

**CENTRO UNIVERSITÁRIO UNIFACVEST
CIÊNCIA DA COMPUTAÇÃO
UÉLITON DE BRITO VIANA**

**AutoBeat: Classificação de Arritmias Cardíacas em
Eletrocardiogramas de 12 Derivações Usando Redes Neurais
Convolucionais em um Ambiente Web
ÁREA DE INTELIGÊNCIA ARTIFICIAL NA MEDICINA**

Trabalho de Conclusão do Curso de
Ciência da Computação, apresentado
à Banca Examinadora para análise e
aprovação no Centro Universitário
Unifacvest.

Aluno: Uéilton de Brito Viana
Orientadora: Juliana Facchini
Orientador: Márcio José Sembay
Orientador: Igor Muzeka

LAGES, SC, 2023

RESUMO

A automação na classificação de eletrocardiogramas (ECGs) é crucial na medicina contemporânea para diagnósticos e tratamento cardíaco. Apresentamos o AutoBeat, uma plataforma web que utiliza Redes Neurais Convolucionais (CNNs) Unidimensionais (1D) para categorizar ECGs com precisão. Estes representam a atividade elétrica cardíaca, cuja interpretação é complexa. O AutoBeat simplifica o processo, fornecendo relatórios técnicos e métricas do modelo classificador, apoiando profissionais e reduzindo erros. Doenças cardiovasculares (DCVs) são a principal causa global de morte, totalizando cerca de 17,9 milhões de óbitos anualmente, conforme a OMS. O modelo treinado em quatro categorias de ritmos cardíacos alcançou precisão de 0,935, escore F1 de 0,940 e média de acurácia categórica de 0,955 nos dados da Universidade Chapman em colaboração com o Hospital Popular de Shaoxing. Limitações incluem tamanho da amostra e variedade de ritmos cardíacos abordados. Futuras melhorias visam expandir dados, incluir mais classes de ritmos cardíacos, validação clínica e tornar o modelo acessível em dispositivos com recursos limitados. Considerações refletem nosso compromisso com o contínuo desenvolvimento do AutoBeat e seu impacto benéfico na prática cardiológica.

Palavras chave: AutoBeat, ECG, Classificação automatizada, Redes Neurais Convolucionais 1D (CNNs 1D), Arritmias cardíacas;

ABSTRACT

Automation in electrocardiogram (ECG) classification plays a pivotal role in contemporary medicine for cardiac diagnostics and treatment. We introduce AutoBeat, a web-based platform employing 1D Convolutional Neural Networks (CNNs) for precise categorization of ECGs. These ECGs represent cardiac electrical activity, interpretation of which can be complex. AutoBeat streamlines this process, providing technical reports and model classifier metrics, aiding professionals and reducing errors. Cardiovascular diseases (CVDs) stand as the leading global cause of mortality, accounting for approximately 17.9 million deaths annually, according to the WHO. The model, trained on four categories of cardiac rhythms, achieved an accuracy of 0.935, F1 score of 0.940, and mean categorical accuracy of 0.955 on the dataset from Chapman University in collaboration with Shaoxing Popular Hospital. Limitations encompass sample size and the range of addressed cardiac rhythms. Future enhancements aim to expand the dataset, incorporate additional classes of cardiac rhythms, conduct clinical validation, and enhance model accessibility on resource-constrained devices. These considerations underscore our commitment to the ongoing development of AutoBeat and its beneficial impact on cardiology practice.

Keywords: AutoBeat, ECG, Automated Classification, 1D Convolutional Neural Networks (1D CNNs), Cardiac Arrhythmias.

