por conta disso acaba sendo menos suscetível a valores extremos que a média. Uma diferença significativa entre a mediana e a média sugere uma distribuição assimétrica dos valores de amplitude na janela.
- Desvio Padrão da Amplitude Quantifica a dispersão ou variabilidade da amplitude do sinal em torno da média. Um valor mais alto pode indicar uma componente pulsátil (AC) maior, maior variabilidade fisiológica, ou a presença de ruído e artefatos significativos na janela. (IBTEHAZ et al., 2022; ELGENDI, 2012)

$$\sigma_{PPG} = \sqrt{\frac{1}{N} \sum_{i=1}^N (p_i - \mu_{PPG})^2} \quad (4.2)$$

Onde σ_{PPG} é o desvio padrão.

- Intervalo Interquartil Mede a dispersão estatística dos 50% centrais dos dados de amplitude. Por ser baseado em percentis, é uma medida de variabilidade mais

robusta a valores extremos do que o desvio padrão.

$$IQR = Q_3 - Q_1 \quad (4.3)$$

Onde Q_1 é o primeiro quartil (25º percentil) e Q_3 é o terceiro quartil (75º percentil) dos valores de amplitude.

- Assimetria Mede a assimetria da distribuição de probabilidade dos valores do sinal. Estudos demonstram que a assimetria é um Indicador de Qualidade do Sinal (SQI) eficaz, pois ruídos e artefatos de movimento tendem a introduzir assimetrias características na distribuição do sinal (SOLTANE et al., 2022). Como neste estudo não foram incluídos artefatos de movimento, o maior indicativo é que essa característica não seja significativa.

$$S = \frac{1}{N} \sum_{i=1}^N \left(\frac{p_i - \mu_{PPG}}{\sigma_{PPG}} \right)^3 \quad (4.4)$$

Onde S é o coeficiente de assimetria, e as demais variáveis (μ_{PPG} , σ_{PPG}) foram definidas anteriormente.

- Curtose Leva em consideração desvios com relação a distribuição normal, ou seja, mede valores extremos em comparação a distribuição normal. Assim como a assimetria, é um indicador sensível a valores extremos e tem sido utilizado como um Indicador de Qualidade do Sinal (SQI) (ELGENDI, 2016; SOLTANE et al., 2022).

$$K = \frac{1}{N} \sum_{i=1}^N \left(\frac{p_i - \mu_{PPG}}{\sigma_{PPG}} \right)^4 \quad (4.5)$$

Onde K é o coeficiente de curtose.

- Número de Picos Corresponde à contagem total de picos sistólicos detectados na janela, $N_{picos} = |\mathcal{P}|$, onde \mathcal{P} é o conjunto de picos identificados na janela. Pode ser utilizada como uma estimativa direta da frequência de pulso média na janela e pode indicar problemas de qualidade do sinal se o valor for anormalmente alto ou baixo. (GODA; CHARLTON; BEHAR, 2023)

4.4.1.2 Características de Frequência do Sinal Normalizado (FFT)

Para a análise espectral, aplicou-se a FFT sobre as janelas do sinal $X(f)$. Antes da transformação, foi aplicado um janelamento de Hanning para minimizar o vazamento espectral nas bordas da janela de 10 segundos. O espectro resultante foi normalizado para garantir consistência entre diferentes amplitudes de sinal, focando na distribuição relativa de energia nas frequências de interesse.

- **Frequência e Amplitude Dominantes** Representa a frequência na qual o espectro de potência do sinal exibe sua energia máxima. Em um sinal sem a presença de ruídos, esta frequência corresponde à frequência fundamental do batimento cardíaco. Este valor é influenciado pela amplitude fisiológica do pulso e pela qualidade do sinal (INSTRUMENTS, 2023; SEMMLOW, 2018).

$$f_{dom} = \arg \max_f |X(f)| \quad (4.6)$$

$$A_{dom} = |X(f_{dom})| \quad (4.7)$$

Onde f_{dom} é a frequência com a máxima energia e A_{dom} é a amplitude correspondente.

- **Centroide Espectral Normalizado** Indica a frequência na qual a maior parte da energia do sinal está distribuída. Um deslocamento do centroide pode indicar alterações no conteúdo harmônico da onda de pulso ou a introdução de ruído de alta frequência (SEMMLOW, 2018).

$$f_c = \frac{\sum_k f_k |X(f_k)|}{\sum_k |X(f_k)|} \quad (4.8)$$

Onde f_k é a frequência do k-ésimo bin da FFT e $|X(f_k)|$ é sua magnitude.

- **Largura de Banda Espectral Normalizada** Quantifica a dispersão da potência do sinal através do espectro de frequência. Uma largura de banda estreita sugere um sinal limpo e periódico, enquanto uma largura de banda larga pode indicar a presença de ruído ou modulações complexas (SEMMLOW, 2018).

$$BW = \sqrt{\frac{\sum_k (f_k - f_c)^2 |X(f_k)|}{\sum_k |X(f_k)|}} \quad (4.9)$$

Onde BW representa a Largura de Banda Espectral, e as demais variáveis (f_k , f_c , $|X(f_k)|$) foram definidas na equação do Centroide Espectral.

- **Taxa de Cruzamento por Zero Normalizada** Mede a frequência com que o sinal normalizado cruza o eixo zero. É um indicador simples do conteúdo de frequência e do nível de ruído, sinais com componentes de alta frequência ou com muito ruído tendem a ter uma ZCR mais alta (ELGENDI, 2016; SEMMLOW, 2018).

$$ZCR = \frac{1}{T_w} \sum_{i=2}^N \mathbf{1}(p'_{i-1} \cdot p'_i < 0) \quad (4.10)$$

Onde p' é o sinal normalizado, T_w é a duração da janela e $\mathbf{1}(\cdot)$ é a função indicadora.

4.4.1.3 Características da Velocidade do Sinal (VPG)

Propriedades estatísticas do Pletismograma de Velocidade, a primeira derivada do sinal (v_i), tendo o seu valor de média, desvio padrão e valores máximos e mínimos (SUBOH et al., 2022).

- Média e Desvio Padrão da VPG

$$\mu_{VPG} = \frac{1}{N} \sum_{i=1}^N v_i \quad (4.11)$$

$$\sigma_{VPG} = \sqrt{\frac{1}{N} \sum_{i=1}^N (v_i - \mu_{VPG})^2} \quad (4.12)$$

- Valor Máximo e Mínimo da VPG

$$v_{max} = \max_{1 \leq i \leq N} (v_i) \quad (4.13)$$

$$v_{min} = \min_{1 \leq i \leq N} (v_i) \quad (4.14)$$

Onde v_i é o valor da i -ésima amostra do sinal VPG.

4.4.1.4 Características da Aceleração do Sinal (APG)

As estatísticas da segunda derivada (APG) quantificam a aceleração do fluxo sanguíneo. Estas características são particularmente sensíveis a mudanças na rigidez arterial e no envelhecimento vascular, que alteram a curvatura da onda de pulso original (AHN, 2015).

- Média e Desvio Padrão da APG

$$\mu_{APG} = \frac{1}{N} \sum_{i=1}^N a_i \quad (4.15)$$

$$\sigma_{APG} = \sqrt{\frac{1}{N} \sum_{i=1}^N (a_i - \mu_{APG})^2} \quad (4.16)$$

- Valor Máximo e Mínimo da APG

$$a_{max} = \max_{1 \leq i \leq N} (a_i) \quad (4.17)$$

$$a_{min} = \min_{1 \leq i \leq N} (a_i) \quad (4.18)$$

Onde a_i é o valor da i -ésima amostra do sinal APG.

4.4.1.5 Características Morfológicas do Pulso

Descrevem a forma dos N_{picos} pulsos de PPG identificados na janela.

- Média e Desvio Padrão da Amplitude dos Pulsos Calcula a média e a variabilidade da amplitude dos pulsos na janela. A amplitude do pulso está relacionada à perfusão tecidual local e pode variar com a respiração (modulação da amplitude induzida pela respiração), temperatura e estado cardiovascular (MOSCATO et al., 2022; ALLEN, 2007).

$$\mu_{Amp} = \frac{1}{N_{picos}} \sum_{k=1}^{N_{picos}} A_k \quad , \quad \sigma_{Amp} = \sqrt{\frac{1}{N_{picos}} \sum_{k=1}^{N_{picos}} (A_k - \mu_{Amp})^2} \quad (4.19)$$

Onde A_k é a amplitude do k-ésimo pulso.

- Média e Desvio Padrão da Largura dos Pulsos Calcula a média e a variabilidade da largura dos pulsos, comumente medida a 50% de sua altura. A largura do pulso está relacionada a propriedades do sistema vascular, como a resistência vascular sistêmica e a rigidez arterial (ELGENDI, 2012; ALLEN, 2007).

$$\mu_{Larg} = \frac{1}{N_{picos}} \sum_{k=1}^{N_{picos}} L_k \quad , \quad \sigma_{Larg} = \sqrt{\frac{1}{N_{picos}} \sum_{k=1}^{N_{picos}} (L_k - \mu_{Larg})^2} \quad (4.20)$$

Onde L_k é a largura do k-ésimo pulso, medida a 50% de sua amplitude.

4.4.1.6 Características de Variabilidade do Pulso (PPI)

Quantificam as flutuações nos M intervalos entre picos consecutivos (I_k), análogas à VFC.

- Média do Intervalo PPI Representa a duração média do ciclo cardíaco na janela. Seu inverso está diretamente relacionado à frequência de pulso média (SHAFFER; GINSBERG, 2017).

$$\mu_{PPI} = \frac{1}{M} \sum_{k=1}^M I_k \quad (4.21)$$

- Desvio Padrão do PPI Mede a variabilidade geral da frequência de pulso em torno da média. É análogo ao Desvio Padrão dos Intervalos NN(SDNN) da análise de VFC (SHAFFER; GINSBERG, 2017).

$$\sigma_{PPI} = \sqrt{\frac{1}{M} \sum_{k=1}^M (I_k - \mu_{PPI})^2} \quad (4.22)$$

- RMSSD do PPI Reflete as variações rápidas, batimento a batimento, do ritmo cardíaco. Está fortemente associada à atividade do sistema nervoso parassimpático (vagal) e é uma medida robusta para análises de curta duração (SHAFFER;

GINSBERG, 2017).

$$RMSSD = \sqrt{\frac{1}{M-1} \sum_{k=1}^{M-1} (I_{k+1} - I_k)^2} \quad (4.23)$$

Onde M é o número de intervalos PPI na janela e I_k é a duração do k -ésimo intervalo.

- Entropia Amostral do PPI Quantifica a regularidade ou previsibilidade da série temporal de intervalos PPI. Valores mais baixos indicam maior regularidade, enquanto valores mais altos sugerem maior complexidade ou aleatoriedade nos batimentos (RICHMAN; MOORMAN, 2000).
- Potência Espectral do PPI Quantificam a potência da variabilidade do pulso em bandas de frequência específicas. A potência de alta frequência (HF) está ligada à atividade parassimpática e à respiração, enquanto a de baixa frequência (LF) reflete uma mistura de influências simpáticas, parassimpáticas e do barorreflexo (Task Force of The European Society of Cardiology and The North American Society of Pacing and Electrophysiology, 1996).

$$P_{LF} = \int_{0.04}^{0.15} P_{xx}(f) df \quad (4.24)$$

$$P_{HF} = \int_{0.15}^{0.4} P_{xx}(f) df \quad (4.25)$$

Tradicionalmente usada como um índice do balanço simpátovagal (equilíbrio entre as atividades parassimpáticas e simpáticas). Reflete a relação entre as modulações de baixa e alta frequência do ritmo cardíaco (Task Force of The European Society of Cardiology and The North American Society of Pacing and Electrophysiology, 1996).

$$Razão_{LF/HF} = \frac{P_{LF}}{P_{HF}} \quad (4.26)$$

Onde P_{LF} e P_{HF} representam a potência nas bandas de baixa e alta frequência, respectivamente.

