



**UNIVERSIDADE FEDERAL DA FRONTEIRA SUL
CAMPUS DE CHAPECÓ
CURSO DE CIÊNCIA DA COMPUTAÇÃO**

EMILI WILLINGHOEFER

**MAPEAMENTO SISTEMÁTICO DA LITERATURA EM APRENDIZADO DE
MÁQUINA PARA IDENTIFICAÇÃO DE FIBRILAÇÃO ATRIAL**

**CHAPECÓ
2023**

EMILI WILLINGHOEFER

**MAPEAMENTO SISTEMÁTICO DA LITERATURA EM APRENDIZADO DE
MÁQUINA PARA IDENTIFICAÇÃO DE FIBRILAÇÃO ATRIAL**

Trabalho de conclusão de curso apresentado como requisito para obtenção do grau de Bacharel em Ciência da Computação da Universidade Federal da Fronteira Sul.
Orientador: Prof. Dr. Denio Duarte

CHAPECÓ
2023

Willinghoefer, Emili

Mapeamento Sistemático da Literatura em Aprendizado de Máquina para Identificação de Fibrilação Atrial / Emili Willinghoefer. – 2023.

54 f.: il.

Orientador: Prof. Dr. Denio Duarte.

Trabalho de conclusão de curso (graduação) – Universidade Federal da Fronteira Sul, curso de Ciência da Computação, Chapecó, SC, 2023.

1. . 2. . 3. . 4. . I. Duarte, Prof. Dr. Denio, orientador.
II. Universidade Federal da Fronteira Sul. III. Título.

© 2023

Todos os direitos autorais reservados a Emili Willinghoefer. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

E-mail: emili_willi@hotmail.com

EMILI WILLINGHOEFER

**MAPEAMENTO SISTEMÁTICO DA LITERATURA EM APRENDIZADO DE
MÁQUINA PARA IDENTIFICAÇÃO DE FIBRILAÇÃO ATRIAL**

Trabalho de conclusão de curso apresentado como requisito para obtenção do grau de Bacharel em Ciência da Computação da Universidade Federal da Fronteira Sul.

Orientador: Prof. Dr. Denio Duarte

Este trabalho de conclusão de curso foi defendido e aprovado pela banca avaliadora em:
17/02/2023

BANCA AVALIADORA

Documento assinado digitalmente
 DENIO DUARTE
Data: 24/02/2023 12:48:55-0300
Verifique em <https://verificador.iti.br>

Prof. Dr. Denio Duarte – UFFS

Documento assinado digitalmente
 ANDRESSA SEBEN
Data: 23/02/2023 19:24:08-0300
Verifique em <https://verificador.iti.br>

Prof. Ma. Andressa Sebben - UFFS

Documento assinado digitalmente
 JULYANE FELIPETTE LIMA
Data: 23/02/2023 16:00:04-0300
Verifique em <https://verificador.iti.br>

Prof. Dra. Julyane Felipette Lima - UFFS

RESUMO

A Fibrilação Atrial é uma das arritmias que mais acomete a população idosa, tendo como predisposição inúmeros fatores de riscos. Os ECGs servem para verificar a frequência dos batimentos cardíacos e se as ondas emitidas estão em um ritmo constante. Através da utilização de aprendizado de máquina com base em dados de ECGs, é possível prever e detectar sua ocorrência. Este trabalho tem como objetivo sintetizar alguns dos trabalhos presentes na literatura que utilizaram o aprendizado de máquina para detecção de doenças cardíacas. Através dos estudos encontrados na literatura, foi possível concluir que os métodos de classificação que demonstraram melhor desempenho, foram os que utilizaram aprendizado profundo.

Palavras-chave: Aprendizado de máquina. Arritmias. Fibrilação Atrial. Saúde. Predição. ECG.

ABSTRACT

Atrial Fibrillation is one of the arrhythmias that most affect the elderly population, with a predisposition of several risk factors. Electrocardiograms are used to check the frequency of heart pulses and whether the internal waves are in a steady, rhythmic rhythm. Through the use of machine learning using ECGs as data, it is possible to predict and detect its occurrence. This work aims to synthesize some of the works present in the literature that used machine learning to detect heart disease. Through the studies found in the literature, it was possible to analyze that the classification methods that believed better performances were those that used deep learning.

Keywords: Machine learning. Arrhythmias. Atrial fibrillation. Health. Prediction. ECG.

LISTA DE ILUSTRAÇÕES

Figura 1 – Gráfico ilustrativo que mostra a relação da Fibrilação atrial com idades mais avançadas.	16
Figura 2 – Imagem ilustrativa de eletrocardiograma identificado com a arritmia FA . . .	16
Figura 3 – Complexos que estimulam os potenciais de ações	20
Figura 4 – Ilustração das ondas de ECG	21
Figura 5 – Representações de ECG. Na esquerda, um ritmo normal, na direita a presença de FA.	22
Figura 6 – Irregularidades nos comprimentos das ondas P.	23
Figura 7 – Representação do funcionamento de um algoritmo tradicional.	24
Figura 8 – Representação do funcionamento de um algoritmo de aprendizado de máquina.	25
Figura 9 – Representação de fluxo de trabalho comumente utilizado no aprendizado de máquina de Trayanova, Popescu e Shade (2021)	27
Figura 10 – Figura adaptada das colunas mais relevantes apresentadas no trabalho de Wasimuddin et al. (2020)	37

LISTA DE TABELAS

Tabela 1 – Tabela de comparação de estudos de Sahoo et al. (2020) e outros autores pesquisados	32
Tabela 2 – Trabalhos que utilizaram o esquema de dados intra-pacientes	34
Tabela 3 – Trabalhos que utilizaram o esquema de dados intra-pacientes	35
Tabela 4 – Tabela contendo informações principais dos artigos revisados	46

LISTA DE ABREVIATURAS E SIGLAS

AAMI	<i>Association for the Advancement of Medical Instrumentation</i>
Acc	Acurácia
AUC	<i>Area Under Curve</i>
AUROC	Área sob a curva característica de operação do receptor
BPNN	Rede Neural de Retropropagação
CNN	Rede Neural Convolucional
CRF	Campos Aleatórios Condicionais
DCV	Doenças cardiovasculares
DL	<i>Deep Learning</i>
DNN	Rede neural profunda
ECG	Eletrocardiograma
FA	Fibrilação Atrial
FFS	Seleção de Recursos Flutuantes
HBF	Função de Base de Hermite
HOSC	Cumulantes estatísticos de alta ordem
ICA	Análise de Componentes Independentes
IWKLR	Regressão Logística de Kernel Ponderada por Importância
k-NN	<i>K-nearest neighbors</i>
LASSO	Encolhimento logístico mínimo absoluto e operador seletor
LD	Discriminantes Lineares
LDA	<i>Linear Discriminant Analysis</i>
LSTM	<i>Long short-term memory</i>
ML	<i>Machine Learning</i>
NVAF	Fibrilacao atrial não valvar
RC	Computação de Reservatório

RF	<i>Random Florest</i>
RN	Rede Neural
RNN	Rede Neural Recorrente
SA	Nó Sinoatrial
Se	Sensibilidade
SFFS	pesquisa flutuante progressiva sequencial
Sp	Especificidade
SVM	<i>Support Vector Machine</i>

SUMÁRIO

1	INTRODUÇÃO	15
2	REFERENCIAL TEÓRICO	19
2.1	CORAÇÃO	19
2.2	ARRITMIA	20
2.3	APRENDIZADO DE MÁQUINA	23
2.3.1	Métricas de avaliação no aprendizado de máquina	28
2.4	IA E MEDICINA	28
3	TRABALHOS RELACIONADOS	31
4	MAPEAMENTO SISTEMÁTICO	39
5	CONCLUSÃO	49
	REFERÊNCIAS	51

1 INTRODUÇÃO

Este trabalho tem como foco analisar estudos de aprendizado de máquina aplicados à detecção de Fibrilação Atrial (FA). A análise é feita por meio de um mapeamento sistemático dos trabalhos mais atuais encontrados na literatura científica, com o objetivo de sintetizar quais os algoritmos utilizados, o ano de pesquisa, as bases de dados, métricas utilizadas e quais os desempenhos obtidos. Com essas informações, realizar a montagem de uma tabela de fácil visualização com a síntese do que foi analisado.

Logo, com um estudo de tecnologias promissoras na área da saúde, pode-se aplicá-las em diversas situações. O intuito deste trabalho em específico é na utilização de aprendizado de máquina para detectar FA.

A FA é um tipo de arritmia, que faz parte do grande conjunto de doenças cardiovasculares (DCV). [Sahoo et al. \(2020\)](#) apontam que DCVs são as principais causas de morte em todo o mundo, representando cerca de 31% de todas as mortes globais. As DCVs resultam em batimentos irregulares chamados de arritmia, cuja gravidade pode levar à morte súbita ([WASIMUDDIN et al., 2020](#)).

Existem vários tipos de arritmias. Uma das mais frequentes na prática clínica é a Fibrilação Atrial (FA). Esse tipo de arritmia tem se tornado um importante problema para a saúde pública nas últimas duas décadas, visto que consome um grande número de recursos em saúde. Além disso, apresenta importante repercussão na qualidade de vida, devido às consequências clínicas, como fenômenos tromboembólicos e alterações cognitivas ([MAGALHÃES et al., 2016](#)).

[Magalhães et al. \(2016\)](#) citam em seu trabalho, que estudos americanos analisaram que pessoas acima de 65 anos demonstram um aumento na prevalência de FA em 0,3% ao ano, podendo ser visualizada a relação entre FA e idade na Figura [1](#).

De acordo com [Magalhães et al. \(2016\)](#), a FA se dá a partir de anormalidades eletrofisiológicas que alteram o tecido atrial, fazendo com que os impulsos elétricos fiquem anormais. Existem muitos fatores de risco clínicos, como por exemplo, hipertensão, diabetes, doenças valvares, infarto do miocárdio e insuficiência cardíaca. Além desses fatores, existem outros como obesidade, apneia obstrutiva do sono, uso de bebidas alcoólicas, histórico familiar, excesso de exercícios físicos e outros fatores genéticos.

Uma das formas de mapear características para detecção de FA é a partir do exame de ECG, o qual demonstra a atividade elétrica do coração humano. As morfologias dos sinais gerados fornecem informações sobre vários tipos de arritmia, com base em diferentes condições cardíacas. A identificação rápida e precisa da arritmia a partir do gráfico de onda do ECG pode potencialmente salvar muitas vidas e agregar muito em termos de custos de saúde em todo o mundo ([WASIMUDDIN et al., 2020](#)).

Na Figura [2](#) pode-se ver uma ilustração de um eletrocardiograma de uma pessoa com FA. Na imagem é possível identificar que os intervalos das ondas R-R não são constantes, assim

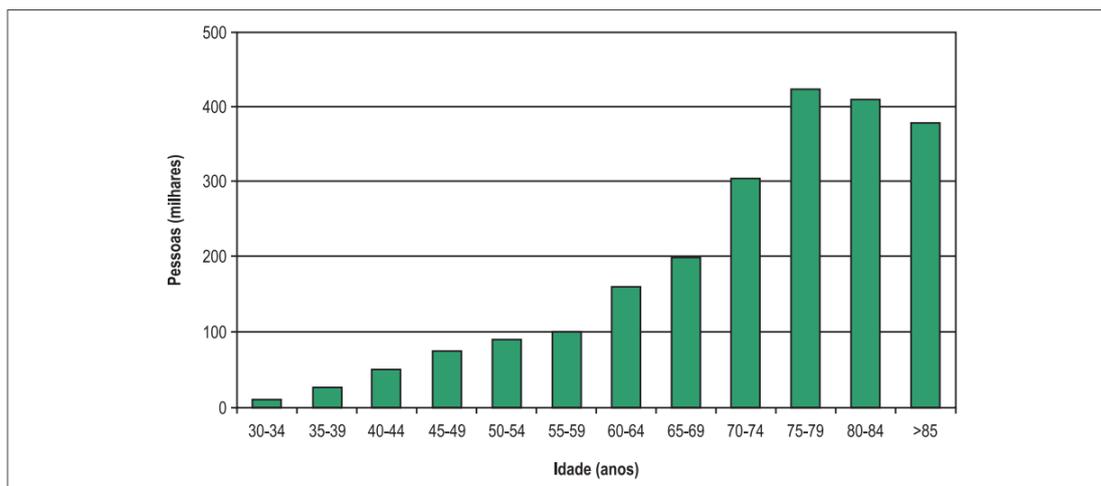


Figura 1 – Gráfico ilustrativo que mostra a relação da Fibrilação atrial com idades mais avançadas.

Fonte: [Magalhães et al. \(2016\)](#)

como é de difícil percepção o final da onda T e o início da onda P.

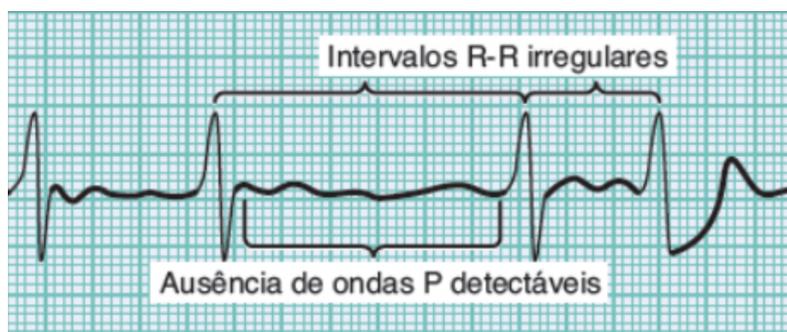


Figura 2 – Imagem ilustrativa de eletrocardiograma identificado com a arritmia FA

Fonte: [Tortora e Derrickson \(2016\)](#)

Eletrocardiogramas que contenham ritmo sinusal normal, possuem marcações definidas do início e fim de cada onda. As ondas seguem um padrão de comprimento quando o ritmo cardíaco está saudável. Logo, a partir da comparação de diversas figuras, que contenham ECG de pessoas saudáveis e de ECG de pessoas com presença de FA, pode-se diferenciar novas imagens com base nos padrões vistos.

Uma tecnologia que pode ser utilizada para detecção de padrões e reconhecimento e classificação é o aprendizado de máquina, que é uma sub-área da inteligência artificial.

A área da Inteligência Artificial (IA) vem se destacando, pois contribui bastante para a automatização de tarefas. Para [Ludermir \(2021\)](#) essa tecnologia não está somente fazendo trabalhos manuais, mas também trabalhos racionais, tarefas que requerem o uso do que se considera inteligência. Ela vem sendo empregada desde os anos 50 e está sendo cada vez mais

utilizada.