1. Introdução

O ECG avalia a atividade elétrica do coração, registrando os impulsos que coordenam as contrações, fornecendo informações sobre ritmo, velocidade dos batimentos e possíveis alterações no ciclo (HOPKINS MEDICINE, 2023) [1]. Erros na leitura podem levar a decisões médicas inadequadas e desfechos negativos. Com o avanço da tecnologia, soluções automatizadas estão transformando a forma como lidamos com dados, incluindo ECGs, como destacado em trabalhos anteriores (Raghunath et al., 2020) [2], (Yildirim et al., 2019) [3] e (Yildirim O et al., 2020) [4]. Na medicina contemporânea, a automatização da classificação de ECGs tem desempenhado um papel fundamental no diagnóstico e tratamento de doenças cardíacas. Este trabalho explora a importância da classificação automática de ECGs, especialmente com o uso de CNNs 1D. Apresenta o AutoBeat, um sistema que não apenas classifica ECGs, mas também fornece um relatório ao usuário. Como o AutoBeat pode aprimorar a prática médica ao facilitar a detecção e classificação de

problemas cardíacos através de análises precisas de eletrocardiogramas e relatórios técnicos?

1.1 Objetivo Geral

Este projeto propõe a criação de um sistema online que possa auxiliar os profissionais na detecção e classificação de problemas cardíacos, utilizando técnicas avançadas de inteligência artificial.

1.2 Objetivos Específicos

Para alcançar o objetivo geral, os seguintes objetivos específicos serão buscados:

- Desenvolver um sistema online capaz de fornecer uma análise preliminar de dados de eletrocardiograma, fornecendo um relatório técnico.
- Desenvolver um modelo que alcance uma precisão acima de 90%.
- Possibilitar a consulta de relatórios anteriores, fornecendo um histórico das classificações.
- Desenvolver uma interface de usuário que seja intuitiva e acessível, visando atender tanto a profissionais de saúde quanto a usuários leigos, independentemente de sua familiaridade com tecnologia ou medicina.
- Garantir a privacidade e segurança dos pacientes, tornando os dados anônimos antes da utilização no sistema, seguindo as normas de proteção de dados presentes na lei nº 13.709/2018 (Lei Geral de Proteção de Dados) (BRASIL, 2018, Art. 7º, Inciso IV) [5].

2. Revisão da Literatura

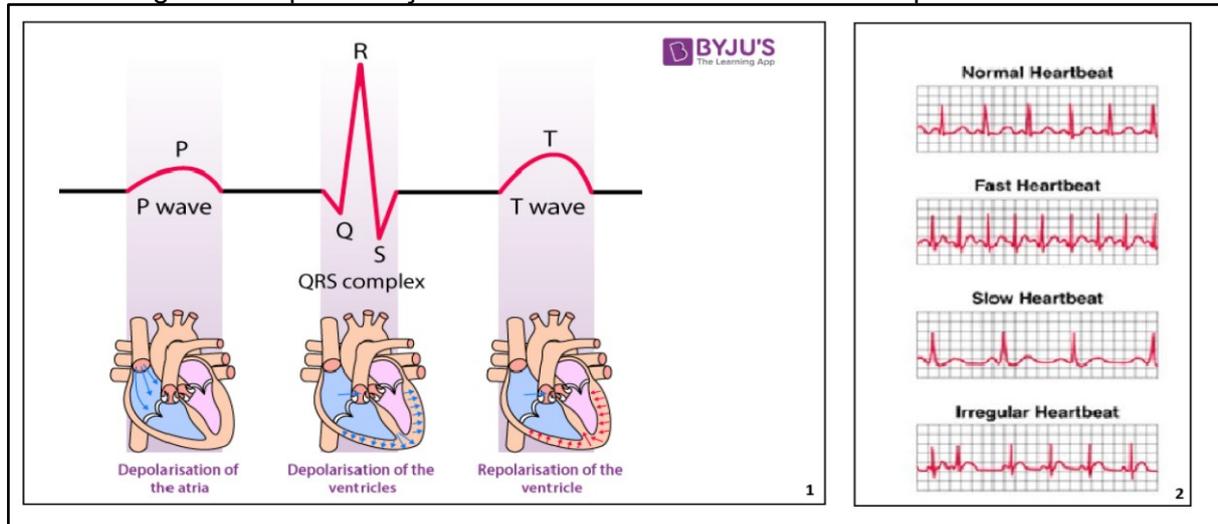
Nesta seção, será realizada uma revisão da literatura acerca da classificação de ritmos cardíacos em sinais de ECGs com o uso de CNNs. O uso de ferramentas que unem o estado da arte em tecnologia à saúde pode contribuir para a detecção precoce destas enfermidades, contribuindo para uma melhora na saúde.