4.4.2 Seleção de características

Com o intuito de diminuir o custo computacional do treinamento e da própria inferência, além de reduzir o risco de sobreajuste no treinamento, a seleção de características foi performada de tal maneira em que características redundantes ou irrelevantes foram removidas do treinamento e posteriormente não vieram a ser incluídas no sistema embarcado. Por exemplo, pode-se verificar a correlação linear entre as características através de um mapa de calor resultante de uma análise de correlação de Pearson, em que valores próximos de 1 ou -1 indicam alta correlação, sugerindo

redundância de informação e reforçando a necessidade dos métodos de seleção de características. Na seção 5.2.1 será discutido mais sobre o tema.

Visando selecionar as melhores características, três métodos distintos foram investigados, sendo eles o Análise de Variância F-Test, Informação Mútua e Eliminação Recursiva de Recursos.

4.4.3 Modelos Classificadores da Abordagem Clássica

Visando estabelecer um comparativo entre diferentes métodos de aprendizado de máquina e aprendizado profundo, optou-se por utilizar para a abordagem clássica dois modelos bem fundamentados e conhecidos que podem ser usados para fundamentar valores de referência de eficácia dos modelos. Os modelos escolhidos foram o Perceptron Multicamadas (MLP) e o *Random Forest*, em que o primeiro foi treinado para as diferentes três metodologias de seleção de características e o segundo somente com RFE, visto que este método apresentou melhores resultados já para a MLP e por definição técnica e metodológica possui sinergia com o *Random Forest*. A escolha destas técnicas específicas se justifica pela maturidade e interpretabilidade que oferecem. O MLP serve como um aproximador universal robusto, enquanto o *Random Forest* foi selecionado pela sua resiliência intrínseca ao sobreajuste e capacidade de lidar com dados não lineares, características essenciais para estabelecer uma linha de base sólida.

4.4.3.1 *Perceptron Multicamadas* (MLP)

Para a avaliação da abordagem clássica, foram desenvolvidos e treinados três modelos MLP diferentes, cada um utilizando os subconjuntos de características descritos na Seção 2.2.1 (ANOVA F-Test, Informação Mútua e RFE), permitindo uma análise comparativa do impacto da seleção de características na performance do modelo.

- Arquitetura do Modelo

A arquitetura da MLP foi mantida a mesma entre os três experimentos para que se pudesse garantir uma comparação direta do ponto da estrutura e podendo-se isolar a performance de cada método de seleção de características. A estrutura, definida empiricamente, foi composta por:

- Camada de entrada com dimensão correspondente ao número de características de cada método.
- Camada oculta densa com 128 neurônios.
- Camada de *Dropout* com taxa de 0,5 para regularização.
- Camada oculta densa com 64 neurônios.

- Camada de *Dropout* com taxa de 0,3.
- Camada de saída com um único neurônio e ativação sigmoide, adequada para classificação binária.

Todas as camadas ocultas utilizaram a função de ativação ReLU. Adicionalmente, foi aplicada uma regularização L2 com um fator λ de 0,01 na primeira camada densa para penalizar a complexidade do modelo e mitigar o sobreajuste.

- Procedimento de Treinamento Além disso, o processo de treinamento também foi mantido igual para os três modelos, sendo que a compilação utilizou o otimizador Adam e a função de perda de entropia cruzada. O tamanho do lote de treinamento utilizado foi de 32 amostras por no máximo 50 épocas, sendo que um mecanismo de parada antecipada foi utilizado para evitar sobreajustes e para que se pudesse garantir a generalização do modelo. O mecanismo monitorou a AUC no conjunto de validação com uma paciência de 10 épocas.
- Justificativa dos Hiperparâmetros A seleção dos hiperparâmetros para a arquitetura MLP foi baseada em práticas comuns e valores de referência bem estabelecidos na literatura de aprendizado de máquina, com o objetivo de configurar um modelo de referência representativo, sem necessariamente fazer uma busca exaustiva para a definição dos melhores hiperparâmetros.

A justificativa para a configuração adotada é a seguinte:

- Arquitetura da Rede (128 e 64 neurônios): Foi adotada uma arquitetura em que reduz-se a quantidade de neurônios entre camadas, o que é comum a fim de que se reduza gradualmente a dimensionalidade dos dados entre as camadas.
- Regularização (*Dropout* e L2): As taxas de 0,5 e 0,3 para cada *dropout* e o fator de regularização L2 igual à 0,01 são valores padrão, os quais são recomendados em diversas fontes, incluindo a documentação de bibliotecas como Keras e artigos de referência (SRIVASTAVA et al., 2014a), para prevenir o sobreajuste em redes de média complexidade.
- Conjuntos de Características Utilizados Os três modelos MLP se diferenciaram exclusivamente pelo conjunto de características de entrada, conforme detalhado abaixo:
 - Modelo MLP-ANOVA: Utilizou as 7 características selecionadas pelo método ANOVA F-Test, sendo elas: a amplitude da frequência dominante, média da amplitude do pulso, curtose, VPG máximo, VPG mínimo, APG máximo e desvio padrão do PPI.

- Modelo MLP-MI: Utilizou as 7 características selecionadas pelo método de Informação Mútua, sendo elas: APG mínimo, APG máximo, desvio padrão do APG, média do APG, VPG máximo, a amplitude da frequência dominante e curtose.
- Modelo MLP-RFE: Utilizou as 6 características selecionadas pelo método RFE, sendo elas: APG mínimo, média da largura do pulso, desvio padrão do PPI, desvio padrão do PPG, RMSSD do PPI e a amplitude da frequência dominante.

4.4.3.2 *Random Forest*

A seleção do *Random Forest* como um dos modelos base para a referência se justifica por três fatores principais, sendo eles:

- Alta performance para dados tabulares
- Simplicidade de implementação
- Através das métricas de importância de características, ela fornece graus de interpretabilidade dos preditores

Para o treinamento do *Random Forest*, optou-se por utilizar somente o RFE como método de seleção. A escolha foi baseada nos resultados encontrados para o RFE *versus* ANOVA F-TEST e MI para o treinamento da MLP e por o RFE operar em sinergia com o *Random Forest*, visto que ele treina um *Random Forest* durante o seu processo de decisão de importância de cada característica. Além disso é um método do tipo *wrapper* e através da sua abordagem multivariada tende a correlacionar melhor metodologicamente a etapa de seleção de características e de classificação.

Portanto, a combinação RFE com *Random Forest* foi definida como a potencial melhor solução através de abordagens clássicas para servir de referência para este estudo quando comparado com o desempenho de modelos neurais mais complexos.

O modelo foi implementado utilizando a biblioteca Scikit-learn e os hiperparâmetros foram configurados com valores padrão que podem ser vistos abaixo

- Configuração do Modelo O modelo *Random Forest* foi implementado utilizando a biblioteca Scikit-learn. Os hiperparâmetros foram configurados com valores padrão robustos, visando criar uma referência forte e representativa. A configuração utilizada foi a seguinte:

- * Número de Árvores: O *ensemble* foi composto por 100 árvores de decisão. Este valor é um padrão comum que geralmente oferece um bom balanço entre performance e custo computacional.
 - * Profundidade Máxima: As árvores foram permitidas a crescer até uma profundidade máxima de 20.
 - * Critério de Divisão: Foi utilizado o critério Gini para medir a qualidade das divisões nos nós das árvores.
 - * Balanceamento de Classes: Para lidar com o desbalanceamento de classes, foi utilizado o SMOTE.
 - * Outros Parâmetros: Todos os outros hiperparâmetros foram mantidos em seus valores padrão da biblioteca, como `min_samples_split=2` e `min_samples_leaf=1`.
- Procedimento de Treinamento Conforme a metodologia, o modelo *Random Forest* foi treinado exclusivamente com o subconjunto de 6 características selecionadas pelo método RFE (detalhadas na Seção 2.2.1.2). O treinamento foi realizado utilizando o conjunto de dados de treino previamente balanceado pela técnica SMOTE (descrita na Seção 4.3).

4.5 ABORDAGEM 2: MODELO DE APRENDIZADO PROFUNDO PURO

Visando superar a eficiência encontrada com a referência estabelecida, uma abordagem com aprendizado profundo foi desenvolvida utilizando redes neurais convolucionais. O objetivo dessa abordagem era o de encontrar, desde a sua concepção, uma arquitetura que fosse totalmente compatível com as restrições do microcontrolador escolhido e as bibliotecas do TensorFlow Lite, garantindo de tal maneira que se fosse viável implementar o modelo no *hardware* em questão.

4.5.1 Preparação dos Dados Sequenciais

Diferentemente da abordagem anterior, aqui, ao invés de se extrair um vetor de características, a própria sequência de sinal da janela de 10 segundos é utilizada como entrada para o modelo. Na expectativa de se aprimorar a capacidade da rede neural de extrair os padrões necessários para classificar corretamente as classes, foi adotada uma abordagem multicanal, em que não somente o sinal original foi utilizado como entrada, mas também a sua primeira derivada, a qual descreve a VPG. A decisão de utilizar apenas os dois sinais e não ir além, por exemplo usando a segunda derivada (APG) foi deliberada e buscando um balanço entre riqueza da informação e o custo computacional. Além disso, processos de diferenciação tendem a amplificar ruídos de alta frequência, os quais estarão

presentes no sinal real, quando todo o modelo estiver embarcado em um relógio inteligente, como a APG é a segunda derivada, acaba se tornando ainda mais suscetível a esse tipo de problema.

- Canal 1 (PPG Normalizado): É o sinal original normalizado por Z-score para ter média zero e desvio padrão um. Representa a informação principal e direta da variação do fluxo sanguíneo.
- Canal 2 (VPG): É a primeira derivada do sinal PPG normalizado. Conforme discutido na Seção 2.2.1.1, a inclusão do VPG tem como objetivo fornecer ao modelo uma visão mais direta da dinâmica do fluxo sanguíneo, o que auxilia em uma melhor representação do sinal ao acentuar características morfológicas importantes da onda de pulso.

4.5.2 Arquitetura Puramente Convolutiva (CNN)

A fim de se garantir a compatibilidade do modelo utilizando TFLM para o microprocessador escolhido, desenvolveu-se uma rede neural convolutiva utilizando apenas operações padrões que são suportadas pela TFLM, como as camadas as camadas convolucionais 1D para extrair padrões morfológicos do sinal e uma camada *Global Average Pooling 1D* para agregar a informação temporal encontrada através das camadas as camadas convolucionais 1D.

- Blocos Convolutivos A extração de características foi realizada através de três blocos convolutivos sequenciais, sendo que cada um desses blocos é composto por um conjunto de filtros que tem como objetivo identificar padrões. Neste estudo utilizou-se uma progressão no número de filtros em cada um dos três blocos, começando com 32 e posteriormente progredindo para 64 e 128. A escolha de aumentar a quantidade de filtros seguiu a convenção padrão de aumentar a capacidade de camadas mais profundas aprenderem padrões mais complexos através dos padrões mais simples detectados em camadas iniciais (SIMONYAN; ZISSERMAN, 2014).

Já o tamanho dos filtros em cada camada diminui ao passo que se aprofunda na rede neural, no caso do estudo foram utilizados 7, 5 e 3 respectivamente, visto que filtros maiores nas camadas iniciais permitem que padrões mais gerais e amplos sejam detectados como a morfologia geral da onda de pulso, enquanto que filtros menores nas camadas mais profundas aprendem a detectar padrões com detalhes mais finos e pontuais do sinal (FAWAZ et al., 2019).