Um bom exemplo da utilização em massa dessa tecnologia é o Chat-GPT (OPENAI, 2021), sendo novo no mercado que vem sendo muito admirado pela capacidade de responder de forma rápida e certa os usuários da plataforma. O Chat-GPT faz parte da organização OpenAI. Esta última foca na pesquisa em inteligência artificial com o objetivo de desenvolver tecnologias que tornem a IA benéfica para toda a humanidade. Também desenvolve modelos de linguagem baseados em aprendizado profundo que são capazes de realizar uma ampla gama de tarefas, incluindo a geração de texto, tradução de idiomas, resposta a perguntas e geração de código. Além disso, a OpenAI trabalha em projetos que buscam solucionar desafios críticos em áreas como privacidade, segurança, transparência e ética em IA. Em resumo, a OpenAI é uma plataforma de ponta para o desenvolvimento e aplicação de tecnologias de inteligência artificial e que promete grandes revoluções na área.

Uma tecnologia que faz parte da IA é o aprendizado de máquina, que está sendo cada vez mais utilizado para solucionar inúmeros tipos de problemas, nas mais diversas áreas. O objetivo do aprendizado de máquina é criar um modelo de predição a partir de um conjunto de dados que pode explicar o modelo alvo, como por exemplo, a classificação de novas imagens de ECGs, dado que a máquina já tenha recebido exemplos para reconhecer o que são ECGs saudáveis ou não.

Assim, baseado nos padrões que os dados apresentam, um algoritmo de aprendizado de máquina generaliza o padrão destes dados para encontrar o modelo que melhor prediz como os dados geraram as características procuradas.

Por exemplo, se um conjunto de dados apresenta características do desempenho acadêmico de um estudante no primeiro ano de um curso superior e se este estudante conclui o curso no tempo previsto, o algoritmo, após a criação do modelo, pode prever, como uma certa precisão, se um estudante que finalizou o primeiro ano vai ou não concluir o curso no tempo previsto.

Existem várias formas de se aplicar o aprendizado de máquina para detecção de arritmias, visto que há uma ampla gama de métodos de classificação. Segundo Duarte e Ståhl (2019) encontrar o método que mais se encaixa com o modelo proposto é o grande desafio.

A principal contribuição é a síntese dos trabalhos mapeados da literatura, em que buscou-se publicações que implementaram várias formas de detecção de FA aplicando métodos de aprendizado de máquina. A pesquisa contemplou artigos publicados entre 2018 e 2023, buscando localizar trabalhos mais atualizados com tecnologias inovadoras. Do total de trabalhos estudados, doze foram selecionados para o mapeamento sistemático proposta.

A partir dos trabalhos encontrados, identificou-se que as aplicações de aprendizado de máquina na área são promissoras e que os métodos que implementaram o aprendizado profundo obtiveram melhores resultados.

A sequência deste trabalho é apresentada como segue. O Capítulo 2 apresenta o referencial teórico deste trabalho, descrevendo conceitos de fibrilação atrial e aprendizado de

máquina. O Capítulo 3 apresenta trabalhos relacionados que foram selecionados para auxiliar na construção do trabalho e nortear as contribuições. O Capítulo 4 apresenta os métodos de busca que foram utilizados para a obtenção de trabalhos na literatura e um resumo dos trabalhos, trazendo seus principais pontos e resultados para que pudesse ser construída uma tabela para comparação dos resultados. Por fim, o Capítulo 5 apresenta a discussão e conclusões obtidas a partir do estudo.

2 REFERENCIAL TEÓRICO

Este capítulo apresenta brevemente alguns conceitos teóricos utilizados neste trabalho. O objetivo é deixar a leitura da revisão mais autocontida. As primeiras seções apresentam aspectos ligados à saúde, mais precisamente arritmias. Em seguida, aprendizado de máquina e seus algoritmos são discutidos.

2.1 CORAÇÃO

O coração humano é composto por quatro câmaras, dois átrios que ficam nas cavidades superiores e dois ventrículos nas cavidades inferiores. O funcionamento correto do coração é receber sangue que não possui oxigênio pelo átrio direito, passar para o ventrículo direito que mandará para o pulmão. Após isso, o pulmão envia sangue oxigenado para o átrio esquerdo e o ventrículo esquerdo é responsável por enviar o sangue para todo o corpo, o que o faz trabalhar mais que o ventrículo direito, tornando-se assim, mais espesso ((TORTORA; DERRICKSON, 2016)).

O ritmo cardíaco é definido pelo seu marca-passo natural, chamado nó sinoatrial (SA), localizado no átrio direito. A partir dos potenciais impulsos gerados pelo nó SA, propagam-se ações potenciais para outros nós e fibras cardíacas ((TORTORA; DERRICKSON, 2016)).

Na Figura 3 são apresentados os complexos estimulantes presentes no coração humano, os quais geram potenciais de ações e percorrem o miocárdio, formando um ritmo cardíaco. Logo, o coração possuindo um ritmo, ele produz ciclos cardíacos. Em um ciclo, os dois átrios se contraem, enquanto os dois ventrículos relaxam, seguindo do relaxamento dos átrios e contrações dos ventrículos. Logo, Tortora e Derrickson (2016) definem que o ciclo cardíaco se dá através de sístoles (contrações) e diástoles (dilatações).

Os potenciais de ação gerados pelos nodos e fibras cardíacas geram correntes elétricas. Através de eletrodos colocados na pele, é possível captar esses impulsos. Essa captação das mudanças elétricas do coração com o objetivo de acompanhar seus batimentos é chamado de eletrocardiograma (ECG) (TORTORA; DERRICKSON, 2016)

A partir do ECG é possível reconhecer três ondas que acompanham cada batimento cardíaco. São elas:

- Onda P, que uma fração de segundo após seu início, os átrios se contraem;
- Seguido do complexo QRS, onde logo após seu início os ventrículos começam a se contrair;
- A onda T é quando os ventrículos começam a relaxar.

Quanto ao relaxamentos dos átrios, a evidência de ocorrência não fica presente no ECG, pois é mascarada pelo complexo QRS (TORTORA; DERRICKSON, 2016).

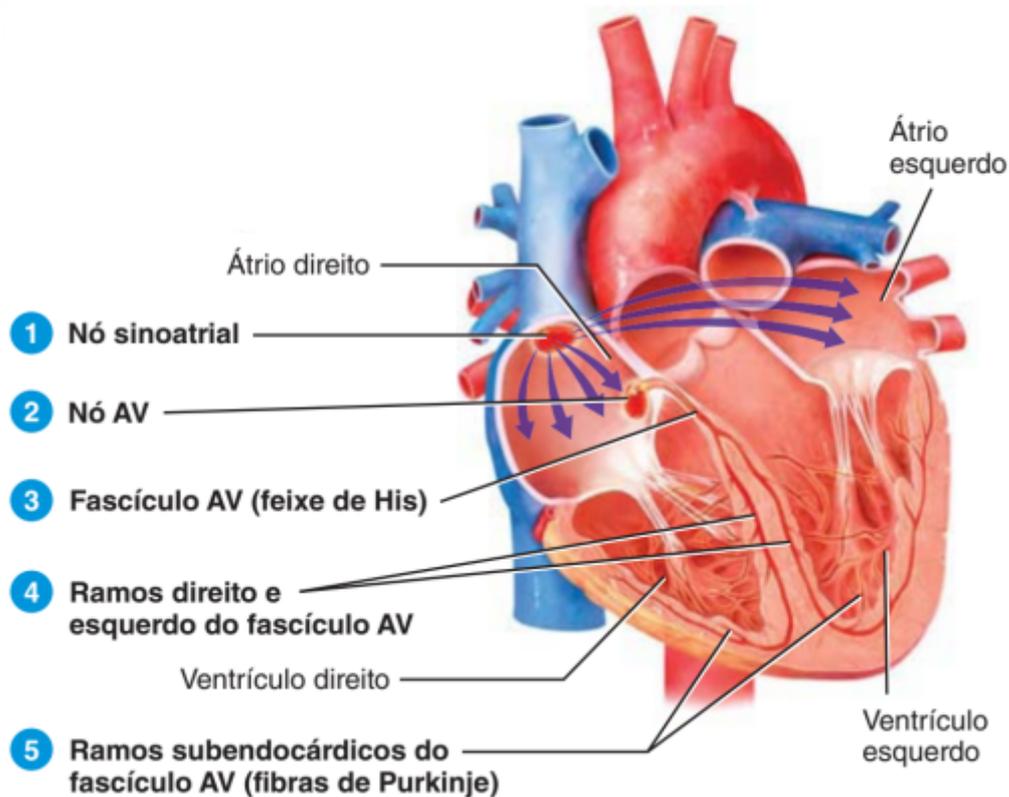


Figura 3 – Complexos que estimulam os potenciais de ações

Fonte: (TORTORA; DERRICKSON, 2016)

Na Figura 4 são apresentadas as ondas descritas acima, em suas sequências, através da representação de um eletrocardiograma normal.

Em (TORTORA; DERRICKSON, 2016) é descrito que eletrocardiogramas são essenciais para diagnósticos de ritmos cardíacos e padrões de condução anormais, além de observar pacientes que estão se recuperando de um ataque cardíaco.

2.2 ARRITMIA

Como visto na seção anterior, o coração possui um marca-passo natural, mantendo um ritmo constante de batimentos. Esse ritmo pode se elevar, ao fazer exercícios físicos, por exemplo, ou então diminuir, quando ficamos em repouso.

Quando os batimentos cardíacos ficam irregulares, com o ritmo muito rápido (taquicardia) ou muito lento (bradicardia), diz-se que ocorre uma arritmia cardíaca (ANWAR et al., 2018). Anwar et al. (2018) destacam que as arritmias podem levar à incapacidade do coração de bombear sangue, falta de ar, dor no peito, cansaço e perda de consciência. Existem vários tipos de arritmias. Algumas delas podem ser fatais e outras requerem análises e tratamentos

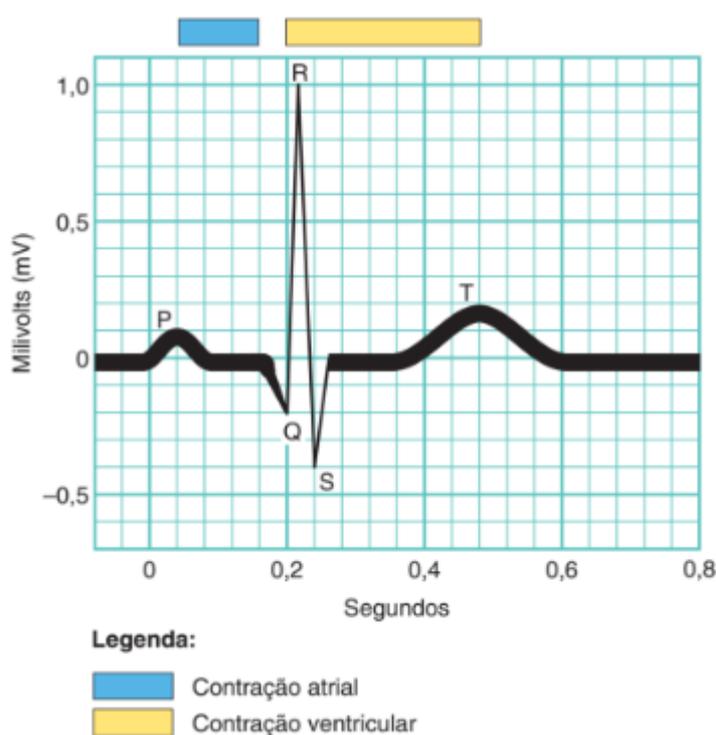


Figura 4 – Ilustração das ondas de ECG

Fonte: (TORTORA; DERRICKSON, 2016)

para evitar problemas futuros.

A fibrilação atrial (FA) representa o tipo mais comum de arritmia cardíaca observada na população em geral (LANDSTROM; DOBREV; WEHRENS, 2017). Alguns fatores que podem ocasionar a ocorrência de FA são determinantes genéticos, fatores extra-cardíacos (por exemplo, apneia do sono, obesidade, hipertensão, desequilíbrio autonômico), bem como remodelação do tecido cardíaco.

Andrade et al. (2014) detalham que alguns dos fatores mais influentes para Fibrilação Atrial são a idade e o sexo. A ocorrência desse tipo de arritmia em pessoas idosas (>60) é alta, além de que o sexo masculino possui uma predisposição de 1.5 (um ponto cinco) vezes a mais de adquirir FA. Outro fator importante que atua para predisposição é a hipertensão. Segundo Andrade et al. (2014), 14% de todos os casos de FA tem como responsável a hipertensão. Doenças cardiovasculares também possuem relações com a incidência de FA. Também a fibrilação atrial pode ser altamente prevalente são em casos de insuficiência cardíaca, cardiomiopatia hipertrófica e doença cardíaca congênita (ANDRADE et al., 2014).

Andrade et al. (2014) explicam que além das doenças cardíacas, doenças como obesidade, apneia do sono, disfunções renais crônicas, o consumo de bebidas alcoólicas e tabaco, também possuem um forte risco na obtenção de FA. Incluem-se também neste grupo as doenças crônicas, como a diabetes *mellitus* e a disfunção da tireoide, além de fatores genéticos que podem aumentar em 2 vezes mais a chance de ter FA, caso um parente de primeiro grau já tenha tido. Exercícios

físicos são aliados e podem ajudar a prevenir a incidência, desde que não sejam feitos em excesso.

Além da fibrilação atrial ser comumente presente em pessoas idosas, os números da taxa de mortalidade por AVCs em idosos vêm aumentando. A combinação das duas doenças juntas, faz com que a gravidade da ocorrência delas se torne maior e demande mais recursos (ANDRADE et al., 2014).

Os autores em (LORGA FILHO et al., 2003) também afirmam que pacientes portadores de FA possuem uma predisposição grande a ter AVC, levando em consideração a idade mais avançada, história de hipertensão arterial, diabetes e evento tromboembólico prévio.

A FA pode ser silenciosa e não apresentar sintomas, contudo, caso seja detectada através de eletrocardiogramas, ela pode ser tratada com terapias. As terapias não-invasivas incluem: restauração do ritmo sinusal, controle de frequência, prevenção das recorrências e anticoagulação. Já em terapias invasivas os tratamentos considerados são: ablação por cateter, tratamento cirúrgico e estimulação cardíaca artificial (LORGA FILHO et al., 2003).

Um das causas frequentes de FA é o aumento do volume atrial, que podem impedir os átrios de se esvaziarem adequadamente nos ventrículos ou de insuficiência ventricular com acúmulo excessivo de sangue no átrio. Com as paredes dos átrios dilatadas, as vias sanguíneas podem criar condições tanto longas como lentas, ambas predisponentes da fibrilação atrial (HALL, 2021).

Durante o episódio de fibrilação atrial, os átrios não conseguem desempenhar seus papéis com eficiência e bombear o sangue recebido. Através de um ECG, quando as ondas estão fracas e muitas delas têm polaridades opostas em qualquer momento dado, suas respostas elétricas quase que se neutralizam completamente. Assim, as ondas P, que representam o início de um ciclo cardíaco, podem não aparecer ou possuir um registro ondulado fino de voltagem muito baixa e com alta frequência. Diferente das demais ondas do ECG, que caso não haja nenhum problema nos ventrículos, aparecem normalmente.