2.1 Cardiologia e Tecnologia na Redução de Riscos Cardíacos

A Figura 1 representa a atividade elétrica do coração em um ciclo cardíaco, com batimentos classificados como Normais, Rápidos, Lentos e Irregulares. Arritmias cardíacas são um desafio de saúde pública, elevando o risco de eventos cardiovasculares graves como insuficiência cardíaca, acidente vascular cerebral (AVC) e morte súbita [1]. Doenças cardiovasculares (DCV) são a principal causa de mortalidade global, totalizando cerca de 17,9 milhões de óbitos anualmente, segundo a Organização Mundial da Saúde (OMS) [6]. Mais de 80% dessas fatalidades são atribuíveis a eventos como ataques cardíacos e derrames, ressaltando a urgência de abordagens preventivas [6]. A aplicação de Redes Neurais é crucial para enfrentar o desafio das DCVs, conforme enfatizado pela OMS, através do desenvolvimento e

aplicação de algoritmos de aprendizado profundo para análise precisa de dados cardíacos.

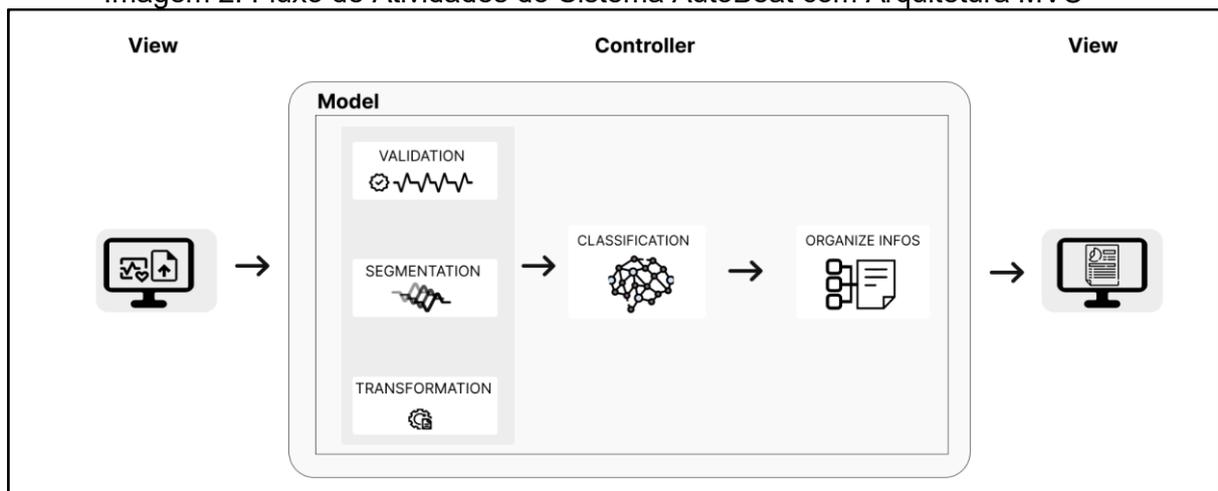
Imagem 1: Representação da Atividade Elétrica Cardíaca e Tipos de Batimentos



Referência dos links das imagens no Tópico 7, nos itens img 1.1 e img 1.2.

À medida que a tecnologia avança, a quantidade de dados para análise cresce, impulsionando a necessidade de métodos mais eficientes de captura e análise. A automação das classificações se torna, portanto, uma ferramenta crucial, permitindo a criação de sistemas com rotinas predefinidas que aguardam a entrada de dados e retornam análises, como um relatório. O fluxo de atividades do sistema, na Figura 2, ilustra o funcionamento do AutoBeat, baseado na arquitetura MVC (Model-View-Controller), e a função do Controller na gestão das etapas após receber os dados via upload. O Modelo é responsável pelo pipeline de dados, desde a validação inicial até a entrega de informações organizadas para análise e interpretação pelo usuário do site na view.

Imagem 2: Fluxo de Atividades do Sistema AutoBeat com Arquitetura MVC



Próprio Autor, 2023.