Após o processamento por cada camada as camadas convolutivas 1D, a saída de cada camada é então normalizada através da etapa chamada *Batch Normalization*, a fim de se estabilizar a distribuição das ativações e, assim, resolver o

problema do desvio covariante interno, o qual nada mais é de que o problema causado pela constante atualização dos pesos de cada camada ao passo que o treinamento avança, o que altera a distribuição de saída de cada camada. Como cada camada está atualizando seus pesos e a saída de cada uma dessas é utilizada para alimentar a próxima, esta recebe sempre dados que não são estáveis para utilizar como treinamento. A normalização garante que o sinal sempre tenha média zero e desvio padrão unitário, garantindo que cada camada tenha um ambiente muito mais estável para o treinamento e possibilitando que taxas de aprendizado sejam mais elevadas, acelerando a convergência do modelo (IOFFE; SZEGEDY, 2015).

- Agregação Temporal e Classificação

Após a extração de características, a camada *Global Average Pooling 1D* é utilizada, a fim de que toda a informação da sequência temporal seja agregada ao se calcular a média de cada mapa de características e montando por fim um vetor de características. Desta maneira, quando se compara com a alternativa tradicional (achatamento) reduz-se drasticamente o número de parâmetros, visto que o que servirá como entrada para a camada densa será um resumo de cada mapa de característica, enquanto que o achatamento utilizará todos os dados de cada mapa de característica (LIN; CHEN; YAN, 2013).

O vetor de características resultante mencionado anteriormente é processado por um bloco classificador. Além do bloco, tem-se as camadas de *dropout* como explicado na Seção 2.2.3.3.

A camada de saída possui somente um neurônio com ativação linear e, diferentemente do que normalmente se usa, a resposta do modelo se encerra em uma função *logit* ao invés de seguir até uma sigmoide, em outras palavras, o valor da saída do modelo é um valor não normalizado e não binário, o qual não será processado pela função sigmoide. Optou-se por esta metodologia pela sua maior estabilidade numérica, visto que, como a função de perda utilizada para otimizar os pesos do modelo, depende de logaritmos, os quais podem ter como resposta infinito, interrompendo assim o treinamento. Na fase de validação, a função sigmoide é utilizada para a classificação (BENGIO; DELALLEAU, 2011).

4.6 ABORDAGEM 3: INVESTIGAÇÃO DE PERFORMANCE COM ARQUITETURA HÍBRIDA

Seguindo a abordagem de alguns estudos referenciados na seção 3, explorou-se a arquitetura híbrida CNN-LSTM para entender um pouco mais sobre qual o limite de desempenho alcançável da CNN. O microcontrolador escolhido não tem bibliotecas

prontas para a parte LSTM, então o modelo investigado serve somente como referência para o estudo da CNN.

4.6.1 Arquitetura Híbrida CNN-LSTM: Análise de Dependências Temporais com LSTM

Nesta arquitetura, após as características serem extraídas pelas camadas convolucionais, elas são processadas pela camada de Memória de Curto e Longo Prazo (LSTM) com 64 unidades. Todos os blocos convolucionais utilizados na Abordagem 2, o procedimento de treinamento, função de perda e mecanismo de parada antecipada foram também utilizados nesta abordagem.

4.7 OTIMIZAÇÃO DE MODELO PARA AMBIENTE EMBARCADO

Como mencionado anteriormente, a abordagem 1 e 3 foram desenvolvidas para se encontrar valores de referência mínimo e máximo de que uma CNN (abordagem 2) deveria conseguir alcançar ao comparar-se com uma MLP e uma CNN-LSTM. Logo, para embarcar o modelo desenvolvido na Abordagem 2 em um ambiente de sistema embarcado, decidiu-se por explorar diferentes estratégias de quantização e otimização para reduzir tanto consumo de memória *flash* quanto *RAM*. Para cada uma das estratégias, comparou-se valores de acurácia, AUC, etc com o valor de referência original do treinamento. Foram exploradas a abordagem de conversão de 32-bits float para 16-bits float e a quantização para inteiros de 8-bits através do Treinamento Consciente de Quantização (QAT).

4.7.1 Conversão para Ponto Flutuante (float16) com *half-precision*

A primeira estratégia de otimização explorada foi a quantização dos pesos do modelo para o formato de ponto flutuante de 16-bits, visando encontrar um compromisso entre a compressão do modelo e a manutenção da precisão encontrada no modelo original. Como a estrutura do ponto flutuante é mantida, diferentemente da quantização para inteiros, espera-se que esse seja a quantização com menor perda de informação (GUPTA et al., 2015).

A quantização do modelo Keras treinado com pesos em 32-bits float foi realizada utilizando o TensorFlow Lite Converter. A conversão utilizou configurações padrão `tf.lite.Optimize.DEFAULT` e `converter.target_spec.supported_types = [tf.float16]`, os quais acarretam em uma redução da precisão dos tensores de pesos, o que reduz em teoria 50% do tamanho do modelo com perda mínima na performance, conforme será avaliado no Capítulo 5.

4.7.2 Investigação da Quantização para Inteiros (int8)

A fim de se encontrar o limite máximo de otimização, estudou-se a quantização para inteiro de 8 bits. Essa abordagem de quantização possui a maior taxa de compressão do tamanho do modelo, permitindo que uma gama maior de microcontroladores sejam utilizadas, mas também é a que apresenta maiores chances de ter o modelo com uma performance degradada (JACOB et al., 2018). A fim de reduzir tal risco, utilizou-se a técnica QAT, o qual simula o efeito de quantização durante a fase de treinamento, ao invés de fazer um pós-processamento. Tal efeito simulado é alcançado ao se inserir nos nós uma falsa quantização durante o treinamento, de tal maneira que um peso treinado em 32-bits float é convertido para um inteiro e logo em seguida convertido novamente para 32-bits float, fazendo com que os pesos sejam ajustados levando em consideração o erro de conversão, levando potencialmente à uma melhoria na performance (KRISHNAMOORTHY, 2018).

A implementação da quantização QAT para a arquitetura CNN descobriu-se que a biblioteca *TensorFlow Model Optimization* (TF-MOT) não possui suporte nativo para a quantização de camadas convolucionais 1D, então fez-se necessário desenvolver uma classe customizada, conforme pode ser visto abaixo:

- **Configuração de Quantização Customizada para as camadas convolucionais 1D** A classe `Conv1DQuantizeConfig`, a qual herda a classe base `tfmot.quantization.keras.QuantizeConfig`, foi implementada especificando como os pesos e as ativações da camada convolucionais 1D devem ser quantizados, aplicando o *Moving Average Quantizer* para a conversão para 8-bits para cada componente.

- **Processo de Treinamento e Conversão**

Após a conclusão da configuração customizada, o processo de QAT seguiu duas etapas. A primeira consistiu na anotação no modelo original quais camadas são convolucionais 1D utilizando `tfmot.quantization.keras.quantize_annotate_layer` para serem quantizadas com a classe `1DQuantizeConfig`. Por fim, a função `tfmot.quantization.keras.quantize_apply` foi utilizada para transformar o modelo anotado em um modelo QAT, pronto para o retreinamento.

Quando o novo treinamento utilizando QAT foi finalizado, a conversão para um arquivo tflite com a quantização total para inteiros. Tal processo é realizado utilizando um conjunto de dados representativos para que a calibração da conversão seja feita. No caso deste estudo foram utilizadas 20.000 amostras do conjunto de treinamento. Tais amostras são balanceadas com a presença igualitária das diferentes classes e

também amostras com valores extremos, como com maior amplitude e variação que a média (BANNER; NAHSHAN; SOUDRY, 2019).

4.8 MÉTRICAS DE AVALIAÇÃO

A fim de se avaliar e comparar de maneira quantitativa a performance dos diferentes modelos treinados e desenvolvidos neste trabalho, dois tipos de métrica foram selecionados, sendo eles: métricas de performance preditiva, as quais quantificam a capacidade do modelo em classificar corretamente os sinais, e métricas computacionais, as quais avaliam a viabilidade de se implementar o modelo em um sistema embarcado.

4.8.1 Métricas de Performance Preditiva

Visto que as classes tem presença desequilibrada intrinsecamente no conjunto de dados e há a importância clínica de detectar episódios de FA, foram escolhidas métricas que vão além da acurácia e foram selecionadas conforme recomendado pela literatura para problemas que envolvem classificação na área médica (POWERS, 2008).

Acurácia Métrica intuitiva em que é feita a medida da proporção de previsões corretas em relação ao total de amostras. Ela não deve ser usada como única métrica, pois em um problema com bases desbalanceadas, como é o caso deste trabalho, caso o modelo sempre predissesse a classe majoritária, ainda assim teria-se uma alta acurácia, mesmo que erre todas as vezes uma outra classe (HOSSIN; M.N, 2015).

Área Sob a Curva ROC (AUC-ROC) A curva de operação do receptor consiste de uma representação gráfica da performance de um classificador binário. Ela plota a taxa de verdadeiros positivos, o que é chamado de sensibilidade, contra a taxa de falsos positivos à medida que o limiar de discriminação varia. A AUC-ROC é a quantificação da área sob esta curva e pode variar entre 0.5 ou 1.0, sendo que o primeiro caracteriza um desempenho aleatório e o segundo um desempenho com 100% de acerto (FAWCETT, 2006). Esta métrica foi a principal métrica para guiar o método de parada antecipada durante o treinamento dos modelos de aprendizado profundo.

Precisão, Sensibilidade e F1-Score Estas métricas são de suma importância para que a correta avaliação do desempenho do modelo na classe minoritária (FA) seja feita.

- Sensibilidade (*Recall*): Responsável por medir a proporção de casos positivos reais que foram corretamente identificados pelo modelo em relação ao

total de casos positivos no conjunto de dados. É uma das principais métricas, a qual espera-se que seja maximizada especialmente em uma aplicação médica, significando que o modelo é altamente capaz de detectar a presença da classe. É definida como (POWERS, 2008):

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (4.27)$$

onde VP é o número de Verdadeiros Positivos e FN é o número de Falsos Negativos.

- **Precisão:** Responsável por medir a proporção das predições positivas corretamente identificados pelo modelo em relação a todas as vezes que o modelo previu a classe. Alta precisão significa que o número de falso alarmes está minimizado e que o modelo erra pouco na classificação. É definida como (POWERS, 2008):

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (4.28)$$

onde FP é o número de Falsos Positivos.

- **F1-Score:** É a média harmônica entre sensibilidade e precisão, fornecendo em uma única métrica o resumo entre ambas. Um F1-Score alto indica que o modelo possui tanto uma boa precisão quanto uma boa sensibilidade. Foi a métrica utilizada para encontrar o limiar de decisão ótimo para a classificação final (GOUTTE; GAUSSIER, 2005). É definida como:

$$\text{F1-Score} = 2 \cdot \frac{\text{Precisão} \cdot \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} \quad (4.29)$$

4.8.2 Métricas de Custo Computacional

Como o foco do trabalho é embarcar o modelo em um sistema embarcado, faz-se necessário avaliar a viabilidade de se implementar o modelo no sistema embarcado. Para isso é necessário quantificar os custos da execução do modelo com os recursos de *hardware* presentes. A metodologia de avaliação tais custos do modelo para microcontroladores são baseadas principalmente nas seguintes métricas (WARDEN; SITUNAYAKE, 2019):

Tamanho do Modelo Mede o consumo de memória para armazenar o arquivo do modelo convertido (.tflite) e tem como unidade Kilobytes.

Uso de Memória RAM Quantifica a memória de acesso aleatório (SRAM), a qual é necessária para a execução da inferência do modelo, sendo o principal componente desta métrica o *Tensor Arena*, o qual é um buffer de memória estático que armazena os tensores de entrada e saída, além de ativações intermediárias do modelo (DAVID et al., 2021).

Tempo de Inferência Mede o tempo médio, em milissegundos (ms) ou *clock* do microcontrolador, que leva para executar uma única previsão em uma janela de 10 segundos. Esta métrica é importante para entender a abordagem das previsões em um sistema embarcado podendo ter previsões em tempo real ou necessitando fazer as previsões em períodos definidos.