A Figura 5 possui duas representações de ECG. À direita, um registro de FA em que as ondas estão bagunçadas e a visualização nítida das ondas P é mais difícil. À esquerda, trata-se de um eletrocardiograma de um coração saudável.

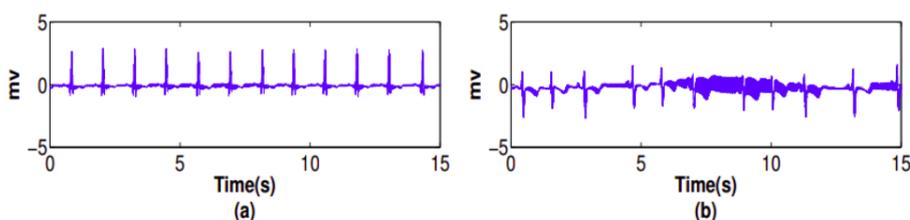


Figura 5 – Representações de ECG. Na esquerda, um ritmo normal, na direita a presença de FA.

Fonte: JUNIOR, Alfredo Costa Oliveira (2017, p. 20)

A detecção da fibrilação atrial por meio de eletrocardiogramas pode ser visualizada, de

acordo com [Hall \(2021\)](#), através da irregularidade demonstrada pelo espaçamento das ondas dos batimentos cardíacos no ECG, sendo essa uma das formas de identificação da patologia. Na Figura 6 pode-se identificar que os espaçamentos das ondas P não mantêm um padrão.



Figura 6 – Irregularidades nos comprimentos das ondas P.

Fonte: [\(HALL, 2021\)](#)

2.3 APRENDIZADO DE MÁQUINA

Na área da computação, os algoritmos são uma sequência de instruções em forma de códigos descritos em linguagem computacional, as quais podem ser interpretadas/compiladas e posteriormente executadas pelo computador.

[Duarte e Ståhl \(2019\)](#) descrevem a diferença entre algoritmos tradicionais e aprendizado de máquina. É dito que, em algoritmos tradicionais é dado para o computador uma entrada (contendo dados necessários para execução do programa) e também um programa a ser executado. A saída dependerá dos dados fornecidos ao computador como entrada e de como o programa utilizou essas informações para executar a sequência de instruções. A Figura 7 representa a ideia de um algoritmo tradicional.

Para que a máquina “aprenda” algo, é necessário ensinar. Assim como aprendemos a distinguir, por exemplo, gatos de cachorros, a máquina precisa receber essas informações para ser capaz de diferenciar a partir de características dos dados. Os algoritmos de aprendizado recebem como entrada: a saída que espera-se que a máquina consiga gerar e os dados de entrada. O computador deve, a partir dos dados, gerar por si só um modelo de instruções que consiga atender àquela saída dada ([DUARTE; STÅHL, 2019](#)). Além disso, após a criação do modelo, são inseridos novos dados de entrada para que o algoritmo gere sua saída. Na Figura 8 adaptada do trabalho dos autores ([DUARTE; STÅHL, 2019](#)) é possível visualizar o fluxo descrito acima.

O processo de aprendizado de máquina ocorre em quatro etapas ([DUARTE; STÅHL, 2019](#)), em que a primeira é a obtenção do conjunto de treinamento de dados, seguido da escolha e implementação de um aprendizado para os dados de treinamento, a terceira etapa é a construção do modelo e por fim, a avaliação do modelo, dado novas entradas de testes para verificar o desempenho do modelo gerado.

Um dos grandes desafios do aprendizado de máquina é a escolha de qual algoritmo utilizar. Existem diversos algoritmos que podem ser utilizados no aprendizado de máquina, e,

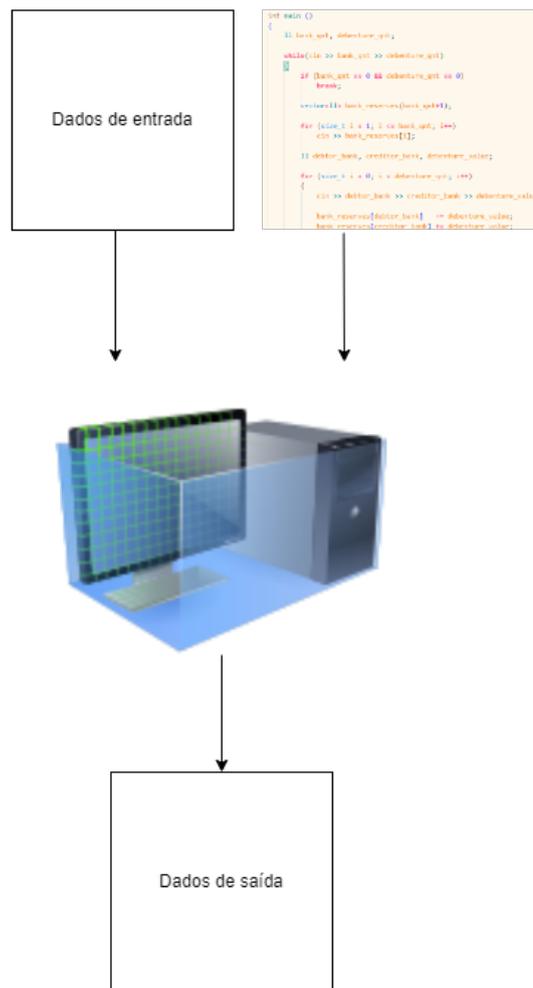


Figura 7 – Representação do funcionamento de um algoritmo tradicional.

Fonte: Adaptado de Duarte e Ståhl (2019)

esse conjunto de possibilidades de qual algoritmo utilizar é chamado de espaço de hipóteses. Além disso, Duarte e Ståhl (2019) dividem os componentes de aprendizado em (i) qual o tipo de aprendizagem de interesse, (ii) a avaliação dos resultados previstos obtidos a partir do modelo escolhido e (iii) e se o aprendizado alcançou um bom desempenho.

Existem diferentes formas de se aplicar o ML. A Figura 9 apresenta um fluxo comum. Uma delas é o aprendizado supervisionado, que de acordo com (BZDOK; KRZYWINSKI; ALTMAN, 2018) utiliza dados de treinamento rotulados. Rótulos são características de um determinado conjunto de dados que auxiliarão o algoritmo na classificação. Ou seja, para treinar um algoritmo para, por exemplo, reconhecer se dada uma imagem é um gato ou um cachorro, são passadas características que diferem os dois animais, rotações de quais características pertencem ao gato e quais ao cachorro. Assim, quando o algoritmo receber uma imagem, conseguirá identificar pelos padrões apresentados à qual espécie o animal pertence.

No aprendizado supervisionado, Duarte e Ståhl (2019) explicam que, dependendo do tipo

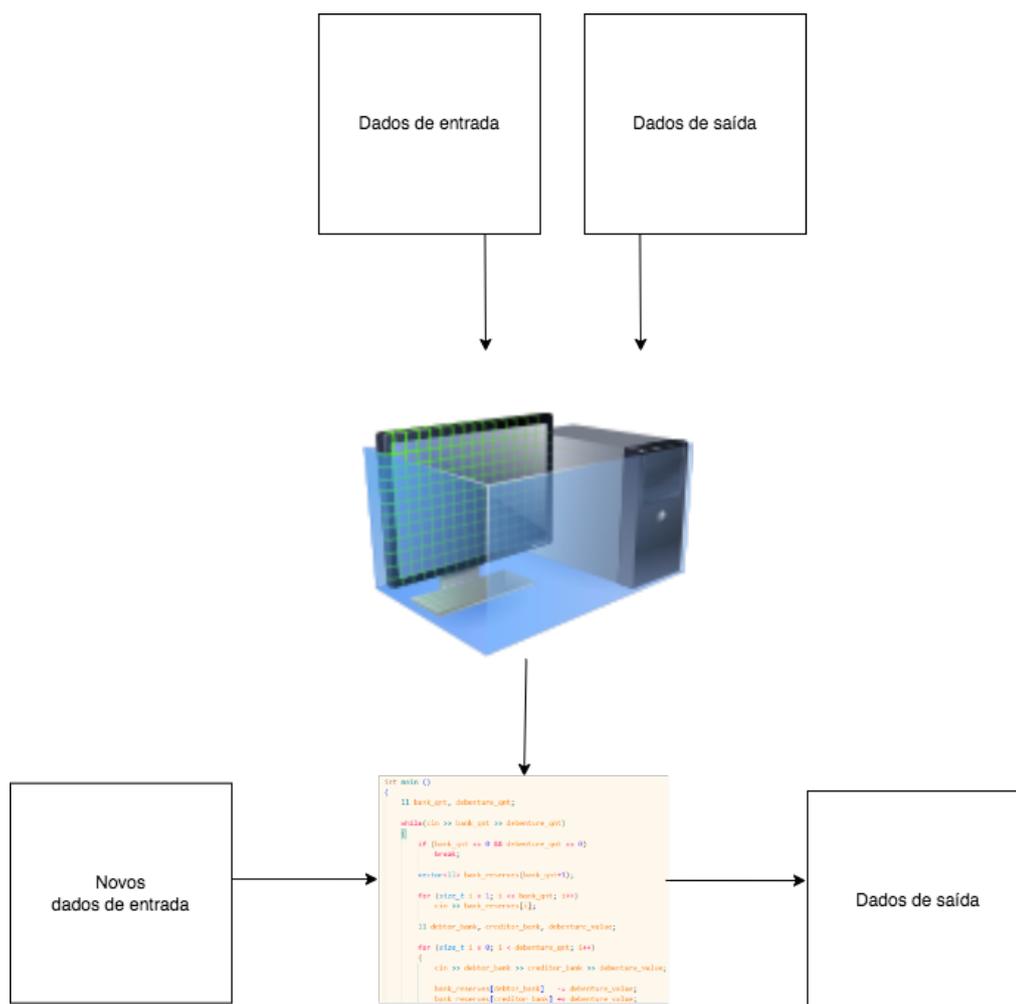


Figura 8 – Representação do funcionamento de um algoritmo de aprendizado de máquina.

Fonte: Adaptado de [Duarte e Ståhl \(2019\)](#)

de rótulo, pode-se aplicar algoritmos de classificação ou regressão. Caso o rótulo seja composto por valores numéricos, é possível aplicar algoritmos de regressão. Se o rótulo for descritivo, o problema se tornará de classificação. Também é possível que valores numéricos sejam revistos e repassados para descritivos. [Duarte e Ståhl \(2019\)](#) afirmam que todos os problemas de regressão podem ser transformados em problemas de classificação. Logo, a análise dos dados é importante para identificar qual algoritmo utilizar.

Ainda segundo os autores, um algoritmo de regressão tem como saídas previstas variáveis de destino que possuem valores contínuos. Um dos algoritmos de regressão mais conhecido é o de regressão linear. O algoritmo utiliza valores anteriores calculados para prever os possíveis valores futuros. Segundo [\(SANTOS, 2018\)](#), é possível obter respostas contínuas em relação aos valores obtidos com o valor que se almeja. Um exemplo comum para explicar a regressão é imaginar um gráfico de duas dimensões que tenham pontos dispersos; Ao utilizar o modelo de regressão, é traçada uma reta entre os pontos encontrados, onde os próximos pontos (que seriam nossos valores esperados) devem ficar próximos da reta. Porém, segundo [\(TRAYANOVA;](#)

POPESCU; SHADE, 2021), em conjuntos de dados muito grandes, se perde a praticidade desse algoritmo.

Já algoritmos de classificação analisam os resultados de modo distinto em relação aos de regressão. Um exemplo deste tipo de algoritmo é a máquina de vetor suporte (*Support Vector Machine* - SVM), que pode ser usada para conjuntos de dados de alta dimensão. Tem como princípio obter um subconjunto de pontos que, de acordo com (TRAYANOVA; POPESCU; SHADE, 2021), calcule a distância entre o limite de decisão e o ponto mais próximo dos dados.

O algoritmo de K-Vizinhos mais próximos (KNN) tem como base usar um sistema de votação, onde, por exemplo a maioria dos k-vizinhos mais próximos estimem um valor para um novo ponto (TRAYANOVA; POPESCU; SHADE, 2021).

Outra abordagem supervisionada são os algoritmos de árvores de decisão, que são usados para resolver problemas de classificação. Duarte e Ståhl (2019) explicam que o modelo é baseado em regras de decisão implementadas nos nós de uma árvore, em que cada nó representa um teste a ser realizado, e dependendo do resultado do teste, é possível acessar a um nó filho. O teste é repetido até atingir um nó folha, quando encontra-se a classe.

O algoritmo de florestas aleatórias (*Random Forest* - RF) utiliza várias árvores de decisão para retornar saídas integradas (TRAYANOVA; POPESCU; SHADE, 2021). Gomes (2022) explica que as árvores com aumento de gradiente geram diversas árvores de decisão sequencialmente. A cada geração, a árvore atual corrige os erros resultantes da árvore anterior gerada. No final, é dada uma combinação dos resultados de todas as árvores geradas.

Algoritmos de redes neurais (RN) simples podem ser utilizados no aprendizado supervisionado também. Gomes (2022) explica de forma simplificada que redes neurais com três camadas podem ser usadas para classificar dados ou então encontrar, em problemas de regressão, as relações entre as variáveis. Segundo IBM (2020), as redes neurais baseiam-se em nós, ou então neurônios artificiais, que são organizados por camadas, sendo todos os nós conectados, formando assim uma rede. Esses nós possuem um peso e um limite atribuído, sendo ativados quando o valor de saída é maior que o valor limite estimado, fazendo com que seja enviado os dados para a próxima camada. Se o valor não chegar a ultrapassar o limite, o repasse de dados para outra camada não é feito.

Em Ranstam e Cook (2018) é explicada a regressão LASSO (Mínimo Encolhimento Absoluto e Operador de Seleção) que seleciona as variáveis para o modelo de regressão através de um método de encolhimento. Esse algoritmo tem como objetivo a identificação de variáveis e os coeficientes correspondentes de regressão que levam a um modelo que minimiza o erro de previsão.

Dentro do grande campo de aprendizado de máquina tem-se os aprendizados profundos ou *Deep Learning* (DL). Esse tipo de aprendizado define que a própria máquina aprende várias representações internas de dados brutos para realizar regressão ou classificação (DUARTE; STÅHL, 2019).