2.2 Aprendizado de Máquina

O Machine Learning (ML), subárea da Inteligência Artificial (IA), visa criar algoritmos que aprendem com dados, eliminando a necessidade de programação para

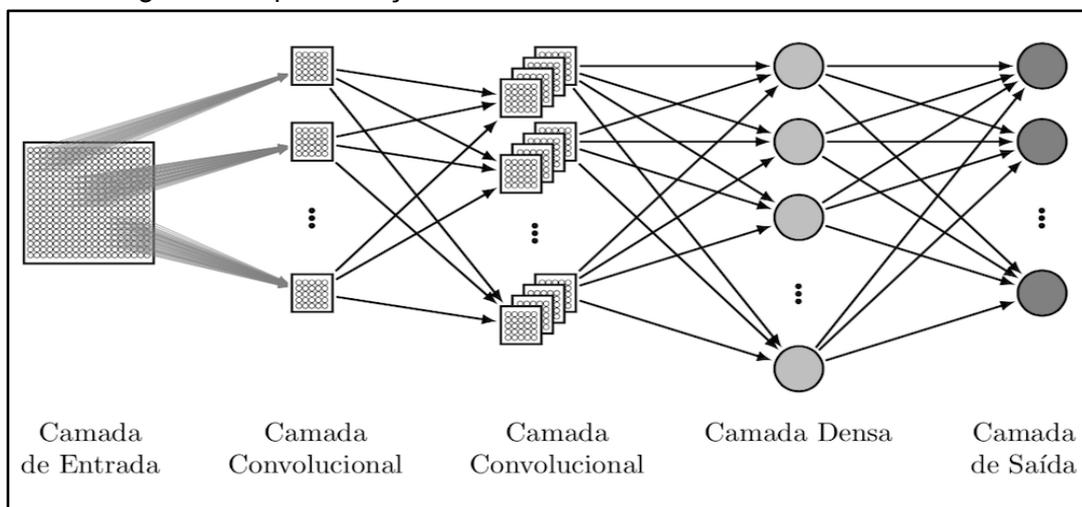
casos específicos (Microsoft, 2022) [7]. As principais abordagens incluem o supervisionado, que utiliza dados rotulados para classificar novos dados não vistos, e o não-supervisionado, que identifica padrões nos dados para agrupá-los ou analisá-los sem a necessidade de agrupamento prévio (IBM, 2020) [8]. Optamos pelo aprendizado supervisionado, no qual cardiologistas especializados analisaram e rotularam os dados de cada paciente, conforme detalhado no artigo de referência (Zheng et al., 2020) [9].

É crucial estar ciente do fenômeno do overfitting durante a aplicação de técnicas de aprendizado supervisionado. Isso ocorre quando um modelo se ajusta excessivamente aos dados de treinamento, capturando até mesmo o ruído nos dados, o que pode levar a uma performance inferior em dados não vistos. Portanto, é importante implementar estratégias para mitigar o overfitting e garantir que o modelo generalize bem para novos casos.

2.3 Aprendizado profundo e redes neurais

O Deep Learning (DL) é uma subdivisão do ML que utiliza redes neurais artificiais para executar tarefas complexas de reconhecimento de padrões, como identificação de imagens e detecção de insights nos dados (Microsoft, 2023) [10]. A imagem 3 (Sakurai, 2023) ilustra uma rede neural convolucional responsável pelo processamento dos dados. Ao término desse processo, a rede gera um conjunto de valores numéricos a ser analisado e interpretado de acordo com a natureza específica do problema a ser solucionado, como a identificação de batimentos cardíacos normais, arrítmicos ou a categoria à qual o batimento pertence.

Imagem 3: Representação de uma Rede Neural Convolucional



Sakurai, Rafael (2023).

2.4 Otimização Bayesiana

Durante os experimentos para encontrar a melhor arquitetura do modelo, os hiperparâmetros desempenham um papel crítico, incluindo o número de blocos convolucionais e densos, filtros de convolução, taxa de dropout, configuração da atenção multi-cabeça e total de neurônios nas camadas conectadas.