4.9 FERRAMENTAS E AMBIENTE COMPUTACIONAL

Todos os *scripts* implementados e análise dos dados foram feitos utilizando a linguagem de programação *Python*, especificamente na versão 3.10. Tal linguagem foi escolhida devido ao robusto ecossistema de bibliotecas para computação científica e aprendizado de máquina. Algumas bibliotecas como Pandas (MCKINNEY, 2010), (TEAM, 2020) e NumPy (HARRIS et al., 2020) foram utilizadas para a manipulação dos dados e operações numéricas. O primeiro foi utilizado por conta da estrutura *Data Frame*, a qual auxilia na organização e pré-processamento dos dados, já o segundo fornece a implementação de todas as operações matemáticas necessárias.

Para a implementação dos modelos da abordagem clássica, como o *Random Forest* e o seletor de características RFE, foi utilizada a biblioteca Scikit-learn (PEDREGOSA et al., 2012). Esta biblioteca é consolidada e possui uma grande variedade de algoritmos de aprendizado de máquina com interfaces bem definidas e bem documentada.

A construção e o treinamento dos modelos de redes neurais, como MLP, foram realizados com as bibliotecas do *TensorFlow* (versão 2.15.0) (ABADI et al., 2016). Este foi selecionado por sua flexibilidade e escalabilidade para o desenvolvimento de modelos de aprendizado profundo. Especificamente, a API de alto nível Keras (CHOLLET et al., 2015) foi utilizada para a prototipação e definição da arquitetura da rede neural, devido à sua simplicidade e modularidade.

Todos os experimentos foram executados em um computador com as seguintes especificações:

- Processador: 11th Gen Intel(R) Core(TM) i7-11850H @ 2.50 GHz.
- Memória RAM: 32,0 GB.
- GPU: NVIDIA T1200 Laptop GPU com 4 GB de VRAM dedicada.
- Sistema Operacional: Windows 10, sistema operacional de 64-bits.

O microcontrolador escolhido foi o STM32L4R5ZI da STMicroelectronics, utilizando a placa de desenvolvimento Nucleo-144, a qual estava disponível no laboratório de pesquisa. Este microcontrolador possui um Arm Cortex-M4 operando até 120MHz e

contando com 2048 kBytes de memória *flash* e 640 Kbytes de SRAM (STMicroelectronics, 2025b).

Para embarcar o modelo, utilizou-se a ferramenta da STMicroelectronics chamada STM32CubeMX, a qual nada mais é que uma ferramenta geradora de código baixo nível que fornece as camadas de abstração de *hardware* (STMicroelectronics, 2025a). Foi utilizada a versão 6.15.0 para Windows. Além disso, ela conta com uma extensão para desenvolvimentos de aprendizado de máquina em que o modelo tanto em formato Keras ou TFLite pode se carregado e a própria ferramenta gera as funções necessárias para fazer a inferência. A ferramenta se chama X-CUBE-AI e foi utilizada a versão 10.2.0 para Windows.

5 RESULTADOS

Seguindo a mesma ordem lógica do que foi previamente descrito no Cap.4, neste capítulo são inicialmente abordados os resultados obtidos com a geração dos conjuntos de dados, posteriormente progredindo para os resultados obtidos para o aprendizado de máquina utilizando a abordagem clássica (MLP e *Random Forest*, posteriormente para os dois modelos de aprendizado profundo (CNN e CNN-LSTM) e concluindo com os resultados da otimização para o ambiente embarcado.


5.1 GERAÇÃO DE DADOS

O conjunto de dados foi gerado de maneira aleatória dentro de um espaço de inferência bem definido através de um conjunto de parâmetros principais para garantir a generalização do modelo final, sendo então gerados através da ferramenta de simulação de Fibrilação Atrial (SOLOŠENKO et al., 2022). Os parâmetros variados são:

- Quantidade de tipos morfológicos do sinal: A ferramenta possibilita a geração de até quatro morfologias do sinal PPG diferentes, sendo que então todos os tipos foram gerados, justamente para que o modelo seja capaz de aprender a classificar a FA independentemente da fisiologia de cada paciente. Com essa estratégia, evita-se que exista um sobreajuste do modelo a um tipo determinado o que possibilita a escalabilidade da solução.
- Presença de FA: Através desse parâmetro, foi possível gerar os dados com diferentes graus de presença de Fibrilação Atrial. Tal parâmetro é configurado através da porcentagem de incidência dentro do tempo total do sinal gerado. Foram então gerados dados com ritmo totalmente sinusal, dados somente com fibrilação atrial, mas também sinais com diferentes porcentagens de presença de FA, caracterizando sinais com transição entre as duas classes.
- Frequência de batimentos prematuros e mediana de episódios: Estes parâmetros possibilita a simulação de diferentes estágios e gravidades da arritmia, garantindo que a natureza paroxística da FA seja replicada, visto que os episódios terão, assim, durações e intensidades variadas, ou seja, o modelo foi treinado para detectar a condição cardíaca de diversas graus de manifestação.
- Tamanho do sinal: A duração total das simulações foi alterada para garantir que a metodologia de análise, a qual é baseada em janelas deslizantes de 10 segundos, fosse eficaz independentemente do tempo de monitoramento, reproduzindo tanto cenários de curta quanto de longa duração.

Seguindo essa estratégia de variação controlada foi possível construir um conjunto de dados que não apenas representa a FA, mas diferentes contextos nos quais ela pode se manifestar, fortalecendo a generalização do modelo.

Figura 5.1 – Amostra de sinal PPG simulado em Ritmo Sinusal (RS). Notar a periodicidade regular e a morfologia consistente dos pulsos, características de um ritmo cardíaco normal.




No total 1100 simulações foram executadas, sendo que cada simulação tinha as quatro morfologias citadas anteriormente, de tal maneira em que para cada simulação o equivalente a 4 pacientes foram gerados. Durante o pré-processamento esses dados foram separados e analisados individualmente, possibilitando então que se tenha o equivalente a 4400 simulações. Durante o pré-processamento, como mencionado anteriormente, somente janelas que possuíam todas as amostras com anotações refletindo a presença de FA foram consideradas dentro da janela de 10 segundos de análise. Presenças transitórias foram descartadas, visto que para ser considerado um diagnóstico de presença FA, esta deve estar presente por 30 segundos consecutivos e analisar os dados através de uma janela deslizante não se tornou possível no computador em que este estudo foi feito devido a limitações técnicas. Alguns sinais podem ser vistos nas Figuras 5.1 e 5.2.

Na Figura 5.1 pode se verificar uma parcela de um pulso gerado com 483 picos R-R, sem adição de ruídos e sem a presença de FA. Por fim, na Figura 5.2, tem-se um sinal com presença de FA com 474 picos R-R e com adição de ruídos.

A quantidade de dados gerados através dessas simulações após serem processados em janelas de 10 segundos e a distribuição destes entre conjunto de dados de treinamento e validação podem ser vistos na Tabela 5.1. Confirma-se a partir desta que os dados foram separados em 80% para o conjunto de treinamento e 20% para

Figura 5.2 – Amostra de sinal PPG simulado com Fibrilação Atrial (FA). Observa-se a clara irregularidade tanto no intervalo entre os pulsos quanto na amplitude dos picos, padrões que o modelo de aprendizado de máquina visa detectar.



teste. Além disso, pode-se aferir que a distribuição de cada classe dentro do conjunto de teste e validação se manteve, contendo aproximadamente 80% dos casos classificados como RS e os outros 20% como FA. Os valores estatísticos como média e desvio padrão também se mantiveram, indicando que os dados foram corretamente divididos e distribuídos entre os conjuntos.

Tabela 5.1 – Resumo estatístico do conjunto de dados processado.

Característica	Conjunto de Treino	Conjunto de Teste
Número de Amostras	993.568	246.756
Dimensão das Características	(1000, 2)	(1000, 2)
Distribuição de Classes		
Amostras - Classe 0	805.320 (81,05%)	199.208 (80,73%)
Amostras - Classe 1	188.248 (18,95%)	47.548 (19,27%)
Estatísticas das Características		
Média	0,0004	0,0004
Desvio Padrão	7,4394	7,4965
Mínimo	-70,6987	-63,3415
Máximo	249,2027	174,5418

Após o pré-processamento dos dados e separação destes em janelas de 10 segundos, seguiu-se com o cálculo das características a serem utilizados na abordagem

clássica para cada uma destas janelas.

5.2 ANÁLISE DE CORRELAÇÃO E SELEÇÃO DE CARACTERÍSTICAS

Após a extração de um conjunto de 31 características a partir dos sinais de PPG, fez-se uma análise de correlação delas a fim de que se tivesse um melhor entendimento e até mesmo validar conceitualmente se as características selecionadas por cada método para explicar o comportamento físico eram similares, o que elevaria o grau de confiança nos métodos de seleção. O mapa de calor apresentado na Figura 5.3 apresenta a matriz de correlação, onde os valores próximos de 1 (vermelho escuro) indicam uma forte correlação positiva, valores próximos de -1 (azul escuro) indicam uma forte correlação negativa e valores próximos de 0 (cores claras) indicam ausência de correlação linear.

A inspeção visual do mapa de calor revela que realmente existem características que são altamente correlacionadas, o que é esperado, visto que muitas delas derivam de princípios fisiológicos ou matemáticos semelhantes. As seguintes correlações foram destacadas:

1. Métricas de Variabilidade do Pulso (PPI/VFC): As características de média (`ppi_mean`), desvio padrão (`ppi_std`), raiz quadrada da média das diferenças quadráticas sucessivas (RMSSD) (`ppi_rmssd`) e entropia amostral `ppi_sampen` do PPI são todas métricas do domínio do tempo da variabilidade da frequência cardíaca (VFC que é extraída do PPI), fazendo que naturalmente a intercorrelação existe. Por exemplo, tanto o desvio padrão quando a raiz quadrada da média das diferenças sucessivas ao quadrado são indicadores da variabilidade do pulso em um curto prazo.
2. Métricas de Frequência do Pulso (PPI/VFC Frequência): As características do domínio da frequência também derivadas do sinal PPI estão altamente correlacionadas, sendo elas potência espectral de baixa frequência (`ppi_lf_power`), potência espectral de alta frequência (`ppi_hf_power`) e a própria razão entre elas (`ppi_lf_hf_ratio`).
3. Características Morfológicas: As características de morfologia da onda de pulso, média e desvio padrão da amplitude e largura dos pulsos (`morph_amp_mean_norm`, `morph_amp_std_norm`, `morph_width_mean_norm`, `morph_width_std_norm`) possuem tanto correlações moderadas quando fortes entre si, indicando que a largura e amplitude do pulso estão correlacionadas.
4. Estatísticas do Sinal Bruto: As características estatísticas básicas como a média (`ppg_mean_raw`), mediana (`ppg_median_raw`) e desvio padrão (`ppg_std_raw`) do PPG mostram alta correlação.

A existência desses blocos de características com alta correlação impacta diretamente a etapa de seleção de características, pois idealmente o modelo deve ser treinado com o mínimo de redundância para não enviesá-lo e ter um consumo computacional desnecessário, mas ainda tendo o maior poder preditivo possível.

5.2.1 Conexão com os Métodos de Seleção de Características

A Tabela 5.2 apresenta os subconjuntos de características selecionados pelos métodos ANOVA F-test, MI e RFE. A análise cruzada com o mapa de calor de correlação permite uma interpretação mais profunda e rica desses resultados, permitindo algumas análises, as quais são discutidas abaixo.

Ao analisar a seleção de características, conclui-se que nenhuma foi unanimemente escolhida pelos três métodos. No entanto, pode-se analisar a alta relevância de métricas ligadas à variabilidade do pulso (PPI), com o desvio padrão do PPI sendo selecionado tanto pelo ANOVA F-test quanto pelo RFE, ressaltando sua importância.