Os modelos de aprendizado profundo estruturados são em camadas. Cada camada

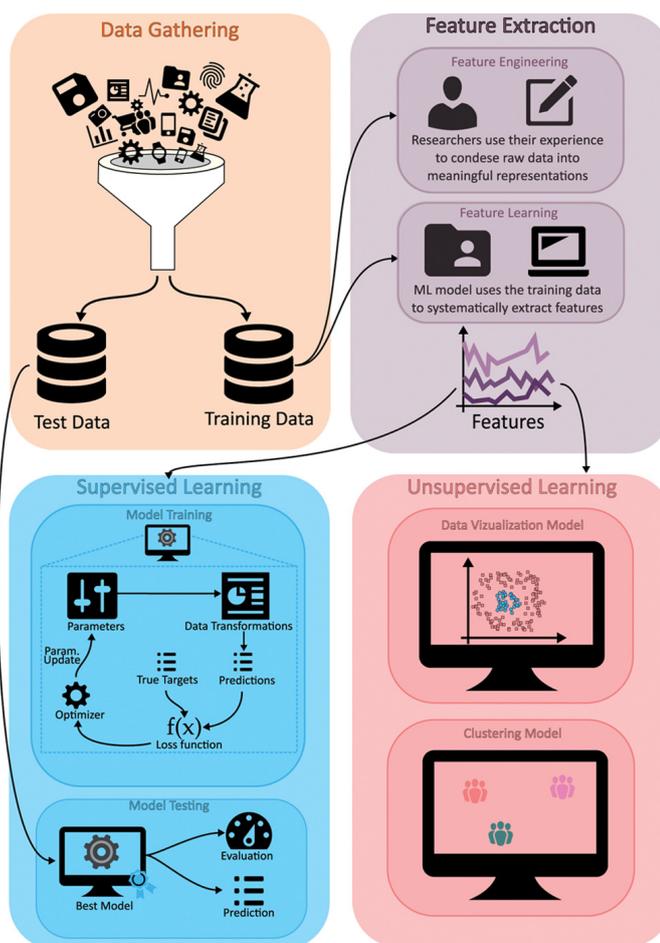


Figura 9 – Representação de fluxo de trabalho comumente utilizado no aprendizado de máquina de [Trayanova, Popescu e Shade \(2021\)](#)

Fonte: [Trayanova, Popescu e Shade \(2021\)](#)

aprende um conjunto de representações de difícil compreensão humana. Nas primeiras camadas o aprendizado é iniciado com combinações simples, tornando-se mais complexas ao longo do processo. Em aprendizados utilizando um conjunto de imagens, por exemplo, geralmente inicia-se aprendendo a detectar bordas e traços e então avança-se para os reconhecimentos mais complexos.

As redes neurais são algoritmos que fazem parte do aprendizado profundo. Além dela existem outros como as Redes Neurais Convolucionais (*convolutional neural network* - CNN). [Duarte e Ståhl \(2019\)](#) apresentam que a ideia principal da arquitetura das CNNs é que, por exemplo, dada uma imagem, ela pode ser dividida em inúmeros pedaços e a ordem com que o algoritmo vai processar, não é relevante. Logo, as CNNs conseguem detectar padrões simples nas suas primeiras camadas de treinamento. A capacidade de reconhecimento tende a aumentar a cada nova camada gerada.

A rede neural recorrente (*recurrent neural network* - RNN) é um dos tipo de rede neural artificial cuja sua diferença é a ligação com seus nós (neurônios). As RNNs criam ligações

cíclicas entre os neurônios, permitindo que a rede mantenha um estado interno para que atue em informações da entrada anterior para a rede, exibindo assim um comportamento temporal dinâmico (DUARTE; STÄHL, 2019).

Entretanto, as RNNs possuem alguns problemas em suas retro-propagações, e uma das formas de contornar o problema é utilizando o algoritmo de memória de longo curto prazo (*Long Short Term Memory* - LSTM). A arquitetura da LSTM é similar à das RNNs padrões, porém, em sua estrutura, existem células que são capazes de "lembrar" processamentos anteriores. Em suas células são mantidas as informações e as manipulações de memória são feitas pelos portões, que são três: (i) portão de esquecimento - verifica se a informação armazenada na célula é relevante, se for, mantém, caso não, esquece; (ii) portão de entrada, em que são adicionadas as informações úteis para o estado da célula; e (iii) portão de saída, que é responsável por extrair informações úteis do estado atual da célula e apresentá-las na saída (ACADEMY, 2022).

2.3.1 Métricas de avaliação no aprendizado de máquina

As métricas de avaliação ajudam na verificação do desempenho do algoritmo, quanto ao resultado obtido. Através das métricas é possível mensurar a qualidade dos resultados.

Uma das métricas é a acurácia. (Guimarães, Meireles e Almeida (2019) explica a acurácia como sendo a porcentagem dos exemplos de teste que são corretamente classificados pelo algoritmo em relação ao total de exemplos das classes a serem classificadas.

Outro conceito utilizado é a precisão. Essa medida é calculada a partir do percentual de instâncias classificadas corretamente como positivas dentre todas as instâncias que foram classificadas como positivas.

Uma métrica muito utilizada para auxiliar na identificação de todos os pontos de cortes possíveis em dados de treinamento é a curva ROC (MEURER; TOLLES, 2017). A curva ROC (característica de operação do receptor) é um gráfico 2D, que tem como seus eixos a sensibilidade (na vertical do gráfico) e 1 menos a especificidade (na horizontal do gráfico).

A partir da curva ROC, (Meurer e Tolles (2017) descreve outra métrica: a AUROC/AUC ou então área sob a curva ROC. Essa métrica consegue mensurar a probabilidade de que o modelo classifique corretamente os dados esperados.

2.4 IA E MEDICINA

De acordo com (Lobo (2017) computadores podem armazenar e recuperar dados sobre imagens, através de eletrocardiogramas e dados de dispositivos vestíveis/corporais (*wearable devices*), além de outros exames por imagens, e a partir disso, gerar probabilidades de diagnóstico baseadas em algoritmos de decisão estabelecidos e que podem se aprimorar através dos resultados obtidos.

Além da obtenção de dados através de *wearable devices*, para a aplicação de algoritmos inteligentes, esses podem ser adquiridos diretamente de prontuários médicos eletrônicos, ou por meio da digitação de informações de anamnese, de exame clínico do paciente, exames complementares, evolução da enfermidade e medicamentos prescritos. E esses dados, em conjunto com algoritmos definidos, podem ser atualizados a partir da análise dos resultados obtidos para propor diagnósticos diferenciais de enfermidades, assim como suas probabilidades de ocorrência (LOBO, 2017).

O uso de dispositivos vestíveis como, por exemplo, *smartwatches*, celulares com sensores capazes de medir a frequência cardíaca, dentre outros, já é uma realidade e está presente no dia a dia das pessoas. Esses dispositivos em Lobo (2017) podem gerar ações automatizadas, como por exemplo, dar uma descarga elétrica de um desfibrilador subcutâneo. Existindo também a possibilidade de monitoramento e envio desses dados para os médicos responsáveis.

O desenvolvimento de sistemas computadorizados que apoiem diagnósticos clínicos, existe há mais de 50 anos (LOBO, 2017). A utilização da tecnologia em ambientes clínicos pode resultar em ganhos, pois com modelos definidos, treinados e validados, os diagnósticos podem ser feitos mais rapidamente, tendo uma menor margem de erro, ganhando-se tempo para investir em outras atividades. Na saúde, o tempo é crucial para salvar vidas, e o uso de tecnologias avançadas nesse meio vem ganhando cada vez mais espaço.

3 TRABALHOS RELACIONADOS

Este capítulo apresenta alguns trabalhos similares ao mapeamento sistemático proposto aqui. Os artigos relacionados foram encontrados através da plataforma da pubmed, utilizando a *string* de busca contendo as palavras “*Survey*” OR “*Review*” AND “*Machine Learning*” AND “*Atrial Fibrillation*”. Os trabalhos foram selecionados através do critério de relevância - Quantas citações possuíam, pelo título e ano de publicação, até 2020. Foram selecionados três trabalhos relevantes que utilizam a revisão da literatura atual com foco na classificação e extração das partes que compõem eletrocardiogramas.

Em (SAHOO et al., 2020), foi realizado um estudo apresentando as técnicas de aprendizado de máquina na interpretação de eletrocardiogramas, cujo o foco foi identificar com precisão a detecção de picos R, complexo QRS e a classificação de arritmias através de ECGs. Os autores utilizaram uma busca sistemática de publicações entre 1999 até 2019 com uma *string* de busca com diferentes palavras-chave, nas bases de dados da IEEE, Pubmed e Science direct. O banco de dados utilizado para o estudo foi o MIT-BIH, onde foram selecionados 47 gravações de ECGs.

Sahoo et al. (2020) utilizou vinte e sete trabalhos, incluindo um de seus estudos na área, que possuíam uma metodologia similar a proposta em seu trabalho. A Tabela 1 apresenta a comparação dos trabalhos encontrados que utilizaram métodos diferentes do proposto por Sahoo et al. (2020) em outro trabalho aplicado na área.

A primeira coluna da tabela contém as referências dos autores utilizados para comparação. A segunda coluna contém as características que os classificadores apresentados na terceira coluna utilizaram. Os tipos de batimentos, corresponde a quantos batimentos cada método conseguiu identificar de acordo com sua base de dados. Por fim, a última coluna representa os resultados obtidos, utilizando a métrica de acurácia.

Logo, os autores concluem que os métodos padrões como Redes neurais e SVMs atenderam bem às expectativas e alcançaram uma precisão superior a 99%, utilizando recursos de morfologia e tempo de frequência. Contudo, neste estudo, todos os trabalhos relacionados coletados pelos autores utilizaram a mesma base de dados (MIT-BIH) para obter os eletrocardiogramas (SAHOO et al., 2020).

Em Luz et al. (2016) foram levantados estudos existentes na literatura sobre os métodos de classificação de arritmias baseados em ECG, discutindo as principais técnicas para classificação, trazendo a tona também os paradigmas referentes a intra-pacientes e inter-pacientes. Além disso, discutem também sobre as bases de banco de dados e dos problemas das avaliações dos métodos atuais vistos na literatura.

A avaliação dos problemas encontrados nos métodos é o diferencial do trabalho de Luz et al. (2016), além de trazer uma revisão mais atualizada da literatura, até 2016, ano de publicação do trabalho. Os bancos de dados mencionados no trabalho são os recomendados pela AAMI, que indica *MIT-BIH: The Massachusetts Institute of Technology – Beth Israel Hospital Arrhythmia Database*, *EDB: The European Society of Cardiology ST-T Database*, *AHA: The*

Literatura	Features	Classificadores	Tipos de batimentos de ECG	Acc(%)
Sahoo et al.	DWT + Temporal + Morphological	SVM	4	98.39
Ince et al.	DWT + PCA	MDPSO	5	95.58
Martis et al.	WT + PCA, LDA, ICA	SVM	5	99.28
Shadmand et al.	Hermit function	NN	5	97.00
Martis et al.	Cumulant + PCA	NN	5	94.52
Gulera et al.	Statistical features	NN	4	96.94
Kamath C.	Teager energy function features	NN	5	95
Asl et al.	Heart rate variability	SVM	4	97.65
Fei S.W.	Time intervals	SVM	5	95.65
Inana et al.	WT and timing interval	NN	3	95.2
Banerjee et al.	Mahalanobis distance	NN	-	95.14
Elhaj et al.	Linear and non-linear	NN	5	98.91
Chazal et al.	Morphology + heart beat interval	LDA	5	85.9
Tsipouras et al.	RR-interval	Fuzzy System	4	96
Park et al.	QRS complex, P wave	Decision tree	2	94.6
Llamedo & Martinez	RR interval and its derivative	LD	3	98
Li et al.	Eight heartbeat features	NN	5	95
Sahoo et al.	EMD based features	RBF-NN	5	99.89
Nguyen et al.	Count2 and VF-filter Leakage Measure	SVM	3	95.9
Raj et al.	A set of five features	SVM	16	99.21
Yang et al.	PCA Net	SVM	5	97.77
Rai et al.	Multiresolution DWT	MPNN	2	99.07
Raj et al.	DOST	PSO tuned SVM	16	99.18
Khalaf et al.	Statistical features	SVM	5	98.60
Oh et al.	CNN and LSTM	Deep learning	5	98.10
Sannino & Pietro	RR intervals	Deep learning	2	99.68
Isin et al.	DNN	Deep learning framework	2	92
Mathew et al.	Simple features	Deep belief networks	2	95.57

Tabela 1 – Tabela de comparação de estudos de [Sahoo et al. \(2020\)](#) e outros autores pesquisados

Fonte: [Sahoo et al. \(2020\)](#)

American Heart Association Database for Evaluation of Ventricular Arrhythmia Detectors, CU: The Creighton University Sustained Ventricular Arrhythmia Database, NST: The Noise Stress Test Database. Contudo, dentre os cinco recomendados, o mais utilizado é o MIT-BIH, pois é mais representativo para arritmias, além de ser a primeira base de dados disponível para estudos da área e que tem sido constantemente refinada.

De acordo com [Luz et al. \(2016\)](#), a AAMI recomenda apenas alguns tipos de arritmias para serem detectadas por equipamentos ou métodos. Também recomenda as medidas para as avaliações dos métodos, como sensibilidade (*recall*), preditividade positiva (precisão), taxa de falsos positivos e precisão geral. Além dessas recomendações existem outras, como por exemplo protocolos para testes e avaliações de métodos. Contudo, não são especificados quais dados devem ser usados para teste, pois caso se utilize os dados de um paciente para teste e validação do método, os resultados podem se tornar enviesados.

No trabalho de [Luz et al. \(2016\)](#), o esquema de dados de um mesmo paciente que aparecem tanto no treinamento quanto na validação dos métodos é chamado de intra-pacientes. Já quando são utilizados dados de pacientes diferentes no treinamento e na a validação, o esquema é chamado de inter-pacientes. Contudo, grande parte dos estudos não adota essa esquematização, e acaba por utilizar os mesmos dados no treinamento e validação.

A pesquisa na literatura em busca de trabalhos relacionados a métodos para detecção de arritmia dos autores foi dividida em duas tabelas. A Tabela [2](#) mostra trabalhos em que os pesquisadores se importaram em utilizar dados diferentes de treinamento e validação dos métodos implementados.

A primeira coluna da tabela se refere aos autores das pesquisas, enquanto que a segunda coluna mostra quais os conjuntos de características utilizadas, e a terceira contém os classificadores utilizados para obtenção dos resultados apontados na quarta coluna. Os autores que [Luz et al. \(2016\)](#) destacaram com “#” são referentes a trabalhos que não disponibilizaram a matriz de confusão, fazendo com que alguns valores não pudessem ser calculados para a coluna de eficácia. Aqueles que possuem “\$” na frente, são autores que otimizaram seu resultado. As siglas utilizadas S & SVEB se referem à grupo de batimentos cardíacos ectópicos supraventriculares (superclasse) e as V & VEB referem-se ao grupo de batimentos cardíacos ectópicos ventriculares (superclasse).

A Figura [3](#) apresenta trabalhos nos quais os autores utilizaram o mesmo conjunto de treinamento para o treinamento e teste dos métodos (intra-pacientes).