Os hiperparâmetros foram otimizados usando um método sofisticado de otimização Bayesiana (Greenhill, S. et al., 2020) [11]. Esse método se baseia em

cálculos probabilísticos dos valores anteriores juntamente do resultado do modelo. Avalia o desempenho da função de perda em um conjunto de validação durante o treinamento, permitindo uma exploração eficiente do espaço de hiperparâmetros e encontrando valores de configuração que maximizam o desempenho da rede. Essa abordagem foi preferida em relação a métodos como GridSearch e RandomSearch devido à sua eficácia com um grande número de parâmetros ajustáveis e combinações possíveis, sendo significativamente mais eficaz em projetos experimentais em que a função a ser otimizada é consideravelmente cara.

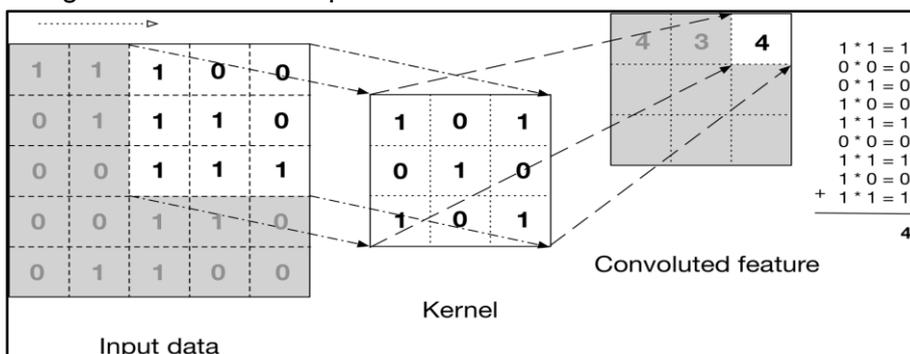
3. Background Matemático

Nesta seção, serão apresentados conceitos matemáticos fundamentais para o aprendizado profundo, área de grande sucesso na solução de problemas complexos em diversos campos. Serão discutidas equações de convolução e MaxPooling e função de ativação ReLU, utilizadas em CNNs. Também será abordado o uso do gradiente descendente para otimizar o desempenho da rede neural através do método de backpropagation. Além disso, abordaremos o método de atenção multi-cabeça, onde aparece pela primeira vez no trabalho de pesquisa realizado por Ashish Vaswani e demais pesquisadores em (Vaswani et al., 2017) [12].

3.1 Equação de convolução 1D

As camadas de convolução são elementos fundamentais em redes neurais convolucionais, são responsáveis por extrair características relevantes dos dados de entrada (Serkan K, et al. 2020) [13]. Trata-se de uma operação matemática que consiste em aplicar um filtro deslizante - uma matriz, por exemplo - em toda a imagem de entrada, com o objetivo de produzir uma nova representação que destaque regiões importantes. A Imagem 4 (MANDAL, M., 2022) ilustra a aplicação de um filtro 3x3 de convolução 2D e o resultado, sendo uma matriz menor. À direita da figura, é mostrado o cálculo para obtenção do valor 4 na matriz resultado.

Imagem 4: Matriz 3x3 a partir de uma 5x5 e um filtro/kernel deslizante 3x3.



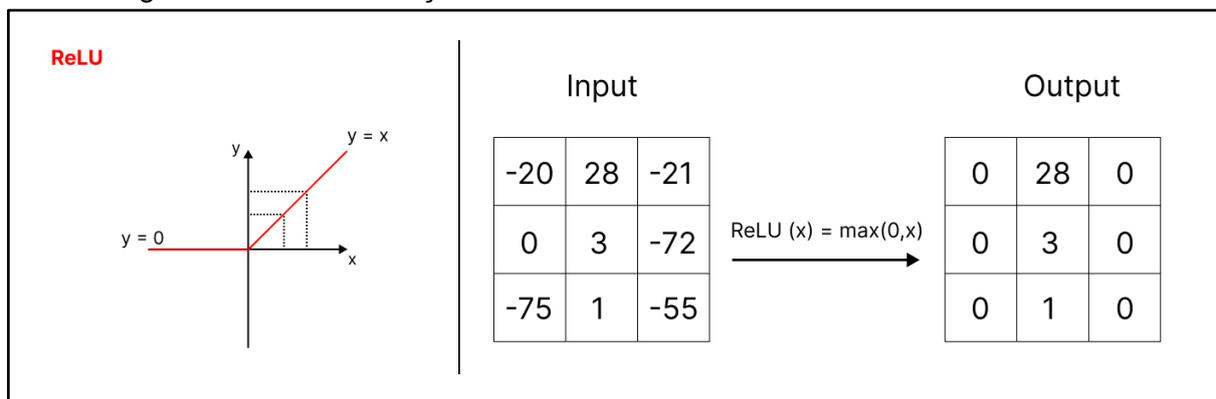
Introduction to convolutional neural networks (CNN). (MANDAL, M., 2022).