- Como o RFE avalia as características em conjunto, selecionou tanto o desvio padrão do PPI quanto o RMSSD do PPI. Conforme o mapa de calor, essas duas métricas são altamente correlacionadas. A escolha de ambas pelo RFE sugere que, apesar da sobreposição de informação, cada uma contribui de forma significativa para o desempenho do modelo.
- A amplitude da frequência dominante e APG mínimo também foram selecionadas por dois dos três métodos (MI e RFE), indicando que múltiplas fontes de informação, como variabilidade do pulso, frequência e aceleração do sinal são importantes para a detecção correta da Fibrilação Atrial.

Cada método lida de alguma maneira diferente com as redundâncias e isso fica claro quando comparamos os resultados do MI com os do RFE para a seleção de características de PPI.

- A informação mútua, por ser um método de filtro univariado, analisa e avalia independentemente cada característica com relação à classe alvo e podemos ver que selecionou três características altamente correlacionadas (desvio padrão, RMSSD e entropia amostral do PPI). Isso se dá porque o MI analisa cada característica individualmente e como são correlacionadas, logicamente cada uma delas possui alta informação mútua com a classe, ou seja, conclui-se que o MI não considera a redundância entre elas.
- Já o Eliminação Recursiva de Característica é um método de envelope (*wrapper*) que avalia o desempenho de um modelo preditivo. Ou seja, ao selecionar o desvio padrão e o RMSSD, mas não selecionar a entropia amostral, conclui-se

que ele foi capaz de analisar e detectar que a informação contida na entropia já era representada pelas outras duas, permitindo então a sua eliminação, visto que é uma informação redundante.

- O MI foi o único método que selecionou o número de picos, a frequência dominante e a taxa de cruzamento por zero, como pode-se ver pelo mapa de calor que essas características possuem baixa correlação com as principais características relacionadas a frequência cardíaca e morfologia (características selecionadas por todos os modelos), sugere-se de que o MI é capaz de capturar relações não-lineares, sendo capaz de encontrar informações únicas ignoradas por outros métodos.
- O RFE selecionou o valor mínimo de pletismograma de aceleração e desvio padrão do PPG, que não foram escolhidas pelos métodos de filtro, indicando que essas características podem não ser as mais representativas individualmente, mas contribuem significativamente para a performance do modelo preditivo quando combinadas com as outras, trazendo, assim, informações que otimizam as fronteiras de decisão do classificador.

Conclui-se que a análise combinada do mapa de calor e dos resultados de seleção de característica demonstra que não há um conjunto exato de características que devem ser escolhidos e sim diferentes perspectivas e caminhos a serem seguidos. Os métodos de filtro conseguem identificar características que são individualmente fortes, mas podendo levar informações redundantes, já o RFE, por analisar as interações entre as características consegue descartar informações redundantes, mantendo potencialmente o conjunto de características reduzido quando comparado com os outros métodos.

Tabela 5.2 – Comparativo dos Métodos de Seleção de Características

Método de Seleção	Nº de Features	Características Selecionadas
ANOVA F-test	7	amplitude da frequência dominante, média da amplitude do pulso, curtose, VPG máximo, VPG mínimo, APG máximo e desvio padrão do PPI
Mutual Information (MI)	7	APG mínimo, APG máximo, desvio padrão do APG, média do APG, VPG máximo, a amplitude da frequência dominante e curtose
RFE	6	APG mínimo, média da largura do pulso, desvio padrão do PPI, desvio padrão do PPG, RMSSD do PPI e a amplitude da frequência dominante




Figura 5.3 – Mapa de calor da correlação de Pearson entre as características extraídas.

5.3 APRENDIZADO DE MÁQUINA

Nesta seção são apresentados os resultados obtidos a partir dos experimentos descritos na metodologia referenciando a parte de aprendizado de máquina. Primeiramente é abordada a abordagem clássica, posteriormente progredindo para os modelos de aprendizado profundo e concluindo com os resultados da otimização e tempos de inferência para o sistema embarcado.

5.3.1 Resultados da Abordagem 1: Modelo Clássico

Nesta seção, os dados referentes aos classificadores MLP e *Random Forest* foram avaliados, sendo que ainda foi utilizado o SMOTE junto do *Random Forest* em uma tentativa de diminuir o impacto do desbalanceamento das classes observado no conjunto de dados.

Na Tabela 5.3 são disponibilizadas as métricas de performance para todas as combinações testadas, permitindo uma comparação direta para a definição do modelo de referência.

Ao se analisar os resultados apresentados na Tabela 5.3, observa-se que, dentre os modelos MLP treinados, a seleção de características que apresentou melhor F1-Score (0,56) foi o ANOVA F-Test. Porém, quando se analisa o modelo *Random Forest* treinado com as características que foram selecionadas pelo RFE e com o conjunto de treinamento balanceado pelo SMOTE, observa-se que esta combinação de métodos demonstrou superioridade consistentemente em todas as métricas relevantes. Além de alcançar um F1-Score de (0,58), acima do MLP com ANOVA F-TEST, demonstrando

Tabela 5.3 – Resultados comparativos dos classificadores da abordagem clássica. O modelo *Random Forest* foi treinado com dados de treino balanceados via SMOTE.

Modelo	Método de Seleção	Acurácia	AUC	Precisão	Sensibilidade	F1
MLP	ANOVA	0,7391	0,8518	0,4141	0,8519	0,5573
	F-Test					
	RFE	0,7349	0,8532	0,4082	0,8351	0,5484
	MI	0,7012	0,8348	0,3792	0,8635	0,5270
<i>Random Forest</i>	RFE	0,8100	0,8661	0,4700	0,7700	0,5800

um melhor balanço entre precisão (0,47) e uma alta sensibilidade (0,77), também apresentou uma maior AUC (0,8661).

Com estes resultados, há um indicativo robusto de que a arquitetura de *ensemble* do *Random Forest* com o tratamento do desbalanceamento de classe (SMOTE) combinada com o método de seleção multivariado RFE, foi a mais eficaz, de tal maneira que esta arquitetura foi estabelecida como a referência da abordagem clássica para ser comparada e superada pelas arquiteturas de aprendizado profundo.

Os resultados que foram apresentados na Seção 5.3.1 foram encontrados utilizando o limiar de decisão da classificação padrão, 0,5, para classificar as saídas probabilísticas dos modelos. No entanto, em problemas médicos que possuem classes desbalanceadas, este limiar pode não ser o ponto ótimo de operação. Buscou-se aqui então descobrir o limiar ótimo para esse modelo, sendo que um limiar muito baixo pode aumentar a sensibilidade, enquanto que um alto tende a aumentar a precisão. Sendo assim, encontrou-se um compromisso em que o F1-Score é maximizado, visto que ele nada mais é que a média harmônica entre ambas características, através de uma análise de comportamento das métricas em função do limiar de decisão. A Figura 5.4 ilustra esta análise para o modelo de referência (*Random Forest* com RFE), enquanto a Figura 5.5 apresenta a mesma análise para o modelo MLP.

Através da análise de ambas as figuras percebe-se que o F1-Score máximo para os modelos clássicos é alcançado com um limiar de decisão significativamente inferior a 0,5. Ao utilizar este limiar otimizado, permite-se ajustar o modelo para um ponto operacional mais eficaz para o problema de detecção de FA, onde o equilíbrio entre a correta identificação dos casos positivos e a minimização de falsos alarmes é crucial.

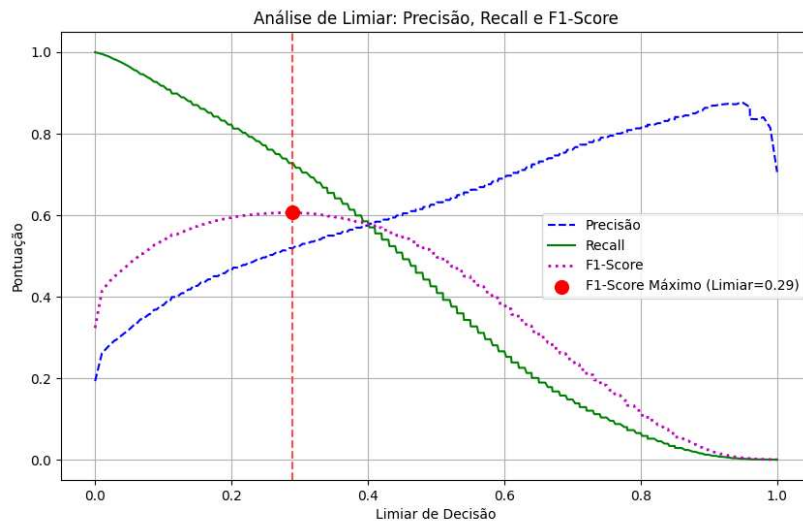


Figura 5.4 – Curvas de Precisão, Sensibilidade e F1-Score em função do limiar de decisão para o modelo *Random Forest*. O limiar ótimo, que maximiza o F1-Score, está indicado pela linha vertical tracejada.

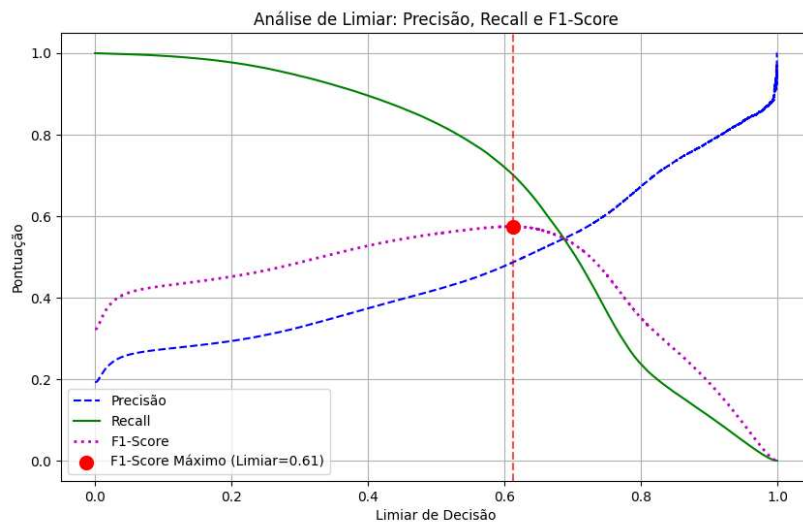


Figura 5.5 – Curvas de Precisão, Sensibilidade e F1-Score em função do limiar de decisão para o modelo MLP. A análise mostra o ponto de corte ideal para maximizar o F1-Score, ajustando o modelo para seu melhor desempenho.

5.3.2 Resultados da abordagem 2: Modelo otimizado de aprendizagem profunda com CNN

Durante a abordagem 2 investigou-se um modelo de aprendizado profundo utilizando uma CNN projetada para ter todas as camadas compatíveis com as bibliotecas disponíveis para funcionar no sistema embarcado em questão deste estudo. Na Tabela 5.4 pode-se averiguar os resultados de performance do modelo no conjunto de teste.

Neste caso, a avaliação já foi feita utilizando o limiar de decisão ótimo que maximiza o F1-Score.

Para se encontrar este limiar, utilizou-se da mesma estratégia descrita na seção anterior a Figura 5.6 demonstra que o F1-Score máximo (0,71) é alcançado em um ponto de corte de aproximadamente 0,44.

Tabela 5.4 – Resultados do classificador CNN (Abordagem 2) no conjunto de teste, utilizando o limiar de decisão otimizado (0,44).