Os trabalhos analisados pelos autores [Luz et al. \(2016\)](#) geralmente utilizam o banco de dados MIT-BIH. Autores que seguiram uma abordagem mais realista e optaram por não misturar os batimentos cardíacos para o treinamento e teste (esquema inter-pacientes), relataram grande dificuldade em obter resultados promissores. Além disso, [Luz et al. \(2016\)](#) afirma que pesquisadores da comunidade de aprendizado de máquina têm mostrado que a escolha do bancos de dados utilizado para a construção de métodos impacta mais do que a escolha do algoritmo de aprendizado e/ou técnicas empregadas. Logo, os autores concluem que, um grande obstáculo

Trabalho	Conjunto de características	Classificador	Efetividade
Chen et al. [152]	Intervalos - RR	Conjunto de regras	Acc = 95%
Lagerholm et al. [138]	HBF, SOM	clustering	Acc = 98%
Dokur e Olmez [98]	Fourier, Wavelet + FSDP	MLP, RCE, Novel hybrid NN	Acc = 96%
Osowski e Linh [88]	HOSC	fuzzy NN	Acc = 96%
Tsipuras et al. [135]	Intervalos - RR	autômatos determinísticos	Acc = 96%
Mehmet [122]	HOSC, Wavelet	mín. Dist, kNN, Bayes	Acc = 98%
Cristov e Bortolan [106]	Intervalos de pulsação, VCG	NN	Acc = 99%
Guler e Ubeyli [44]	Wavelets (estatísticas)	NN combinado	Acc = 96%
Song et al. [102]	Wavelet coef., LDA, Intervalos - RR	SVM	Acc = 99%
Karimifard et al. [153]	HBF	kNN	Acc = 99%
Özbay et al. [84]	Onda bruta	MLP, cluster difuso, FCNN	Acc = 99%
Tsipuras et al. [136]	Intervalos - RR	Sistema especialista difuso	Acc = 96%
Bortolan et al. [105]	VCG e Morfológico, hiperbox+GA	Agrupamento difuso	Acc = 99%
Ubeyli [154]	DWT	SVM, ECOC	Acc = 99%
Yu e Chen [101]	ICA, intervalo RR	PNN	Acc = 99%
Ceilão e Osbay [76]	DWT	FCM, NN	Acc = 99%
Yu e Chen [101]	Wavelet (estatísticas) intervalos - RR	PNN	Acc = 99%
Minhas e Arif [137]	Wavelet, intervalo RR, PCA	kNN	Acc = 99%
Lin et al. [96]	morlet wavelet	AWN	Acc = 90%
Korurek e Nizam [127]	Intervalos - RR, segmentos de ECG	Cluster baseado em ACO, kNN	Acc = 94%
Yu e Chou [79]	Intervalos - RR, ICA	PNN, BPNN	Acc = 98%
Asl et al. [85]	HVR, GDA	SVM	Acc = 100%
Ceylan et al. [90]	PCA, DWT	FCMT2, ANN	Acc = 99%
Wen et al. [73]	Intervalos - RR, Onda bruta	Cluster baseado em SOCMAC	Acc = 98%
Yu e Chou [80]	ICA	SVM	Acc = 98%
Kim e outros. [77]	Intervalos - RR, PCA	OLMO	Acc = 98%
Ye et al. [70]	Wavelet, ICA, PCA, intervalo RR	SVM	Acc = 99%
Ozby e Tezel [74]	onda de ECG	NNAAF	Acc = 98%
Mishra e Raghav [95]	LFD	Vizinho mais próximo	Acc = 89%
Korurek e Nizan [127]	Intervalos - RR, largura QRS, Wavelet, PCA	ACO, kNN	Acc = 90%
Lanata et al. [128]	HOS	MOG, kNN	Acc = 85%
Yeh et al. [131]	Morfológico, intervalo RR QFS	agrupamento	Acc = 94%
Kallas et al. [83]	KPCA	SVM	Acc = 97%
Khazaei [155]	Intervalos de pulsação, amplitudes morfológicas	PSO + SVM	Acc = 97%
Wang et al. [103]	PCA,LDA	PNN	Acc = 99%
Kumar e Kumaraswamy [69]	Intervalos - RR	CART, RBF, MLP, IOAW-FFNN	Acc = 92%
Chen et al. [156]	Intervalos - RR	SVN, NN	Acc = 100%
Mert et al. [147]	Intervalos - RR, HOS,	Árvore de decisão ensacada Coeff LPC de 2ª ordem.	Acc = 99%
Ahmed e Arafat [157]	Intervalos de pulsação amplitude morfológica, HOS	MLP, SVM, TreeBoost	Acc = 98%
Sarfraz et al. [78]	Intervalos - RR, potência QRS	BPNN ICA coef.	Acc = 99%
Tran et al. [158]	intervalos - RR, HBF	Conjunto de classificadores	Acc = 98%
Alickovic e Subasi [159]	modelagem autorregressiva (AR)	SVM, MLP	Acc = 99%

Tabela 2 – Trabalhos que utilizaram o esquema de dados intra-pacientes

Fonte: Luz et al. (2016)

Trabalho	Conjunto de características	Classificador	Efetividade
de Chazal et al. [7]	Intervalos de ECG, Morfológico	LD ponderado	Acc = 83%; SeN = 87%; +PN = 99%; SeS = 76%; +PS = 38%; SeV = 77%; +PV = 82%;
Soria and Martinez [31]	intervalos - RR, VCG, Morfológico +FFS	LD ponderado	Acc = 90%; SeN = 92%; +PN = 85%; SeS = 88%; +P = 93%; SeV = 90%; +P = 92%
Llamedo and Martínez [37]	Wavelet, VCG +SFFS	LD ponderado	Acc = 93%; SeN = 95%; +PN = 98%; SeS = 77%; +PS = 39%; SeV = 81%; +PV = 87%;
Mar et al. [34]	Características temporais, Morfológico, Características estatísticas +SFFS	LD ponderado, MLP	Acc = 89%; SeN = 89%; +PN = 99%; SeS = 83%; +PS = 33%; SeV = 86%; +PV = 75%;
# Bazi et al. [40]	Morfológico, Wavelet	SVM IWKLR, DTSVM	Acc = 97% (DS1) Acc = 92% (DS2)
Luz et al. [134]	Características de estudos anteriores dos próprios autores da tabela	SVM, ANN, Bayesian, OPF	SeN = 84% SpSVEB = 18% SpVEB = 72%
Ye et al. [38]	Morfológico, Wavelet, intervalos - RR, ICA, PCA	SVM	Acc = 86,4% SeN = 88%; +PN = 97%; SeS = 60%; +PS = 53%; SeV = 81%; +PV = 63%;
de Lannoy et al. [32]	Intervalos - ECG, Morfológicos, HOS, coeficientes HBF,	SVM ponderado	Acc = 83%; SeN = 80%; SeS = 88%; SeV = 78%;
Park et al. [33]	HOS, HBF	SVM hierárquico	Acc = 85%; SeN = 86%; SeS = 82%; SeV = 80%;
Zhang et al. [35]	Intervalos - RR, Características morfológicas, Intervalos e segmentos de ECG	SVM combinado	Acc = 86%; SeN = 89%; +PN = 99%; SeS = 79%; +PS = 35%; SeV = 85%; +PV = 92%;
Escalona-Moran et al. [43]	Onda bruta	RC	Acc = 98 % ; SeN = 96 % ; + PN = 91 % ; SeS = 79 % ; + PS = 96 % ; SeV = 96 % ; + PV = 99 % ;
# Huang et al. [42]	Projeção aleatória, intervalos - RR	Conjunto de SVM	SeN = 99%; +PN = 95%; SeS = 91%; +PS = 42%; SeV = 94%; +PV = 91%;
\$ Lin and Yang [41]	Intervalos - RR normalizados	LD ponderado	Acc = 93%; SeN = 91%; +PN = 99%; SeS = 81%; +PS = 31%; SeV = 86%; +PV = 73%;
de Lannoy et al. [8]	Intervalos RR, Segmentos de ECG morfológico, HBF, HOS	CRF ponderado	Acc = 85%; AccN = 79%; AccS = 92%; AccV = 85%;
Zhang and Luo	Intervalos - RR, Características morfológicas, Intervalos e segmentos de ECG e coeficiente de Wavelets.	SVM combinado	Acc = 87%; SeN = 88%; +PN = 98%; SeS = 74%; +PS = 59%; SeV = 88%; +PV = 82%;

Tabela 3 – Trabalhos que utilizaram o esquema de dados intra-pacientes

Fonte: Luz et al. (2016)

para avanços em pesquisas voltadas a detecção automática de arritmias é o número reduzido de banco de dados disponíveis. Como poucos autores utilizam o mesmo esquema de avaliação para os testes, fica difícil comparar os métodos de forma justa. Também é difícil avaliar a real contribuição dos métodos, pois o esquema intra-paciente favorece os números relatados. (LUZ et al., 2016)

No trabalho de Wasimuddin et al. (2020), a pesquisa abrangeu o período de 2000 até 2020, utilizando as plataformas IEEE, MDPI, SPRINGER, ELSEVIER, SENSORS, PLOS e IOP com a *string* de busca contendo palavras como classificação de ECG com aprendizado de máquina e sistemas de monitoramento em tempo real para ECG. A busca retornou 180 artigo, porém com critérios aplicados de exclusão, ficaram apenas 130. O trabalho tem como objetivo explicar sobre sinais, análises e classificações de ECG, assim como o reconhecimento de arritmias através do mesmo.

O estudo foi feito através de estágios, onde no primeiro é retratado sobre o conjunto de dados de ECG que são utilizados para avaliação dos algoritmos de classificação de aprendizado de máquina em pesquisa e dispositivos vestíveis portáteis para detecção em tempo real. No estágio dois, apresentam a qualidade dos sinais de ECG, discutindo também métodos que podem ser usados para remoções dos ruídos contidos neles e assim melhorar a classificação. Nos estágios três e quatro, apresentam uma visão geral das pesquisas mais recentes de algoritmos de classificação de ECG baseados em engenharia de recursos tradicionais e de aprendizado de máquina. Além dessas discussões, trazem a tona os sistemas vestíveis que podem ser utilizados para detecção em tempo real com a aplicação de aprendizado de máquina, e quais as ferramentas disponíveis para tal estudo.

Os autores construíram uma tabela com o resumo de suas pesquisas para comparação da implementação feita por eles, com as pesquisas de outros estudiosos relacionadas no campo.

Na Figura 10 pode-se ver a comparação entre os artigos relevantes para a revisão sistemática dos autores. As colunas de autores e trabalhos foram adaptadas para que aparecessem, pois na original havia apenas a referência que encontrava-se em Wasimuddin et al. (2020). A quarta coluna apresenta o Estágio um, bases de dados utilizadas. A coluna com Estágio 2, apresenta os trabalhos dos autores que utilizaram métodos para eliminar os ruídos de ECG e ter uma melhor qualidade de sinais. A engenharia de recurso, trata-se do reconhecimento de ondas a partir dos dados apresentados nos ECGs. No estágio quatro, trabalhos que utilizaram abordagens tradicionais e aprendizado de máquina relatadas na literatura para classificar o sinal de ECG. Apenas dois trabalhos presentes na tabela utilizaram monitoramento em tempo real, além disso, três trabalhos utilizaram ferramentas de pesquisa para avaliar algoritmos de detecção ou classificação, utilizando softwares para treinar, testar e avaliar seus métodos. Na penúltima coluna, Wasimuddin et al. (2020) apresenta a área de foco dos autores listados, bem como a última coluna sendo quais as métricas utilizadas para medição de desempenho.

Ao finalizar as análises dos trabalhos elencados, observa-se que as abordagens tradicionais de processamento de sinal podem não ter um desempenho tão preciso quanto as abordagens

Autores	Trabalhos	Ano de publicação	Estágio 1: Fonte de Dados	Estágio 2: Verificação de Qualidade	Estágio 3: Engenharia de Recursos	Estágio 4: Classificação	Monitoramento em tempo real	Ferramentas de pesquisa	Área de Estudo	Efetividade
E. J. D. S. Luz, W. R. Schwartz, G. Cámara-Chávez and D. Menotti	ECG-based heartbeat classification for arrhythmia detection: A survey	2016	MITBIH		OK	OK			Heartbeat detection	sen, ppv, acc
J. Revathi and J. Anitha	A survey on analysis of ST-segment to diagnose coronary artery disease	2017	MITBIH, PTB, ESCDB		OK				MI detection	sen, ppv, acc
B. Singh, P. Singh and S. Budhiraja	Various approaches to minimise noises in ECG signal: A survey	2015		OK		OK			Denoising	NR
P. Lamba and K. Rawal	A survey of algorithms for feature extraction and feature classification methods	2019	MITBIH, ESCDB		OK	OK			Beat classification	sen, ppv, acc
S. H. Jambukia, V. K. Dabhi and H. B. Prajapati	Classification of ECG signals using machine learning techniques: A survey	2015	MITBIH		OK	OK			arrhythmia detection	sen, ppv, acc, rmse, mse
R. J. Owels and B. O. Al-Tabbaa	QRS detection and heart rate variability analysis: A survey	2014	MITBIH, QTDB, ESCDB, CSEDB		OK			OK	QRS detection	sen, ppv, acc
S. Sahoo, M. Dash, S. Behera and S. Sabut	Machine learning approach to detect cardiac arrhythmias in ECG signals: A survey	2020	MITBIH	OK	OK	OK			arrhythmia detection	sen, ppv, acc
W. Ahmed and S. Khalid	ECG signal processing for recognition of cardiovascular diseases: A survey	2016	MITBIH, QTDB, ESCDB, PTBDB	OK	OK	OK			Heartbeat detection	sen, ppv, acc
C. K and B. S	A survey on various machine learning approaches for ECG analysis	2017	MITBIH			OK			Arrhythmia detection	sen, ppv, acc
S. Karpagachelvi, M. Arthanan and M. Sivakumar	ECG feature extraction techniques-a survey approach	2010	MITBIH		OK				Feature extration	sen, ppv, acc
M. M. Baig, H. Gholamhosseini and M. J. Connolly	A comprehensive survey of wearable and wireless ECG monitoring systems for older adults	2013					OK	OK	Real-Time monitoring	
U. Iqbal, T. Ying Wah, M. Habib Ur Rehman and Q.-U.-A. Mastoi	Usage of model driven environment for the classification of ECG features: A systematic review	2018			OK	OK			Feature extration	
U. Satija, B. Ramkumar and M. S. Manikandan	A review of signal processing techniques for electrocardiogram signal quality assessment	2018	MITBIH, MITNSTDB, TELE ECG, PICC*, MITBHSTC*, Fansalia*, MACE*, MIMIC-II*	OK	OK	OK			Denoising	sen, ppv, acc
S. Ansari, N. Farzaneh, M. Duda, K. Horan, H. B. Andersson, Z. D. Goldberger, et al.	A review of automated methods for detection of myocardial ischemia and infarction using electrocardiogram and electronic health records	2017	PTBDB, ESCDB, LTSTDB	OK	OK	OK			MI detection	sen, ppv, acc
WASIMUDDIN, Muhammad et al.	Stages-based ECG signal analysis from traditional signal processing to machine learning approaches: A survey	2020	MITBIH, ESCDB, STSTDB, QTDB, TWADB, CSEDB, PTBDB, TELE ECG, AHAD, MITNSTDB, INCARTDB, CHALLENGEDB2017, CPSCDB2018	OK	OK	OK	OK	OK	Estágio 4 => ECG analysis model survey, ECG data acquisition source, Denoising, All fiducial points, Classification, Real-Time monitoring, Research tools, ECG morphology study	sen, ppv, acc, spe, f1-score, err, mse, rmse

Figura 10 – Figura adaptada das colunas mais relevantes apresentadas no trabalho de Wasimuddin et al. (2020)

Fonte: Wasimuddin et al. (2020)

recentes de aprendizado profundo e de máquina. Porém, as abordagens de aprendizado de máquina exigem processadores de custo mais alto para operar. Através da pesquisa, é visível que grande parte dos pesquisadores utilizaram a base de dados do MIT para avaliar seus métodos de análise e classificação de ECG com base em dados unidimensionais de ECG.