Considerando a natureza unidimensional (1D) dos nossos dados, decidimos empregar um vetor 1x3. Aqui, as três linhas denotam distintos momentos temporais, ao passo que a única coluna concentra-se na característica específica em análise, ao longo do tempo, sendo neste caso, cada um dos eletrodos. No entanto, os princípios e o processo permanecem os mesmos da Imagem 4, com o filtro deslizando (da esquerda para a direita) sobre a entrada para destacar características relevantes. Essa adaptação permite uma análise eficaz das informações, resultando em uma representação refinada dos dados.

3.2 Funções de ativação ReLU

O estudo de (Agarap, 2018) [14] demonstra o potencial da função ReLU em aplicações práticas de aprendizado de máquina em larga escala. Essa função permite a ativação e desativação de neurônios na rede neural, tornando-a capaz de aprender e generalizar características para novos dados. A função ReLU retorna 0 para valores menores que 0 ou o próprio valor, caso seja maior. A Imagem 4 ilustra uma matriz 3x3 sendo submetida à função ReLU e suas respectivas saídas, além de sua representação gráfica junto de sua fórmula. Nessa abordagem de Agarap, a ReLU foi aplicada não apenas como função de ativação nas camadas ocultas, mas também como função de classificação na camada final da rede neural.

Imagem 5: Gráfico da função e Matriz de Dados sendo submetida à ReLU



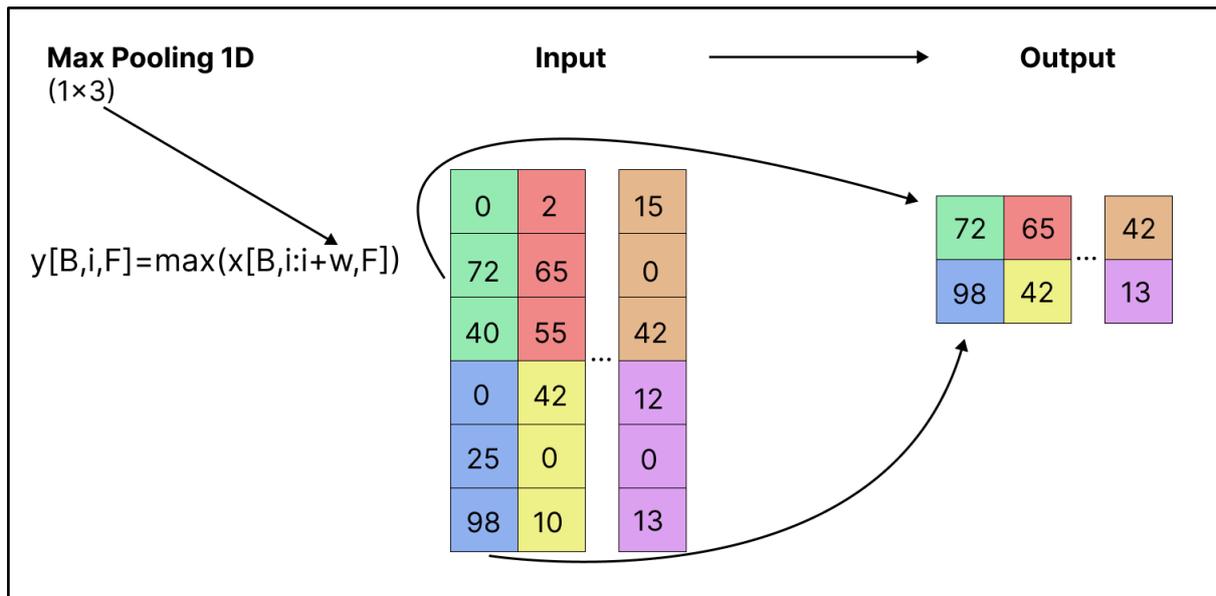
Próprio Autor, 2023.