Modelo	Acurácia	AUC	Precisão	Sensibilidade	F1-Score
CNN	0,8700	0,9232	0,6200	0,8200	0,7100

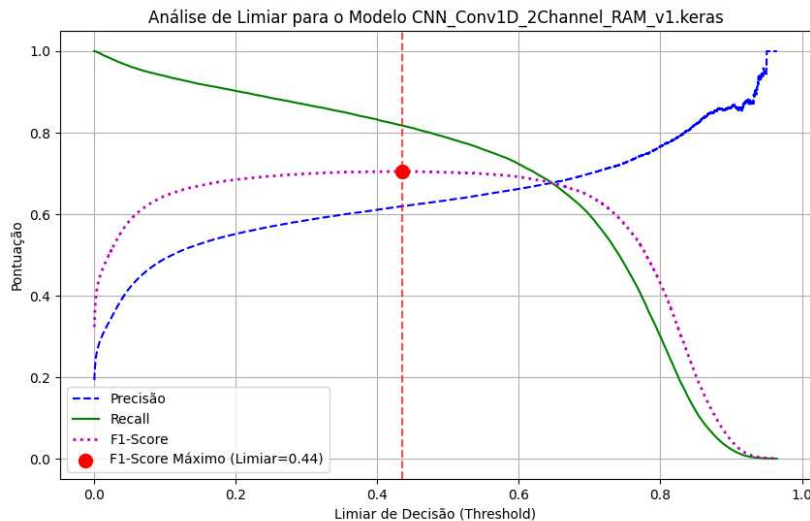


Figura 5.6 – Curvas de Precisão, Sensibilidade e F1-Score em função do limiar de decisão para o modelo CNN

5.3.3 Resultado da abordagem 3: Arquitetura Híbrida com CNN-LSTM

A Abordagem 3, utilizando uma arquitetura híbrida CNN-LSTM, foi investigada para se estabelecer a referência como melhor performance teórica, vista que a biblioteca do microcontrolador em questão não suporta a parte LSTM. Diferentes artigos utilizaram também essa arquitetura fortalecendo sua escolha como teto teórico de performance (PETMEZAS et al., 2021) (KUDO et al., 2023). Os resultados deste modelo são apresentados na Tabela 5.5.

Tabela 5.5 – Resultados do classificador híbrido CNN-LSTM (Abordagem 3) no conjunto de teste, utilizando o limiar de decisão otimizado (0,45).

Modelo	Acurácia	AUC	Precisão	Sensibilidade	F1-Score
CNN-LSTM	0,8900	0,9343	0,6700	0,8400	0,7400

De forma análoga às outras abordagens, a performance final do modelo também foi otimizada através da calibração do limiar de decisão. A Figura 5.7 mostra novamente que o melhor limiar é diferente do padrão e que o valor que maximiza o F1-Score (0,74) é 0,45. Esta performance representa o limite superior de desempenho esperado para a abordagem de aprendizado profundo neste estudo.

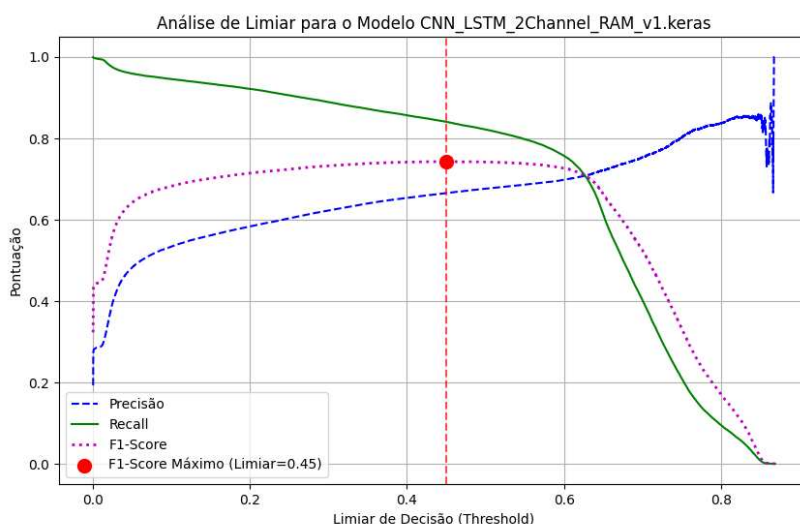


Figura 5.7 – Curvas de Precisão, Sensibilidade e F1-Score em função do limiar de decisão para o modelo híbrido CNN-LSTM.

5.4 RESULTADOS DA OTIMIZAÇÃO DO MODELO PARA AMBIENTE EMBARCADO

Nesta seção os resultados de otimização do modelo de maior performance são analisados comparando tanto a conversão para float 16-bits e inteiro 8-bits. Embora o CNN-LSTM seja incompatível com a biblioteca do microcontrolador utilizado, estes resultados de quantização são fundamentais para que seja feita a definição de qual estratégia de quantização será escolhida.

5.4.1 Análise da Quantização para Inteiros com 8-bits

A primeira técnica de otimização explorada foi a quantização pós treinamento para inteiros de 8-bits e sequencialmente também fez-se a quantização para inteiros de 8-bits juntamente do QAT. A Tabela 5.6 apresenta a comparação direta entre a performance do modelo Keras original em com float 32-bits e sua versão convertida para TFLite com inteiro 8-bits sem e a Tabela 5.7 com QAT.

Os dados mostram que a quantização para inteiros de 8-bits sem QAT resultou em uma perda de performance severa em todas as métricas, com AUC caindo 21% no geral e a precisão caindo 45%, a sensibilidade caindo 64% e o F1-Score caindo 55%

Tabela 5.6 – Análise de Perda de Performance com Quantização INT8.

Métrica	Modelo Original (float32)	Modelo TFLite (int8)	Análise da Perda
AUC	0,934	0,7390	Queda de 19.5%
Precisão (FA)	0,67	0,37	Queda de 30%
Sensibilidade (FA)	0,84	0,30	Queda de 54%
F1-Score (FA)	0,74	0,33	Queda de 41%
Tamanho do Arquivo	~168 KB	~59 KB	Queda de 64.8%

Tabela 5.7 – Análise de Perda de Performance com Quantização QAT INT8.

Métrica	Modelo Original (float32)	Modelo TFLite (int8)	Análise da Perda
AUC	0,934	0,8125	Queda de 12.15%
Precisão (FA)	0,67	0,58	Queda de 9%
Sensibilidade (FA)	0,84	0,13	Queda de 71%
F1-Score (FA)	0,74	0,21	Queda de 53%
Tamanho do Arquivo	~168 KB	~55 KB	Queda de 67%

para a classificação de FA. Pode-se concluir então que o modelo agora só detecta 30% dos casos existentes de presença da FA e além disso só acerta 37% desses casos tornando inviável a utilização do modelo para fins práticos quando quantizado para 8-bits.

5.4.2 Análise da Conversão para ponto flutuante com 16-bits

Por outro lado, ao converter-se o modelo para TFLite utilizando a otimização para ponto flutuante 16-bits não se observou degradação significativa dos resultados como pode ser visto na Tabela 5.8.

Tabela 5.8 – Resultados da Otimização com Conversão para Float 16-bits.

Métrica	Modelo Original (float32)	Modelo TFLite (float16)	Alteração
AUC (Teste)	0,934	0,923	Queda 1.1%
Precisão (FA)	0,67	0,66	Queda de 1%
Sensibilidade (FA)	0,84	0,71	Queda de 13%
F1-Score (FA)	0,74	0,69	Queda de 5%
Tamanho do Arquivo	~168 KB	~73 KB	Queda de 56%

A conversão para ponto flutuante com 16-bits demonstrou ser a melhor opção para embarcar o modelo sem precisar recorrer a muitos esforços, apresentando uma redução de 88% do consumo de memória *flash*, mas sem alterar a AUC, garantindo então que o modelo ainda tem a mesma capacidade de distinguir as classes independentemente do limiar escolhido e a F1-Score com perda de 5% demonstra que o compromisso entre sensibilidade e precisão ainda se mantém apesar de ter perdas

na performance, mas garantindo que o modelo tenha boa capacidade de detectar a presença de FA e quando detecta, acerta na maioria das vezes.

5.5 RESULTADOS DA PERFORMANCE EMBARCADA

Para analisar e validar a viabilidade de utilizar o modelo estudado para detecção de FA em um relógio inteligente, embarcou-se o modelo original com ponto flutuante com 32-bits e a intenção era a de também embarcar o modelo convertido para ponto flutuante com 16-bits, no entanto, o microcontrolador escolhido (STM32L4R5ZI) não possui *half-precision* e por este motivo não foi possível embarcar o modelo convertido. A Tabela 5.9 resume as métricas de custo computacional observadas durante a execução.

Tabela 5.9 – Métricas de Performance do Modelo CNN (*float* 32-bits) no STM32L4R5ZI

Métrica	Valor Observado
Clock do Sistema	120 MHz
Tempo Médio de Inferência (1000 amostras)	1279,50 ms
Desvio Padrão da Inferência	0,00074 ms
Contagem Média de Ciclos de Clock	153.539.899
Uso de Memória Flash (Firmware Total)	156.63 KB
Uso de Memória RAM (Pico para Ativações)	~193 KB

A média do tempo de inferência de 1000 amostras no microcontrolador é de 1,27950 segundos, apesar de funcional, impossibilita a utilização do modelo nessa configuração (sem otimizações) em tempo real. Aqui pode-se perceber o custo computacional de executar um modelo de aprendizado profundo com 12.1 milhões de operações de multiplicação-adição (MACC) em ponto flutuante em um Cortex-M4, ou seja, para fazer uma única inferência, o microcontrolador precisa executar 12.1 milhões de operações de multiplicação e adição. Apesar disso, pode-se observar a consistência nos tempos medidos de inferência, visto que o desvio padrão é inferior a 1 microssegundo, sendo então uma performance extremamente determinística. Este resultado de referência é crucial, pois estabelece a necessidade de otimizações adicionais, para aplicações que exijam latência menor ou monitoramento em tempo real mais frequente. Para se utilizar esse modelo como está, seria necessário fazer as inferências sempre em janelas não deslizantes ou deslizantes com passo maior que 1.28 segundos.

5.6 ANÁLISE COMPARATIVA E CONCLUSÃO DOS RESULTADOS

Com os resultados de todas as abordagens consolidados, uma análise comparativa pode ser realizada. A capacidade de discriminação geral de cada classificador pode ser facilmente analisada através da comparação das suas curvas ROC. A Figura 5.8 apresenta as curvas ROC para o modelo RF, CNN e CNN-LSTM, plotadas sobre o

mesmo conjunto de teste. A área sob a curva (AUC), indicada na legenda, serve como uma métrica agregada da performance em todos os limiares de decisão.

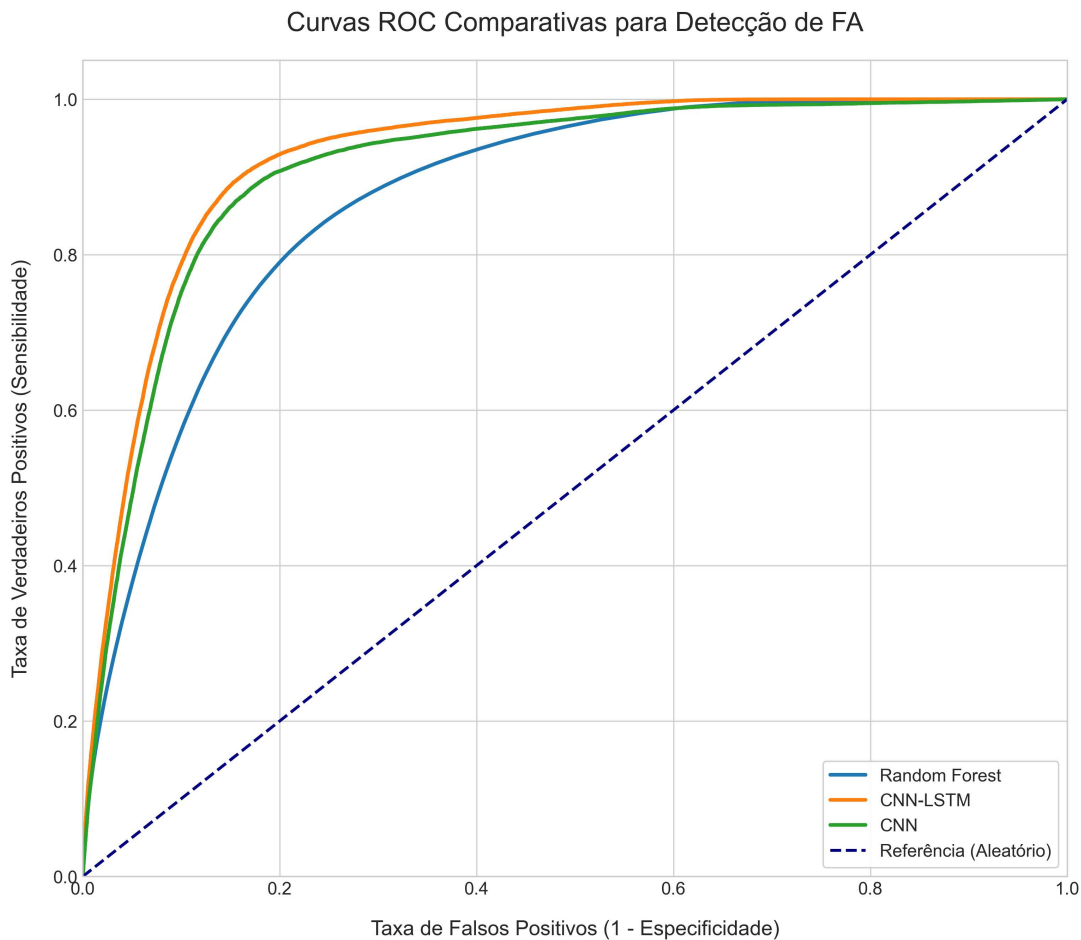


Figura 5.8 – Comparativo das curvas ROC e seus respectivos valores de AUC para os melhores modelos de cada abordagem no conjunto de teste.