Por fim, conclui-se que abordagens de aprendizado profundo, para detecção de picos R e complexo QRS mostram bons resultados, além de que essas técnicas mostraram resultados de detecção e classificação mais eficientes através do trabalho de Wasimuddin et al. (2020).

O presente trabalho utilizou como base os trabalhos relatados acima. Porém, os trabalhos relacionados não focaram em nenhuma arritmia em específico, o qual neste trabalho teve como foco principal, ou seja, artigos na literatura sobre a aplicação de aprendizado de máquina na previsão de fibrilação atrial. Além disso, a *string* de busca utilizada (veja Capítulo 4) neste trabalho buscou artigos publicados de 2018 em diante. Assim como explicações dos algoritmos adotados pelos autores que foram vistos no mapeamento da literatura.

4 MAPEAMENTO SISTEMÁTICO

Este trabalho teve como objetivo buscar publicações que utilizaram aprendizado de máquina na área da saúde, em específico em casos de arritmia do tipo Fibrilação Atrial. A plataforma utilizada para o mapeamento sistemático da literatura foi o *Google Scholar*, em que aplicou-se a *string* de busca: "*Atrial fibrillation*"AND "*machine learning*" filtrando os trabalhos publicados de 2018 até 2023. O retorno obtido através de uma busca ampla e genérica foi de 20.100 artigos. Após o resultado os critérios de aceitação dos trabalhos foram:

- De trabalhos que tivessem palavras relacionadas à aprendizado de máquina e arritmia cardíaca;
- Da leitura do *abstract*;
- Da relevância à pesquisa, se correspondia ao propósito deste trabalho;
- A quantidade de citações (quanto mais, melhor);
- E o idioma, sendo eles português ou inglês.

Já os critérios de exclusão para o mapeamento foram:

- Trabalhos com ano de publicação inferior à 2018;
- Trabalhos que não possuíssem acesso gratuito;
- Títulos que continham palavras como *Survey* ou *Review*.

Porém, como a quantidade de artigos resultantes ainda foi alta, seria inviável ler todos os *abstract*. Através dos primeiros resultados da pesquisa, primeira a terceira página, os critérios citados acima foram utilizados para elencar nove primeiros trabalhos.

Contudo, os nove primeiros trabalhos selecionados tinham suas datas de publicação de 2018 á 2020. Foi utilizado, para a escolha dos três últimos trabalhos, o filtro do *Google Scholar* para ordenar por data, ordem cronológica que trás os mais recentes, utilizando a mesma *string* de busca. O retorno da pesquisa foi de 431 trabalhos, sem inclusão de citações. Os critérios continuaram os mesmos e a partir deles foi elencado os trabalhos com datas mais atuais, para compor o mapeamento.

Nos trabalhos, foram analisados quais os algoritmos e métricas de aprendizado de máquina foram utilizados, se os dados de treino e validação foram separados, qual a base de dados utilizada, qual o objetivo do estudo, quais as métricas utilizadas e o desempenho obtido. Os trabalhos selecionados para realizar o mapeamento sistemático apresentam abordagens e metodologias distintas. A seguir são apresentadas as soluções dos autores escolhidos.

O trabalho de [Liaqat et al. \(2020\)](#) utiliza duas bases de dados: Fibrilação atrial MIT-BIH e PhysioNet. A proposta é comparar os resultados obtidos através dos classificadores tradicionais e de *deep learning* (DL).

As bases utilizadas continham eletrocardiogramas em que, através de cálculos utilizados, foi possível a extração de recursos (como intervalos RR, recursos de onda única e recursos de onda completa). Para treinar os modelos que utilizavam ML, foi necessário reduzir a dimensão dos dados. Já para os modelos de DL, foram utilizados dados brutos. Os autores observaram que, sobretudo o modelo de Rede Neural Convolutiva consegue detectar melhor a Fibrilação atrial.

[Liaqat et al. \(2020\)](#) tiveram como contribuição o desenvolvimento de novas arquiteturas aplicadas no LSTM, CNNs e extração de dados dos ECGs. Compararam o desempenho da nova arquitetura gerada nos algoritmos com outros dois, sendo eles LSTM convolutiva e ResNet (*Residual Network*). Os últimos dois modelos citados obtiveram um desempenho inferior, o LSTM convolutiva possui uma estrutura em que é necessário muitos dados e recursos para ser treinada. Já a utilização de ResNet levou um tempo de treinamento muito superior as arquiteturas de CNN e LSTM. Os autores tomaram o cuidado de dividir os dados de treinamento, teste e validação, fazendo com que os resultados obtidos não ficassem comprometidos e tendenciosos.

Tendo em vista que as bases de dados utilizadas possuem bastante ruídos e mesmo assim o modelo de previsão obteve bons resultados, comparando-se aos demais propostos nos estudos dos autores, considera-se o resultado final como bom.

A precisão dos modelos utilizados com os dados da PhysioNet foi de 0,9905 para a Rede Neural Convolutiva, 0,9949 para LSTM, 0,8652 LSTM Convolutiva e 0,8352 com o ResNet. Já a precisão obtida ao utilizar a base de dados Fibrilação Atrial MIT-BIH foi minimamente inferior para alguns modelos. Sendo 0,982 para a Rede Neural Convolutiva, 0,984 para LSTM, 0,953 LSTM Convolutiva e 0,953 com o ResNet.

Diferentemente do trabalho de [Liaqat et al. \(2020\)](#), os autores [Hill, Ayoubkhani, McEwan et al. \(2019\)](#) utilizaram a base de dados *UK Clinical Practice Research Datalink (CPRD)* selecionando pacientes de 30 anos ou mais, que não possuíam histórico de Fibrilação Atrial (FA) cinco anos antes do início do estudo.

O objetivo do trabalho de [Hill, Ayoubkhani, McEwan et al. \(2019\)](#) se deu em desenvolver um modelo de predição de risco clinicamente aplicável para identificar associações entre fatores basais e variáveis no tempo e a identificação de FA. O trabalho foi desenvolvido em três estágios. Ao decorrer do processo, selecionaram alguns modelos (Regressão LASSO, Random Forest, SVM, Redes neurais, Regressão de Cox E Modelos de risco de FA) que serviram como base para dar seguimento no estudo.

Na primeira etapa do estudo, foi possível identificar que o modelo de Redes Neurais foi o mais ideal dentre as abordagens propostas. Seguiram para as próximas etapas utilizando esse modelo unido com as co-variáveis variantes no tempo que foram consideradas. Ao final do estudo, os autores usaram como referência um modelo já existente, CHARGE-AF ([ALONSO](#)

et al., 2013)) que possuía bons resultados. Contudo, o modelo proposto por Hill, Ayoubkhani, McEwan et al. (2019) conseguiu superar os valores do estudo de referência, aumentando a capacidade de diferenciação entre casos de FA diagnosticados e não-FA, em 14.1% do AUROC (área sob a curva característica de operação do receptor) de 0,827, enquanto o modelo CHARGE-AF conta com um AUROC de 0,725.

Para que os resultados não ficassem enviesados, os autores utilizaram, além da amostra à qual os modelos de risco foram ajustados, uma abordagem em que os pacientes foram designados aleatoriamente para conjuntos de dados de treinamento e validação em uma proporção de 2:1; esses conjuntos de dados foram usados para ajustar e avaliar independentemente cada modelo de risco, respectivamente.

Os autores em (HILL; AYOUBKHANI; MCEWAN et al., 2019) afirmam que o modelo de risco desenvolvido tem alto rendimento e bom potencial para reduzir bastante o número de pacientes rastreados com FA. Entretanto, uma das limitações que impactaram no estudo foi a base de dados utilizada - o CPRD. Os registros de cuidados primários, como a única fonte de dados, não fornecem informações detalhadas sobre os dados de ECG e sua codificação. Por exemplo, se a FA foi um episódio único ou episódios múltiplos ou persistente - esses dados geralmente são deixados incompletos.

Outra limitação foi que os autores só conseguiram analisar os eventos cronologicamente na ordem em que foram registrados no CPRD. Isso pode afetar a descoberta de que um evento cardiovascular adverso recente, como insuficiência cardíaca, pudesse ser um preditor de um diagnóstico futuro de FA, ou que a FA paroxística pode ter desencadeado a insuficiência cardíaca. É possível que existam defasagens no registro dos eventos, de modo que, para alguns pacientes, o diagnóstico de FA possa ter sido feito no mesmo dia, ou mesmo antes, do evento cardiovascular adverso.

Por fim, um último limitador foi ter desenvolvido o modelo com base em casos de FA já diagnosticados e sem informações detalhadas sobre o diagnóstico e reais.

A rede neural exibiu maior desempenho preditivo do que os modelos de risco de FA existentes e é um primeiro passo significativo para melhorar a detecção de FA não diagnosticada. Além disso, Hill, Ayoubkhani, McEwan et al. (2019) reconhecem que o desempenho do modelo para o mundo real não está certo. Contudo, para uma futura pesquisa, pretendem conduzir um ensaio clínico para investigar o desempenho do modelo na prática. Com isso, pode-se avaliar como os fatores de risco identificados se traduzem na previsão e diagnóstico de FA em um cenário do mundo real, em uma tentativa de otimizar a prevenção da FA acidente vascular cerebral, insuficiência cardíaca e mortalidade prematura.

Outra abordagem utilizada foi no estudo de Lown et al. (2020) que aplicou o modelo Máquina de Vetores de Suporte (SVM), com base no banco de dados de Fibrilação Atrial do *Massachusetts Institute of Technology (MIT)—Beth Israel Hospital (BIH)*.

Os dados obtidos através do MIT-BIH foram utilizados para treinamento dos métodos implementados, que a partir da validação cruzada, os dados puderam ser divididos aleatoria-

mente entre registros em todo o conjunto de dados de treinamento. Para a validação, [Lown et al. \(2020\)](#) empregaram dados de um estudo de caso, com dados clínicos obtidos usando um dispositivo. Este estudo continha 415 participantes, com idade acima de 65 anos e, desse total, apenas 79 deles possuíam Fibrilação Atrial. O algoritmo SVM demonstrou excelente discriminação com sensibilidade e especificidade superiores a 99% para o conjunto de dados de treinamento.

Os autores em [ALHUSSEINI et al. \(2020\)](#) partiram da hipótese de que, por meio de uma plataforma computacional, utilizando aprendizado de máquina, é possível mapear casos de Fibrilações Atriais e identificar possíveis pacientes de ablação¹. Outro objetivo dos autores foi desmistificar como é o processo de aprendizado de máquina para que os profissionais da área da saúde consigam entender a funcionalidade e assim ganhar confiança sobre programas que utilizam o aprendizado de máquina.

Em seus estudos, [Alhusseini et al. \(2020\)](#) incluíram 35 pacientes que continuam FA. Partiram da ideia de utilizar Redes Neuras Convolucionais (CNN) em mapas de calor, para ajudar na identificação da necessidade de realizar um procedimento de ablação ou não.

Para validação e comparação de dados, utilizaram outros tipos de aprendizados de máquina. Inicialmente, analisaram um modelo não supervisionado, de clusterização, ou seja, agrupamento de dados semelhantes, com intuito de verificar se o agrupamento condizia com os rótulos impostos. Após, analisaram com mais outros três métodos supervisionados, sendo eles k-vizinhos mais próximos, análise discriminante linear (LDA) e máquinas de vetores de suporte (SVM).

Para desenvolvimento e teste, os dados rotulados foram repartidos aleatoriamente em treinamento independente (57%, 20 pacientes), validação (14%, 5 pacientes) e teste (29%, 10 pacientes), cada um de pacientes distintos.

O modelo não supervisionado (clusterização) obteve uma precisão em dados de teste de 79,4%, enquanto o K-vizinhos mais próximos obteve 78,9%, ficando pouco abaixo da precisão dos dados de teste da LDA, que atingiu 79,7%, sendo esse valor o mesmo atingido pelo modelo SVM.

A conclusão obtida a partir das comparações foi que o uso de redes neurais convolucionais teve um resultado melhor, tendo uma precisão de aproximadamente 95%. Isso se deu pois, após seu treinamento, a rede conseguiu gerar uma lógica, similar a de especialistas da área, que não havia sido codificada, para classificação de FA. Logo, de acordo com [Alhusseini et al. \(2020\)](#) esses resultados podem ser usados para reduzir a ambiguidade das interpretação das abordagens atuais de mapeamento de FA durante os procedimentos de ablação.

De modo diferente, o estudo de [Hung et al. \(2020\)](#) utilizou os dados do *Nationwide Readmissions Database (NRD)* que faz parte de uma família de bancos de dados desenvolvidos para o *Healthcare Cost and Utilization Project (HCUP)*. Dessa base, os dados utilizados foram de pacientes maiores de 18 anos, que não faleceram durante a internação ou que não tiveram

¹ Procedimento cirúrgico invasivo que visa tratar a FA, através da localização de veias pulmonares que causam a arritmia, objetivando acabar com esses impulsos elétricos indesejáveis ([FENELON et al. 2007](#))

tempo de internação. O objetivo foi buscar por diagnósticos de Fibrilação Atrial e procedimentos de ablação por cateter. Como havia muitas variáveis, aplicaram o modelo de *Random Florest* para a seleção de variáveis, que resultou em 30 principais recursos.

Os modelos escolhidos pelos autores para a classificação dos dados foram máquina de vetor de suporte (SVM), K-vizinhos mais próximos (k-NN) e classificador de árvore de decisão. Para o treinamento, dividiram o conjunto de dados de forma aleatória, ficando 60% dados para treinamento e 40% de conjuntos de teste. Os modelos foram então aplicados aos conjuntos de treinamento e teste, e suas precisões foram registradas.

A métrica escolhida para medir o desempenho dos classificadores foi a precisão. Entre os métodos de aprendizado de máquina, o modelo k-NN obteve a maior precisão, sendo de 85%, seguido pelo classificador de árvore de decisão em 78,0% e tendo o SVM como pior desempenho, com 61,3%. Logo, [Hung et al. \(2020\)](#) conseguem prever a reinternação em 30 de pacientes com uma previsão de 85%. Com a utilização de um modelo, pode-se minimizar reinternações hospitalares e melhorar a qualidade dos cuidados de saúde, utilizando modelagem preditiva para avaliar riscos para resultar em tratamentos preventivos eficazes, levando a custos mais baixos, melhor atendimento e menos mortalidade.