3.3 Camada de MaxPooling

O MaxPooling é uma técnica eficaz que aprimora a generalização e ajuda a mitigar o overfitting, reduzindo a dimensionalidade dos dados. Ele opera por meio de um processo deslizante que percorre os dados, semelhante à operação de convolução, resultando na redução das dimensões da camada atual. Nesse processo, ele seleciona o valor máximo de cada região analisada, destacando o elemento mais representativo, que é frequentemente considerado o "ponto forte" daquela região.

No exemplo apresentado na Imagem 6, observa-se a aplicação do MaxPooling 1D, acompanhada de uma representação de sua equação subjacente. Para cada coluna F em um lote de dados B , o MaxPooling 1D identifica e retorna o valor máximo dentro do intervalo que se estende de i até $i + w$, onde w denota o tamanho da janela de pooling. No contexto apresentado, o tamanho da janela é especificado como 3.

Imagem 6: Exemplo de MaxPooling 1D e sua Operação em Dados Unidimensionais



Próprio Autor, 2023.

3.4 Atenção Multi-Cabeça

A Atenção Multi-Cabeça, um conceito fundamental no aprendizado profundo, foi introduzida no influente trabalho de pesquisa "Attention Is All You Need" [12], em colaboração com Ashish Vaswani. Essa técnica revolucionária impulsionou avanços no processamento de sequências e na compreensão de contextos em tarefas de aprendizado de máquina.

A Atenção Multi Cabeça possibilita que uma rede neural se concentre em diferentes partes da entrada simultaneamente, aprendendo representações ponderadas de informações em diferentes posições. Isso é especialmente útil para tarefas envolvendo sequências, como processamento de linguagem natural, tradução automática e, no contexto deste trabalho, análise de eletrocardiogramas.

Essencialmente, a Atenção Multi Cabeça amplia a capacidade de atenção das redes neurais, permitindo que ponderem a importância de diferentes elementos de entrada de forma independente em várias "cabeças" de atenção. Isso facilita a captura de relacionamentos complexos entre os dados de entrada, resultando em um desempenho aprimorado em tarefas de classificação e compreensão de padrões.

3.5 Backpropagation com Gradiente descendente e Função de Custo

Na área de treinamento de Redes Neurais, o processo de backpropagation (Hecht-Nielsen, 1989) [15] é um conceito-chave na etapa de aprendizado profundo. Sua contribuição estabeleceu os alicerces para a compreensão e aplicação da retropropagação em redes neurais, fornecendo uma base sólida para o desenvolvimento de abordagens mais avançadas.

No contexto da retropropagação, os pesos e vieses são cruciais para determinar a contribuição de cada neurônio, impactando diretamente na saída final do modelo.

O Gradiente Descendente (GD) é uma família de algoritmos que calculam o

vetor gradiente de uma função diferenciável, ajustando iterativamente os parâmetros do modelo para minimizar o erro durante o treinamento. No entanto, o GD pode ficar preso em mínimos locais, afetando o desempenho do modelo. Para lidar com isso, o algoritmo Adam (Diederik P. Kingma, Jimmy Lei Ba, 2015) [16] foi escolhido. Ele busca a minimização da função de perda, representada pela Entropia Cruzada Categórica, e é crucial que a função de ativação seja diferenciável para aplicar o algoritmo de backpropagation.

4. METODOLOGIA

Nesta seção, forneceremos uma visão geral dos métodos adotados no projeto, incluindo a fonte dos dados, processos de preparação e processamento, além das ferramentas e frameworks utilizados e a arquitetura da rede neural desenvolvida.