Através da análise visual da Figura 5.8 já fica evidente que os métodos de aprendizado profundo são superiores ao RF, visto que as curvas ROC destes se posicionam mais próximas ao canto superior esquerdo, o que indica um melhor equilíbrio entre alta sensibilidade e alta especificidade em comparação com o modelo de referência clássico.

A Tabela 5.10 resume numericamente a performance dos melhores modelos de cada abordagem, todos eles sendo avaliados em seus respectivos limiares já otimizados.

Primeiramente, observa-se que a Abordagem 2 (CNN), superou a referência da abordagem clássica em todas as métricas, alcançando um F1-Score de 0,71 em comparação com os 0,58 do *Random Forest*. Este resultado valida a hipótese de que um modelo de aprendizado profundo pode extrair representações mais eficazes do sinal PPG do que as extraídas pela engenharia de características manuais.

Tabela 5.10 – Comparação final de performance entre a referência e os modelos de aprendizado profundo

Métrica	Abordagem 1 (Referência <i>Random Forest</i>)	Abordagem 2 (CNN)	Abordagem 3 (CNN-LSTM)
AUC	0,8661	0,9232	0,9343
Sensibilidade	0,7700	0,8200	0,8400
Precisão	0,4700	0,6200	0,6700
F1-Score	0,5800	0,7100	0,7400

Adicionalmente, a Abordagem 3 (CNN-LSTM) confirmou seu papel como um teto de performance, demonstrando isso através de todas as métricas apresentando melhores resultados. É importante ressaltar que o ganho de desempenho, no entanto, foi moderado, o que talvez não justifique o aumento de custo computacional e a incompatibilidade com o ambiente do TFLite para microcontroladores para uma aplicação prática, visto que seria necessário fazer uma implementação própria.

Por último, a avaliação do custo computacional do modelo CNN demonstrou ter sua implementação viável em um sistema embarcado ao apresentar um tempo de inferência médio e altamente estável de 1.27950 segundos no microcontrolador STM32L4R5ZI. Confirma-se que a execução é possível, no entanto, a latência inviabiliza aplicações de tempo real, motivando futuros trabalhos com otimizações de quantização, caso esse seja o intuito.

Ao comparar com o estado da arte, observa-se que trabalhos como os de (TISON et al., 2018) atingem acurácias superiores (97%), porém utilizam arquiteturas extremamente profundas ou processamento em nuvem ou dispositivos com maior poder computacional. A solução aqui proposta, embora apresente métricas ligeiramente inferiores em números absolutos, destaca-se pela complexidade reduzida, viabilizando a execução autônoma dentro das restrições severas de um microcontrolador, algo não endereçado pela maioria dos trabalhos de alta performance citados

6 CONCLUSÃO

Este trabalho abordou diferentes métodos para a detecção de Fibrilação Atrial, que é uma arritmia cardíaca com sérios riscos à saúde. Os métodos visavam ser utilizados em tecnologias acessíveis e adequadas para monitoramento contínuo, como por exemplo os relógios inteligentes. O foco da pesquisa foi no desenvolvimento e validação de uma metodologia para a criação de um modelo de aprendizado de máquina otimizado que pudesse operar em sistemas embarcados com restrição de *hardware*. Através da utilização de sinais simulados de fotopletismografia (PPG), comparou-se duas abordagens principais: a abordagem clássica contando com engenharia de características e a utilização de um modelo *Random Forest*, e o aprendizado de representação através das Redes Neurais Profundas (CNN e CNN-LSTM).

A principal contribuição do estudo se encontra na demonstração de um modelo CNN projetado com foco em eficiência computacional, oferecendo o compromisso entre viabilidade de implementação prática e alta performance preditiva. O estudo validou que, mesmo em um ambiente limitado, é possível alcançar uma capacidade de discriminação consistente para a FA, avançando no campo de soluções de monitoramento contínuos para a área da saúde e que sejam acessíveis.

6.1 RESPOSTA AOS OBJETIVOS ESPECÍFICOS

A análise dos resultados possibilita não apenas comparar as três abordagens, mas também validar diretamente os objetivos específicos propostos no início deste trabalho.

1. Validação da representatividade das características de PPI para descrever a presença de FA: O primeiro objetivo específico foi investigar se características de variabilidade do pulso (PPI), como o desvio padrão e RMSSD teriam alto poder discriminativo. A análise de seleção de características (Seção 4.4.2) confirmou esta hipótese de maneira robusta. Tanto o ANOVA F-Test quanto o RFE selecionaram características relacionadas ao PPI, o que ressalta sua importância fundamental na detecção da Fibrilação Atrial, conforme pode ser visto na Tabela 5.2.
2. Superioridade da Aprendizagem de Representação: O segundo objetivo visava confirmar se uma estratégia de aprendizado profundo teria uma performance superior à da abordagem clássica. Os resultados da Tabela 5.10 demonstram que este objetivo foi alcançado. O modelo CNN (AUC de 0,9232) e o CNN-LSTM (AUC de 0,9343) foram significativamente superiores ao modelo de referência *Random Forest* (AUC de 0,8661), além de todas as outras métricas importantes, as quais também apresentaram resultados superiores. Isso valida a capacidade

do aprendizado profundo de aprender representações mais ricas diretamente do sinal bruto do que a abordagem clássica através de seleção manual de características.

3. Viabilidade da Implementação Embarcada: O terceiro objetivo era investigar se o modelo final manteria sua alta performance após a otimização para um microcontrolador de baixo custo. Os resultados da otimização para inteiros de 8-bits demonstrou que, neste caso, há um decréscimo na performance do modelo a qual inviabiliza seu uso. No entanto, para a otimização para ponto flutuante de 16-bits houve uma compressão expressiva do modelo (-56%) com uma perda de performance mínima e aceitável (0,69), como pode ser visto na Tabela 5.8. Este resultado, combinado com a baixa latência e o consumo de memória medidos no microcontrolador (Tabela 5.9), confirma que o modelo CNN representa o melhor compromisso entre alta performance preditiva e a viabilidade de implementação para a detecção de Fibrilação Atrial em um dispositivo embarcado.

Ao se comparar os resultados com os analisados no Capítulo 3 na Tabela 3.1, observa-se que, embora alguns trabalhos apresentem métricas de acurácia ou precisão superiores aos encontrados neste trabalho, como 97%, eles utilizaram modelos complexos e não foram embarcados. A principal contribuição deste trabalho está em alcançar uma performance de discriminação elevada ($AUC > 0,92$) com um modelo CNN capaz de fazer inferências em aproximadamente 1.28 segundos. Conclui-se que esta dissertação avança no campo ao apresentar uma solução viável e simples para o monitoramento contínuo da presença de Fibrilação Atrial.

6.2 TRABALHOS FUTUROS

Com a validação da arquitetura do modelo utilizando uma CNN para a tarefa de detecção de Fibrilação Atrial em um sistema embarcado, este estudo avança na utilização de modelos simples e de fácil acesso para serem embarcados em dispositivos eletrônicos, como relógios inteligentes. Para utilização prática deste modelo, necessita-se, no entanto, que mais estudos sejam realizados, não se restringindo somente no aprimoramento da performance do modelo quando utilizando otimizações, como a conversão para float com 16-bits. Deve-se explorar também tópicos como robustez a artefatos de movimento, robustez a ruídos e melhoria de performance quando utilizando modelos mais otimizados. Os tópicos a seguir detalham as principais direções para o avanço do projeto.

1. Investigar impacto de artefatos de movimento no modelo desenvolvido. A ferramenta utilizada para gerar os dados simulados apresenta também a opção de gerar alguns tipos de artefato de movimento, então a partir dela, seria preciso

gerar mais dados para que investigue métodos de contornar a presença dos artefatos, seja através do retreinamento do modelo CNN ou através da criação de outro algoritmo de aprendizado de máquina para somente detectar os sinais com presença de artefato para que sejam descartados, como feito por (ALIAMIRI; SHEN, 2018).

2. Análise de outros tamanhos para as janelas para identificar se o tempo de inferência poderia diminuir. Para isto seria necessário a utilização de um computador com GPU de maior poder computacional, visto que neste estudo somente janelas de 10 segundos foram consideradas, pois janelas muito grandes ou muito pequenas impactavam diretamente o treinamento, ou por aumentar muito o tamanho dos dados para ser processados em uma única aferição ou por aumentar muito a quantidade de dados para serem treinados.
3. Avaliação da redução da taxa de amostragem: Investigar o impacto da redução da frequência de aquisição na acurácia do modelo. Embora este trabalho tenha mantido 100Hz para preservar a integridade morfológica fina necessária para a CNN, uma taxa menor além de possibilitar um treinamento mais rápido, visto que diminuiria a quantidade de dados a ser tratada e utilizada no treinamento, reduziria também drasticamente o consumo energético e memória, sendo vital avaliar se a perda de resolução morfológica compromete a detecção da FA.
4. Análise de Consumo Energético: Realizar a medição direta do consumo de energia durante a inferência no microcontrolador. Embora o tempo de inferência e uso de memória tenham sido validados, a autonomia da bateria é crítica para dispositivos embarcados, sendo necessário quantificar o impacto da execução contínua do modelo na vida útil do dispositivo.
5. Executar experimentos com pacientes reais fazendo a aquisição dos dados através de um PPG a ser utilizado em relógio inteligente.