Em seus estudos, [Firyulina e Kashirina \(2020\)](#) utilizaram os modelos de árvores de classificação, regressão linear, floresta aleatória e aumento de gradiente de aprendizado de máquina para prever a forma de fibrilação atrial. Para validar os modelos, usaram a validação cruzada.

Os modelos de árvore de classificação e a floresta aleatória foram os primeiros modelos desenvolvidos. Contudo, os valores obtidos são prejudicados pela entrada de dados que é limitada a poucos valores. Ao comparar os dois modelos, nota-se através porcentagem média de respostas corretas na validação cruzada que o valor obtido da floresta aleatória é maior em comparação ao modelo de árvore de decisão. Contudo, as árvores de decisão são modelos bastante utilizado na prática médica, pois permitem obter regras de classificação intuitivas e visuais ([FIRYULINA; KASHIRINA, 2020](#)).

Após a análise com os modelos citados, os autores construíram outros dois modelos, o aumento de gradiente sobre as árvores de decisão e a Regressão linear. Entre os dois modelos, o aumento de gradiente obteve um melhor resultado entre os dois. Apesar do modelo de árvore de classificação ter apresentado o pior resultado, o algoritmo obteve regras de classificação claras e precisas. Mesmo com a limitação de amostragem de treinamento ser relativamente pequena, os autores ainda conseguiram encontrar fatores significativos para classificar a Fibrilação Atrial.

A pesquisa de [Gregoire et al. \(2019\)](#) utilizou 10.484 monitoramentos de eletrocardiogramas e com aproximadamente 90% desses dados, treinaram dois modelos desenvolvidos. Os modelos construídos foram uma rede neural recorrente (RNN) e árvore de decisão. O restante dos dados (aproximadamente 10%) foi usado para testes. Dentre os dois, aquele que obteve o melhor desempenho foi o modelo de RNN, contudo, houve pouca diferença de resultados entre os dois modelos.

Diferente dos trabalhos citados, o estudo de [Hill, Ayoubkhani, Lumley et al. \(2018\)](#) teve como foco modelos de aprendizado de máquina não lineares com o objetivo de alcançar resultados melhores que os modelos estatísticos lineares convencionais. Os dados utilizados foram da UK Clinical Practice Research Datalink (CPRD), do início de 2006 até o final de 2016.

Foram comparados quatro modelos com um modelo de Cox e outros modelos estatísticos publicados anteriormente para prever a probabilidade de AF/F. Entre os 4 modelos, estão LASSO, redes neurais, florestas aleatórias e máquinas de vetor de suporte. A precisão foi avaliada principalmente pela área sob a curva (AUC). Os resultados obtidos foram de 0,811, para LASSO 0,811, máquinas de vetores de suporte 0,812 florestas aleatórias e 0,818 para redes neurais, enquanto o modelo de Cox resultou em uma AUC de 0,782. Logo, [Hill, Ayoubkhani, Lumley et al. \(2018\)](#) concluem que o aprendizado de máquina supera os resultados de modelos estatísticos convencionais e são de grande valia para tratamentos preventivos.

Já em [Aschbacher et al. \(2020\)](#), o objetivo foi de testar a hipótese de que um algoritmo de aprendizado profundo com formas de onda PPG brutas derivadas de *smartwatch* discriminaria FA de ritmo sinusal normal melhor do que algoritmos que usam apenas a frequência cardíaca. A técnica de fotopletismografia (PPG) usa sensores ópticos para detectar alterações no volume sanguíneo da micro vasculatura tecidual - podendo detectar, através de uma câmera de smartfone ou usando uma pulseira vestível, por exemplo.

O estudo contava com 51 pacientes que foram submetidos a cardioversão elétrica para Fibrilação Atrial na Universidade da Califórnia, San Francisco (UCSF), no período entre final de 2017 e meados de 2018. Só foram aceitos pacientes que não possuíssem outro tipo de arritmia, senão fibrilação atrial. Três modelos foram utilizados para comparação, usando a área sob a curva (AUC) como a principal métrica de desempenho ([ASCHBACHER et al., 2020](#)). Os modelos foram treinados com quarenta pacientes designados aleatoriamente e testados com outros 11. O primeiro modelo foi utilizando a variabilidade da frequência cardíaca como preditor em um modelo de regressão logística; o segundo modelo uma rede neural de memória de longo prazo (LSTM) de camada única, sendo a entrada 35 períodos consecutivos de pulsação e o terceiro modelo uma rede neural convolucional recorrente profunda (RNN) usando a forma de onda PPG bruta como entrada.

O trabalho de [Kanna et al. \(s.d.\)](#) teve como objetivo categorizar o conjunto de dados em diferentes categorias de doenças cardíacas, como: arritmia cardíaca, insuficiência cardíaca congestiva e ritmo sinusal normal, e avaliar os resultados utilizando redes neurais convolucionais (CNN). Para isso, utilizaram os dados de ECG disponibilizados por um hospital, em que, após o pré-processamento dos dados, foi-se transformado em imagens de escalogramas ².

Utilizaram a ferramenta *MATLAB* para o desenvolvimento e implementação das redes neurais profundas. Usaram as arquiteturas de *Alex Net*, *Google Net* e *Squeeze Net* como base de desenvolvimento dos algoritmos. Por meio das ferramentas utilizadas, os autores obtiveram

² Os escalogramas são gráficos que representam a visualização bidimensional dos coeficientes wavelets, podendo-se visualizar por meio de um campo de isolinhas ou imagem ([DOMINGUES et al., 2016](#)).

uma precisão na validação do método proposto de 97.33%. Transferiram os dados de uma rede neural convolucional profunda, que já havia sido treinada, fazendo com que o processamento ficasse mais leve.

Os resultados utilizando a arquitetura de *Alex Net* mostraram que as camadas mais profundas de uma CNN profunda treinada em uma grande quantidade de dados anotados podem ser transferidas e usadas para identificar arritmias de ECG. Logo, os autores concluem que, uma CNN com grande quantidade de dados pode ser capaz de quebrar recordes em um conjunto de dados rígido apenas com aprendizado supervisionado.

Já o objetivo de [Zheng et al. \(2022\)](#) foi objetivo desenvolver um modelo preditivo utilizando ML para identificar pacientes de AVC isquêmico agudo (AIS) com alto risco de Fibrilação atrial pós AVC. Os dados para o estudo foram coletados no *National Advanced Stroke Center do Nanjing First Hospital* (China) entre julho de 2012 e setembro de 2020.

Utilizaram a validação cruzada, para verificar como o algoritmo se comportaria ao ver um dado nunca visto anteriormente. As métricas utilizadas foram : AUC, Sensibilidade, Especificidade, Valor Preditivo Positivo, Valor Preditivo Negativo e Precisão.

Para selecionar os preditores significativos de FA pós-AVC, utilizaram o modelo de Regressão logística multivariada. Utilizaram os modelos de ML que são bem visto na predição de risco de FA pós-AVC, sendo eles regressão logística (LR), floresta aleatória (FR), máquina de vetor de suporte (SVM), aumento de gradiente extremo (XGBoost) e rede neural profunda (DNN). Dentre os modelos, a Rede neural profunda foi a que alcançou as melhores métricas, tendo uma precisão de 92.5%.

Já o trabalho de [Huang et al. \(2023\)](#) propõe um esquema integrado de árvore de decisão de ML para alcançar uma boa precisão na decisão da seleção de dose medicamentosa apropriada para pacientes com fibrilação atrial não valvar (NVAF). Utilizaram um esquema de ML para construir um modelo de árvore de decisão para avaliação de risco em pacientes com NVAF tomando diferentes doses de dabigatrana. Os dados foram obtidos do *Fu Jen Catholic University Hospital*.

Os modelos implementados foram *Naive Bayes* (NB), sendo ele um classificador probabilístico baseado no teorema de Bayes com fortes suposições de independência entre características individuais. O *CART* é um método de árvore de decisão de divisão binária baseado no índice de Gini, que pode ser um classificador ou ferramenta preditiva de regressão com um tamanho de árvore ótimo, aplicando um procedimento de validação cruzada. Implementaram também os métodos de *Random Forest* (RF) e *Extreme Gradient Boosting* (XGBoost) - Aumento de Gradiente.

O trabalho foi dividido em três partes: (i) definição de variáveis e classificação de subgrupos de estudo, (ii) construção dos modelos ML e (iii) regras derivadas a partir da obtenção de variáveis importante, selecionando com precisão a dose certa de dabigatrana para pacientes com NVAF. Os valores obtidos foram uma média de AUC 0,683 para NB, 0,764 para RF, 0,553 para CART e 0,708 para XGBoost.

Trabalho	Autores	Ano	DataSet	Classificador	Resultados	
					Métricas	Valores
Detection of atrial fibrillation using a machine learning approach.	LIAQAT, Sidrah et al.	2020	MIT-BIH	Rede Neural Convolucional, LSTM, LSTM convolucional, ResNet	Precisão	0,982, 0,984, 0,953, 0,953
Predicting atrial fibrillation in primary care using machine learning	HILL, Nathan R; AYOUBKHANI, Daniel;	2019	UK Clinical Practice Research Datalink	Rede neural	AUROC	0,827
Machine learning detection of Atrial Fibrillation using wearable technology	MCEWAN, Phil et al. LOWN, Mark et al.	2020	MIT-BIH	SVM	Especificidade	0,976
Machine learning to classify intracardiac electrical patterns during atrial fibrillation: machine learning of atrial fibrillation.	ALHUSSEINI, Mahmood I et al.	2020	Próprio	Cluster, K-vizinhos, LDA, SVM, CNN	Precisão	0,794, 0,789, 0,797, 0,797, 0,950
Using machine learning to predict 30-day hospital readmissions in patients with atrial fibrillation undergoing catheter ablation	HUNG, Man et al	2020	Nationwide Readmissions Database (NRD)	SVM, K-vizinhos, Árvores de decisão	Precisão	0,613, 0,850, 0,780
Classification of cardiac arrhythmia using machine learning techniques	FIRYULINA, MA; KASHIRINA, IL. C	2020	Dados tratados oriundos do Hospital Clínico Regional de Voronezh	Árvores de classificação, Regressão linear, Floresta aleatória, Aumento de gradiente	Precisão	0,902, 0,755, 0,912, 0,902
Forecasting atrial fibrillation using machine learning techniques.	GREGOIRE, J-M et al	2019	Próprio	Rede neural recorrente, Árvore de decisão	AUC	0,989, 0,982
Machine learning to detect and diagnose atrial fibrillation and atrial flutter (AF/F) using routine clinical data.	HILL, NR; AYOUBKHANI, D; LUMLEY, M et al. M	2018	UK Clinical Practice Research Datalink	Regressão LASSO, Redes neurais, Florestas aleatórias, SVM	Precisão	0,811, 0,818, 0,812, 0,811
Atrial fibrillation detection from raw photoplethysmography waveforms: A deep learning application.	ASCHBACHER, Kirstin et al.	2020	Universidade da Califórnia, San Francisco (UCSF)	Regressão logística, Rede Neural de Memória de Longo Curto Prazo (LSTM), Rede Neural Recorrente Convolucional	AUC	0,717, 0,954, 0,983
Cardiac Arrhythmia Detector Using CNN Application.	KANNA, R Kishore et al.	2023	Próprio	Rede Neural Recorrente Convolucional	Precisão	0,973
Using machine learning to predict atrial fibrillation diagnosed after ischemic stroke.	ZHENG, Xiaohan et al.	2022	Próprio, obtido do National Advanced Stroke Center do Nanjing First Hospital	Rede Neural Profunda	Precisão	0,925
Integrated Machine Learning Decision Tree Model for Risk Evaluation in Patients with Non-Valvular Atrial Fibrillation When Taking Different Doses of Dabigatran.	HUANG, Yung-Chuan et al.	2023	Próprio, obtido do Fu Jen Catholic University Hospital.	Naive Bayes(NB), Random Forest, CART, XGBoost	AUC	0,683, 0,764, 0,553, 0,708

Tabela 4 – Tabela contendo informações principais dos artigos revisados

Fonte: Própria

Dentre os modelos citados, algoritmo de rede neural convolucional recorrente profunda obteve o melhor resultado. Logo, os autores concluem que a utilização de algoritmos de aprendizado de máquina, unido a uma tecnologia vestível podem ser muito promissores na detecção de doenças cardiovasculares, como nesse caso a FA. Ter uma tecnologia capaz de identificar e alertar com antecedência pode reduzir bastante as morbidades cardíacas, visto que podem ser tratadas assim que descobertas.

A Tabela 4 apresenta um resumo dos trabalhos estudados. A primeira e segunda coluna da tabela apresentam os títulos dos trabalhos e seus autores, respectivamente. A terceira coluna, o ano de publicação dos artigos. As bases de dados utilizadas pelos autores são apresentadas na quarta coluna, seguida pelos métodos de classificação utilizados. A última coluna está dividida em duas, pois os autores disponibilizaram seus resultados em diferentes métricas; Logo, na primeira coluna dos resultados, está qual foi a métrica adotada para validação dos métodos seguida pelos valores resultantes.

Observando-se a tabela e como visto no Capítulo 3, muitos trabalhos utilizaram a base de dados do MIT-BIH. Para que houvesse uma contribuição entre o presente trabalho e os trabalhos relacionados, vale analisar o resultado dos estudos que utilizaram o mesmo método mas com base de dados diferentes.

Apesar da base de dados MIT-BIH ainda estar presente em trabalhos atuais, é possível ver

que em dois anos essas bases aumentaram e fomentaram pesquisadores a obterem seus próprios dados.

Contudo, o tempo de dois anos não é o suficiente para ter-se desenvolvido um método ainda melhor do que os já analisados. Mas, podemos confirmar que abordagens que utilizaram algoritmos de aprendizado profundo, obtiveram melhores resultados. Deve-se destacar que a base de dados utilizada é importante para os resultados, pois se aplicado uma base com poucos dados em um algoritmo de aprendizado profundo, os resultados podem ficar comprometidos, já que esses algoritmos precisam de uma grande quantidade de dados.

Dos resultados, classificadores que utilizaram aprendizado profundo, obtiveram um resultado de precisão maior em comparação aos demais, em específico o método CNN.

Outro ponto importante que deve ser evidenciado é o trabalho de [Alhusseini et al. \(2020\)](#), cuja base de dados utilizada foi extremamente pequena e os resultados obtidos não foram tão significativos, apesar da CNN ter alcançado um valor expressivo, torna-se duvidoso o resultado pela questão de quantidade de dados imposta.

Além disso, no trabalho de [Luz et al. \(2016\)](#) é destacada a importância da separação dos conjuntos de dados de treinamento e validação. Em alguns dos presentes trabalhos, os autores esclarecem como foi feita a divisão dos dados para teste e treinamento, contudo, nem todos os trabalhos selecionados apresentam essas informações. Sendo assim, a visualização e comparação dos métodos se torna mais difícil, pois não sabendo como foi feita a validação e obtenção de resultados, compara-los de forma justa se torna uma missão difícil. Contudo, ao olhar para os resultados obtidos pelos trabalhos revisados, fica visível que algoritmos que utilizam aprendizado profundo obtiveram melhores resultados.

5 CONCLUSÃO

O poder computacional atual é imenso comparado a alguns anos atrás. Com uma grande quantidade de processamento e desempenho, é possível repassar tarefas repetitivas para uma máquina.

O aprendizado de máquina, uma sub-área da IA, é a construção de programas que melhorem seu desempenho por meio de exemplos. Para isso é necessária uma grande quantidade de exemplos, já que o computador “aprende” através desses dados, e a partir desses são gerados hipóteses. Ou seja, As técnicas de ML são orientadas a dados, isto é, aprendem a partir de grandes volumes de dados repassados a elas. Os algoritmos de AM geram hipóteses a partir dos dados (LUDERMIR, 2021). A utilização do aprendizado de máquina vem ganhando mais espaço, com possíveis alertas de acontecimentos que podem ser previstos a partir de uma grande análise de todas as variáveis que podem levar aquele evento a ocorrer.

Tamanho avanço permite ir além, contribuindo para diversas áreas de conhecimento. Uma dessas grandes áreas é a da saúde, que ainda possui bastante processos e atividades sendo feitas manualmente.

Uma área de crescente aplicação da automação é a de diagnósticos automáticos utilizando inteligência artificial (IA). Atualmente já existem diagnósticos automáticos que são corretos e precisos. Um exemplo dessa aplicação na prática foi um robô criado pela empresa *iFlytek*, que passou no exame nacional para licenciamento de médicos da China (SARACCO, 2017). O “Médico Assistente robô” registra os sintomas dos pacientes, analisa as imagens de tomografia computadorizada e faz o diagnóstico inicial. O robô não se destina a substituir médicos, em vez disso, tem como objetivo ajudá-los e aumentar sua eficiência (LUDERMIR, 2021).

Na área da saúde, o campo de estudos é vasto e possui muitos espaços abertos para contribuições. Arritmias cardíacas, mais em específico a Fibrilação Atrial, se encaixam nos tópicos de contribuições para a área da saúde e foi o tema abordado neste trabalho.

O objetivo neste trabalho foi realizar um mapeamento sistemática da literatura, em que se buscou trabalhos que utilizaram o aprendizado de máquina para detecção de fibrilação atrial. A fibrilação atrial é uma doença cardíaca, categorizada no grupo de arritmias cardíacas. Afeta principalmente pessoas acima de 65 anos, além de possuir vários outros fatores de riscos que podem contribuir para sua causa. A descoberta dessa arritmia se faz a partir de eletrocardiogramas que medem a frequência cardíaca. Ao analisar o ECG é possível verificar o comprimento de ondas e visualizar anomalias cardíacas.

Ao revisar os artigos propostos, uma das limitações que existe entre as áreas da saúde e tecnologia é a pouca quantidade de dados. Um conjunto de dados reduzidos pode afetar nos resultados obtidos pelos modelos de aprendizado de máquina, visto que eles usam os conjuntos para serem treinados e validados, logo quanto mais dados melhor.

Contudo, ainda existem grandes barreiras a serem vencidas para a utilização clínica dessa tecnologia, onde se envolve a ética e a confiabilidade desses sistemas inteligentes.

A aplicação de aprendizado de máquina na área da saúde é uma grande aposta que beneficiaria em diversos pontos, como por exemplo, a diminuição de custos nos serviços de saúde e a falta de assistência médica especializada em cidades menores e interiores rurais (LIMA et al., 2022).

Um dos grandes sistemas de saúde que se beneficiaria do aprendizado de máquina seria o Sistema Único de Saúde (SUS). Contudo a aplicação clínica para o sistema unificado de saúde (SUS) no Brasil, ainda é, infelizmente, uma realidade muito distante. A introdução da tecnologia traz consigo enormes desafios, sendo o maior deles a aceitação da população, tanto pelos profissionais da saúde, quanto por usuários do sistema.

Em Lima et al. (2022) estima-se que aproximadamente apenas 16% de gestores e profissionais da área da saúde no SUS possuam compreensão razoável referente ao tema de aprendizado de máquina. Para se ter uma aceitação e aplicação considerável, seria necessário a disseminação de conhecimentos sobre essa tecnologia, não só para profissionais da área, como também para pessoas que utilizam o SUS.

Entretanto, o SUS possui princípios que devem ser seguidos para que cumpra com seu propósito. Um deles é o princípios de equidade, onde objetiva-se tratar desigualmente os desiguais, investindo mais onde a carência é maior (SAÚDE, Accedido el 22 de febrero de 2023). Logo, entra outro desafio em que se tem a transparência como parte do princípio e que por diversos motivos, na aplicação de aprendizado de máquina ela não se torna tão visível. Lima et al. (2022) exemplifica com o uso de dados sensíveis que devem ser protegidos pelas organizações. Outro exemplo seria a não compreensão da forma como determinado algoritmo e técnica foram aplicados.

Por isso, faz-se necessário diversos estudos na área que agreguem na evolução, tanto da tecnologia como na ampliação de conhecimento e visibilidade para a utilização benéfica de aprendizado de máquina no campo da saúde.

Neste trabalho, mapeou-se diversas técnicas e algoritmos de aprendizado de máquina para detecção de Fibrilação Atrial, tendo como intuito a sintetização das arquiteturas utilizadas nos últimos anos e quais os desempenhos obtidos por elas.

Contudo, a análise de qual arquitetura melhor se encaixa com o propósito de detectar e classificar Fibrilação Atrial ainda não é assertiva. Dos algoritmos e técnicas apresentadas, pode-se ver que os resultados favoreceram as arquiteturas de redes neurais e aprendizado profundo. Porém, como os trabalhos utilizaram base de dados, quantidade de dados, métricas, extração, treinamento e validação diferentes, a análise de resultados não pode ser conclusiva.

Assim, para possíveis trabalhos futuros, é importante a validação das arquiteturas propostas, em que se utilize a mesma base de dados e métricas para os diferentes algoritmos analisados. Além disso, a busca por mais trabalhos na literatura em que os objetivos se aproximam dos estudos selecionados neste trabalho.

REFERÊNCIAS

- ACADEMY, Data Science. Deep Learning Book. In: www.deeplearningbook.com.br: Data Science Academy, 2022. Arquitetura de Redes Neurais Long Short Term Memory (LSTM).
- ALHUSSEINI, Mahmood I et al. Machine learning to classify intracardiac electrical patterns during atrial fibrillation: machine learning of atrial fibrillation. **Circulation: Arrhythmia and Electrophysiology**, Am Heart Assoc, v. 13, n. 8, e008160, 2020.
- ALONSO, Alvaro et al. Simple risk model predicts incidence of atrial fibrillation in a racially and geographically diverse population: the CHARGE-AF consortium. **Journal of the American Heart Association**, Am Heart Assoc, v. 2, n. 2, e000102, 2013.
- ANDRADE, Jason et al. The clinical profile and pathophysiology of atrial fibrillation: relationships among clinical features, epidemiology, and mechanisms. **Circulation research**, Am Heart Assoc, v. 114, n. 9, p. 1453–1468, 2014.
- ANWAR, Syed Muhammad et al. Arrhythmia classification of ECG signals using hybrid features. **Computational and mathematical methods in medicine**, Hindawi, v. 2018, 2018.
- ASCHBACHER, Kirstin et al. Atrial fibrillation detection from raw photoplethysmography waveforms: A deep learning application. **Heart rhythm O2**, Elsevier, v. 1, n. 1, p. 3–9, 2020.
- BZDOK, Danilo; KRZYWINSKI, Martin; ALTMAN, Naomi. Machine learning: supervised methods. **Nature methods**, NIH Public Access, v. 15, n. 1, p. 5, 2018.
- DOMINGUES, MO et al. Explorando a transformada wavelet continua. **Revista Brasileira de Ensino de Física**, SciELO Brasil, v. 38, 2016.
- DUARTE, Denio; STÅHL, Niclas. Machine learning: a concise overview. **Data Science in Practice**, Springer, p. 27–58, 2019.
- FENELON, Guilherme et al. Ablação da fibrilação atrial no Brasil: resultados do registro da Sociedade Brasileira de Arritmias Cardíacas. **Arquivos Brasileiros de Cardiologia**, SciELO Brasil, v. 89, p. 285–289, 2007.
- FIRYULINA, MA; KASHIRINA, IL. Classification of cardiac arrhythmia using machine learning techniques. In: IOP PUBLISHING, 1. JOURNAL of Physics: Conference Series. [S.l.: s.n.], 2020. v. 1479, p. 012086.
- GOMES, Pedro César Tebaldi. **Principais Algoritmos de Machine Learning | Qual escolher em 2022?** [S.l.: s.n.], 2022. Disponível em: <https://www.datageeks.com.br/algoritmos-de-machine-learning/>.
- GREGOIRE, J-M et al. P6568 Forecasting atrial fibrillation using machine learning techniques. **European Heart Journal**, Oxford University Press, v. 40, Supplement_1, ehz746–1157, 2019.

- GUIMARÃES, Lucas Marques Sathler; MEIRELES, Magali Rezende Gouvêa; ALMEIDA, Paulo Eduardo Maciel de. Avaliação das etapas de pré-processamento e de treinamento em algoritmos de classificação de textos no contexto da recuperação da informação. **Perspectivas em Ciência da Informação**, SciELO Brasil, v. 24, p. 169–190, 2019.
- HALL, John E. **Guyton & Hall. Tratado de fisiologia médica**. [S.l.]: Elsevier Health Sciences, 2021.
- HILL, Nathan R; AYOUBKHANI, Daniel; MCEWAN, Phil et al. Predicting atrial fibrillation in primary care using machine learning. **PLoS one**, Public Library of Science San Francisco, CA USA, v. 14, n. 11, e0224582, 2019.
- HILL, NR; AYOUBKHANI, D; LUMLEY, M et al. Machine learning to detect and diagnose atrial fibrillation and atrial flutter (AF/F) using routine clinical data. **Value in Health**, Elsevier, v. 21, s213, 2018.
- HUANG, Yung-Chuan et al. Integrated Machine Learning Decision Tree Model for Risk Evaluation in Patients with Non-Valvular Atrial Fibrillation When Taking Different Doses of Dabigatran. **International Journal of Environmental Research and Public Health**, MDPI, v. 20, n. 3, p. 2359, 2023.
- HUNG, Man et al. Using machine learning to predict 30-day hospital readmissions in patients with atrial fibrillation undergoing catheter ablation. **Journal of Personalized Medicine**, MDPI, v. 10, n. 3, p. 82, 2020.
- IBM, Cloud Education. **Redes Neurais**. [S.l.: s.n.], 2020. Disponível em: <https://www.ibm.com/br-pt/cloud/learn/neural-networks>.
- KANNA, R Kishore et al. CARDIAC ARRHYTHMIA DETECTOR USING CNN APPLICATION. **European Journal of Molecular & Clinical Medicine (EJMCM)**, v. 9, n. 09, p. 2022.
- LANDSTROM, Andrew P; DOBREV, Dobromir; WEHRENS, Xander HT. Calcium signaling and cardiac arrhythmias. **Circulation research**, Am Heart Assoc, v. 120, n. 12, p. 1969–1993, 2017.
- LIAQAT, Sidrah et al. Detection of atrial fibrillation using a machine learning approach. **Information**, MDPI, v. 11, n. 12, p. 549, 2020.
- LIMA, Jefferson da Costa et al. **Desafios para a adoção de Inteligência Artificial pelo Sistema Único de Saúde (SUS): ética, transparência e interpretabilidade**. 2022. Tese (Doutorado).
- LOBO, Luiz Carlos. Inteligência artificial e medicina. **Revista Brasileira de Educação Médica**, SciELO Brasil, v. 41, p. 185–193, 2017.
- LORGA FILHO, Adalberto et al. Diretriz de fibrilação atrial. **Arquivos Brasileiros de Cardiologia**, SciELO Brasil, v. 81, p. 2–24, 2003.

LOWN, Mark et al. Machine learning detection of Atrial Fibrillation using wearable technology. **PLoS One**, Public Library of Science San Francisco, CA USA, v. 15, n. 1, e0227401, 2020.

LUDERMIR, Teresa Bernarda. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, SciELO Brasil, v. 35, p. 85–94, 2021.

LUZ, Eduardo José da S et al. ECG-based heartbeat classification for arrhythmia detection: A survey. **Computer methods and programs in biomedicine**, Elsevier, v. 127, p. 144–164, 2016.

MAGALHÃES, LP et al. II Diretrizes brasileiras de fibrilação atrial. **Arquivos Brasileiros de Cardiologia**, SciELO Brasil, v. 106, p. 1–22, 2016.

MEURER, William J; TOLLES, Juliana. Logistic regression diagnostics: understanding how well a model predicts outcomes. **Jama**, American Medical Association, v. 317, n. 10, p. 1068–1069, 2017.

OPENAI. **OpenAI Website**. [S.l.: s.n.], 2021. [Online; accessed 8-Feb-2023]. Disponível em: <<https://openai.com>>.

RANSTAM, Jonas; COOK, JA. LASSO regression. **Journal of British Surgery**, Oxford University Press, v. 105, n. 10, p. 1348–1348, 2018.

SAHOO, S et al. Machine learning approach to detect cardiac arrhythmias in ECG signals: a survey. **Irbm**, Elsevier, v. 41, n. 4, p. 185–194, 2020.

SANTOS, Hellen Geremias dos. **Comparação da performance de algoritmos de machine learning para a análise preditiva em saúde pública e medicina**. 2018. Tese (Doutorado) – Universidade de São Paulo.

SARACCO, Roberto. **Congrats Xiaoyi, You are Now a Medical Doctor!** [S.l.]: IEEE Future Directions, dez. 2017. Disponível em:

<<https://cmte.ieee.org/futuredirections/2017/12/02/congrats-xiaoyi-you-are-now-a-medical-doctor/>>.

SAÚDE, Ministério da. **Sistema Único de Saúde**. [S.l.: s.n.], Acessado el 22 de febrero de 2023. <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/s/sus>.

TORTORA, Gerard J; DERRICKSON, Bryan. **Corpo Humano-: Fundamentos de Anatomia e Fisiologia**. [S.l.]: Artmed Editora, 2016.

TRAYANOVA, Natalia A; POPESCU, Dan M; SHADE, Julie K. Machine learning in arrhythmia and electrophysiology. **Circulation Research**, Am Heart Assoc, v. 128, n. 4, p. 544–566, 2021.

WASIMUDDIN, Muhammad et al. Stages-based ECG signal analysis from traditional signal processing to machine learning approaches: A survey. **IEEE Access**, IEEE, v. 8, p. 177782–177803, 2020.

ZHENG, Xiaohan et al. Using machine learning to predict atrial fibrillation diagnosed after ischemic stroke. **International Journal of Cardiology**, Elsevier, v. 347, p. 21–27, 2022.