REFERÊNCIAS

- ABADI, M. et al. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. In: . [S.l.: s.n.], 2016.
- AHN, J. Wave detection in acceleration plethysmogram. *Healthcare Informatics Research*, v. 21, p. 111, 04 2015.
- ALAMATSAZ, N. et al. A lightweight hybrid cnn- lstm explainable model for ecg-based arrhythmia detection. *Biomedical Signal Processing and Control*, v. 90, p. 105884, 2024. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809423013174>>.
- ALIAMIRI, A.; SHEN, Y. Deep learning based atrial fibrillation detection using wearable photoplethysmography sensor. *2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, mar. 2018.
- ALLEN, J. Photoplethysmography and its application in clinical physiological measurement. *Physiological Measurement*, v. 28, p. R1–39, 04 2007.
- AZIZ, S.; AHMED, S.; ALOUINI, M.-S. Ecg-based machine-learning algorithms for heartbeat classification. *Scientific Reports*, v. 11, n. 1, p. 18738, 2021.
- BANNER, R.; NAHSHAN, Y.; SOUDRY, D. Post training 4-bit quantization of convolutional networks for rapid-deployment. In: _____. *Proceedings of the 33rd International Conference on Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2019.
- BENGIO, Y.; DELALLEAU, O. On the expressive power of deep architectures. In: . [S.l.: s.n.], 2011. p. 1. ISBN 978-3-642-24411-7.
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, p. 5–32, 2001.
- CAMM, A. J. et al. Guidelines for the management of atrial fibrillation: The task force for the management of atrial fibrillation of the european society of cardiology (esc). *European Heart Journal*, v. 31, n. 19, p. 2369–2429, ago. 2010.
- CASTANEDA, D. et al. A review on wearable photoplethysmography sensors and their potential future applications in health care. *National Library of Medicine*, ago. 2018.
- CHAWLA, N. V. et al. Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, v. 16, p. 321–357, 2002.
- CHOLLET, F. et al. *Keras*. 2015. <<https://keras.io>>.
- CHUNG, J. et al. Empirical evaluation of gated recurrent neural networks on sequence modeling. 12 2014.
- DAVID, R. et al. Tensorflow lite micro: Embedded machine learning on tiny-ml systems. In: *Proceedings of the 4th MLSys Conference*. [S.l.: s.n.], 2021. v. 3.
- ELGENDI, M. On the analysis of fingertip photoplethysmogram signals. *Current cardiology reviews*, v. 8, p. 14–25, 02 2012.

- ELGENDI, M. Optimal signal quality index for photoplethysmogram signals. *Bioengineering*, v. 3, n. 4, 2016. ISSN 2306-5354. Disponível em: <<https://www.mdpi.com/2306-5354/3/4/21>>.
- FALLET, S. et al. Can one detect atrial fibrillation using a wrist-type photoplethysmographic device? *Medical & Biological Engineering & Computing*, v. 57, n. 2, p. 477–487, set. 2018.
- FAWAZ, H. I. et al. Deep learning for time series classification: a review. *Data mining and knowledge discovery*, Springer, v. 33, n. 4, p. 917–963, 2019.
- FAWCETT, T. An introduction to roc analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006. ISSN 0167-8655. ROC Analysis in Pattern Recognition. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S016786550500303X>>.
- GAMRAH, M. A. et al. Mechanics of the aortic notch: An acceleration hypothesis. *Journal of Medical Engineering and Technology*, v. 37, n. 4, p. 269–274, 2013.
- GODA, M.; CHARLTON, P.; BEHAR, J. Robust peak detection for photoplethysmography signal analysis. 07 2023.
- GOLDBERGER, A. L. et al. Physiobank, physiotoolkit, and physionet: Components of a new research resource for complex physiologic signals. *Circulation*, v. 101, n. 23, p. e215–e220, 2000.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.l.]: MIT press, 2016.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. Available at <<http://www.deeplearningbook.org>>.
- GOUTTE, C.; GAUSSIÉ, E. A probabilistic interpretation of precision, recall and f-score, with implication for evaluation. In: SPRINGER. *European Conference on Information Retrieval*. [S.l.], 2005. p. 345–359.
- GRAVES, A. *Supervised sequence labelling with recurrent neural networks*. [S.l.]: Springer, 2012. v. 385.
- GUPTA, S. et al. Deep learning with limited numerical precision. In: . [S.l.: s.n.], 2015.
- GUYON, I. M. et al. Gene selection for cancer classification using support vector machines. *Machine Learning*, v. 46, p. 389–422, 2002. Disponível em: <<https://api.semanticscholar.org/CorpusID:207720429>>.
- HARRIS, C. et al. Array programming with numpy. *Nature*, v. 585, p. 357–362, 09 2020.
- HINTON, G. et al. Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint*, arXiv, 07 2012.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural Computation*, v. 9, p. 1735–1780, 11 1997.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. *Neural Networks*, v. 2, n. 5, p. 359–366, 1989. ISSN 0893-6080. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0893608089900208>>.

HOSSIN, M.; M.N, S. A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining and Knowledge Management Process*, v. 5, p. 01–11, 03 2015.

IBTEHAZ, N. et al. Ppg2abp: Translating photoplethysmogram (ppg) signals to arterial blood pressure (abp) waveforms. *Bioengineering*, v. 9, n. 11, 2022. ISSN 2306-5354. Disponível em: <<https://www.mdpi.com/2306-5354/9/11/692>>.

INSTRUMENTS, N. *The Fundamentals of FFT-Based Signal Analysis and Measurement*. [S.l.], 2023.

IOFFE, S.; SZEGEDY, C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. 02 2015.

JACOB, B. et al. Quantization and training of neural networks for efficient integer-arithmetic-only inference. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2018. p. 2704–2713.

JANUARY, C. T. et al. 2014 aha/acc/hrs guideline for the management of patients with atrial fibrillation: A report of the american college of cardiology/american heart association task force on practice guidelines and the heart rhythm society. *Circulation*, v. 130, n. 23, p. 199–267, dez. 2014.

JENKINS, D.; GERRED, S. *ECG Library*. 2017. Disponível em: <<https://ecglibrary.com/ecghome.php>>. Acesso em: 27 de abril de 2024.

JOVIĆ, A.; BRKIĆ, K.; BOGUNOVIĆ, N. A review of feature selection methods with applications. In: *2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*. [S.l.: s.n.], 2015. p. 1200–1205.

JOVIĆ, A.; BRKIĆ, K.; BOGUNOVIĆ, N. A review of feature selection methods with applications. *MIPRO*, mai. 2015.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.

KIRANYAZ, S. et al. 1d convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*, Elsevier, v. 151, p. 107398, 2021.

KRISHNAMOORTHY, R. Quantizing deep convolutional networks for efficient inference: A whitepaper. In: . [S.l.: s.n.], 2018.

KUDO, S. et al. A training pipeline of an arrhythmia classifier for atrial fibrillation detection using photoplethysmography signal. *Frontiers in Physiology*, v. 14, p. 1084837, 01 2023.

LIN, M.; CHEN, Q.; YAN, S. Network in network. *arXiv preprint arXiv:1312.4400*, 2013.

MCKINNEY, W. Data structures for statistical computing in python. In: . [S.l.: s.n.], 2010. p. 56–61.

MOSCATO, S. et al. Quality assessment and morphological analysis of photoplethysmography in daily life. *Frontiers in Digital Health*, Volume 4 - 2022, 2022. ISSN 2673-253X. Disponível em: <<https://www.frontiersin.org/journals/digital-health/articles/10.3389/fdgth.2022.912353>>.

MSD MANUAL. *Fibrilação Atrial*. 2023. Disponível em: <<https://www.msdmanuals.com/pt-br/profissional/doen%C3%A7as-cardiovasculares/arritmias-card%C3%ADacas-espec%C3%ADficas/fibrila%C3%A7%C3%A3o-atrial-fa>>. Acesso em: 04 de janeiro de 2024.

PALIAKAITÈ, B. et al. Modeling of artifacts in the wrist photoplethysmogram: Application to the detection of life-threatening arrhythmias. *Biomedical Signal Processing and Control*, v. 66, p. 102421, abr. 2021.

PANDA, A.; PINISETTY, S.; ROOP, P. Runtime monitoring and statistical approaches for correlation analysis of ecg and ppg. jan. 2022.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, v. 12, 01 2012.

PETMEZAS, G. et al. Automated atrial fibrillation detection using a hybrid cnn-lstm network on imbalanced ecg datasets. *Biomedical Signal Processing and Control*, v. 63, p. 102194, 2021. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809420303323>>.

PETRENAS, A. et al. Electrocardiogram modeling during paroxysmal atrial fibrillation: application to the detection of brief episodes. *Physiological Measurement*, v. 38, n. 11, p. 2058–2080, nov. 2017.

POWERS, D. Evaluation: From precision, recall and f-factor to roc, informedness, markedness & correlation. *International Journal of Machine Learning Technology*, v. 2, p. 37–63, 01 2008.

RICHMAN, J.; MOORMAN, J. Physiological time-series analysis using approximate entropy and sample entropy. *American journal of physiology. Heart and circulatory physiology*, v. 278, p. H2039–49, 07 2000.

SEMMLOW, J. L. *Biosignal and medical image processing*. [S.l.]: CRC press, 2018.

SHAFFER, F.; GINSBERG, J. An overview of heart rate variability metrics and norms. *Frontiers in Public Health*, v. 5, p. 258, 09 2017.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.

SOLOŠENKO, A. et al. Modeling of the photoplethysmogram during atrial fibrillation. *Computers in Biology and Medicine*, dez. 2016.

SOLOŠENKO, A. et al. *Model for Simulating ECG and PPG Signals with Arrhythmia Episodes*. PhysioNet, 2022. Disponível em: <<https://physionet.org/content/ecg-ppg-simulator-arrhythmia/1.3.1/>>.

- SOLTANE, Z. et al. Optimized signal quality assessment for photoplethysmogram signals using feature selection. *Biomedical Signal Processing and Control*, Elsevier, v. 79, p. 104033, 2022.
- SRIVASTAVA, N. et al. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, v. 15, p. 1929–1958, 06 2014.
- SRIVASTAVA, N. et al. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, v. 15, n. 1, p. 1929–1958, 2014.
- STMicroelectronics. *STM32CubeMX*. 2025. <<https://www.st.com/en/development-tools/stm32cubemx.html>>. Acesso em: 4 de Outubro de 2025.
- STMicroelectronics. *Ultra-low-power with FPU Arm Cortex-M4 MCU 120 MHz with 2048 kbytes of Flash memory, USB OTG, DFSDM, CHROM-ART*. 2025. <<https://www.st.com/en/microcontrollers-microprocessors/stm32l4r5zi.html>>. Acesso em: 4 de Outubro de 2025.
- SUBOH, M. Z. et al. Analysis on four derivative waveforms of photoplethysmogram (ppg) for fiducial point detection. *Frontiers in Public Health*, Volume 10 - 2022, 2022. ISSN 2296-2565. Disponível em: <<https://www.frontiersin.org/journals/public-health/articles/10.3389/fpubh.2022.920946>>.
- Task Force of The European Society of Cardiology and The North American Society of Pacing and Electrophysiology. Heart rate variability: standards of measurement, physiological interpretation and clinical use. *Circulation*, Lippincott Williams & Wilkins, v. 93, n. 5, p. 1043–1065, 1996.
- TEAM, T. pandas development. *pandas-dev/pandas: Pandas*. Zenodo, 2020. Disponível em: <<https://doi.org/10.5281/zenodo.3509134>>.
- THARWAT, A. et al. Linear discriminant analysis: A detailed tutorial. *AI Communications*, mai. 2017.
- TISON, G. H. et al. Passive detection of atrial fibrillation using a commercially available smartwatch. *JAMA Cardiology*, v. 3, n. 5, p. 409–416, 2018.
- UNIVERSITY OF ROCHESTER MEDICAL CENTER ROCHESTER. *ECG Placement*. 2024. Disponível em: <<https://www.urmc.rochester.edu/pediatrics/cardiology-fellowship/ecg-placement.aspx>>. Acesso em: 23 de abril de 2024.
- VERGARA, J.; ESTEVEZ, P. A review of feature selection methods based on mutual information. *Neural Computing and Applications*, v. 24, 01 2014.
- VOISIN, M. et al. Ambulatory atrial fibrillation monitoring using wearable photoplethysmography with deep learning. *Medical Physics*, nov 2018.
- WARDEN, P.; SITUNAYAKE, D. *TinyML: Machine learning with TensorFlow Lite on Arduino and ultra-low-power microcontrollers*. [S.l.]: O'Reilly Media, 2019.
- WOLF, P. A. et al. Secular trends in the prevalence of atrial fibrillation: The framingham study. *American Heart Journal*, v. 131, n. 4, p. 790–795, abr. 1996.