4.1 Os Dados da Pesquisa

Os dados utilizados neste projeto foram obtidos a partir de arquivos CSV contendo sinais de eletrocardiograma (ECG) e disponibilizados através de um esforço conjunto da Universidade Chapman (Orange, Califórnia, nos Estados Unidos) e do Hospital Popular de Shaoxing (Hangzhou, China) (Zheng et al., 2020) [9].

A interpretação de ECGs requer especialização, pois os profissionais de saúde devem identificar com habilidade padrões de ondas, intervalos dos eventos, segmentos e arritmias, mesmo diante de possíveis interferências de ruído e variações individuais. Assim, frequentemente, os dados precisam passar por um pré-processamento cuidadoso antes de serem submetidos aos modelos de classificação.

A equipe responsável pela disponibilização dos dados realizou uma série de etapas de preparação e processamento. Isso incluiu a aplicação de um filtro passa-baixo Butterworth para eliminar sinais com frequência acima de 50 Hz. Além disso, foram efetuados ajustes na curva LOESS para corrigir desvios na linha de base e o método Non Local Means (NLM) foi aplicado aos dados para tratar os ruídos residuais como detalhado no trabalho de (Zheng et al., 2020) [9].

4.2 Filtragem e Pré-Processamento dos Dados

Para esta análise, selecionamos uma subamostra de 1.000 pacientes de um conjunto de dados mais amplo de 10.000 pacientes (Zheng et al., 2020) [9]. Cada paciente é representado por um arquivo CSV com 5.000 linhas (correspondendo a 10 segundos de coleta) e 12 colunas representando os 12 eletrodos utilizados. Os dados foram previamente analisados e rotulados por cardiologistas antes de serem disponibilizados ao público (Zheng et al., 2020) [9].

Após a coleta dos dados [17], foram realizadas etapas de filtragem, validação da integridade dos arquivos e seleção de classes. A validação ajudou a filtrar arquivos com irregularidades, como linhas ou colunas faltantes e valores ausentes.

Em seguida, aplicaram-se etapas de segmentação para reduzir a dimensionalidade dos dados, uma técnica promissora nos testes. Juntamente com a segmentação, houve sobreposição entre os segmentos para evitar perda abrupta de informações e a conversão dos dados para o formato tensorial, conforme necessário para o modelo. Esse processo pode ser visualizado na Imagem 2 e é crucial para

garantir a qualidade e adequação dos dados ao modelo, que será discutido posteriormente.

4.3 Ferramentas e Frameworks

O desenvolvimento deste projeto foi realizado no ambiente do Google Colab, uma plataforma de computação em nuvem que oferece recursos computacionais robustos com acesso gratuito limitado. Esses recursos incluem acesso à GPU de alto desempenho Tesla T4 com VRAM de 16GB e memória RAM de 12GB. Os recursos foram suficientes e essenciais para acelerar operações computacionais intensivas, como os cálculos tensoriais, usados no treinamento de modelos de redes neurais.

Para facilitar o acesso e a utilização do modelo CNN desenvolvido, foi criado um site que hospeda a aplicação. O site foi desenvolvido utilizando HTML, CSS e JavaScript para a construção da interface do usuário, garantindo que o site seja intuitivo e responsivo. A implementação do backend foi realizada com FastAPI e Uvicorn, escolhidos por sua alta performance e capacidade de lidar com requisições assíncronas. O FastAPI gerencia as rotas e a lógica do servidor, enquanto o Uvicorn atua como o servidor de aplicação ASGI (Asynchronous Server Gateway Interface).

O desenvolvimento seguiu uma arquitetura MVC (Model-View-Controller). O Model gerencia a lógica de dados e interage com o modelo CNN, a View é responsável pela interface do usuário, e o Controller manipula as entradas do usuário e atualiza o modelo e a visualização. O site foi projetado para receber arquivos de ECG, processar esses dados utilizando o modelo CNN e apresentar os resultados de forma clara e detalhada na interface web, permitindo que os profissionais de saúde façam análises e tomem decisões informadas.

4.4 Arquitetura da Rede

O modelo mais eficaz consiste em sete blocos convolucionais, um módulo de atenção e quatro blocos de camadas totalmente conectadas, cada um com funções específicas na extração e aprendizado de características dos dados.

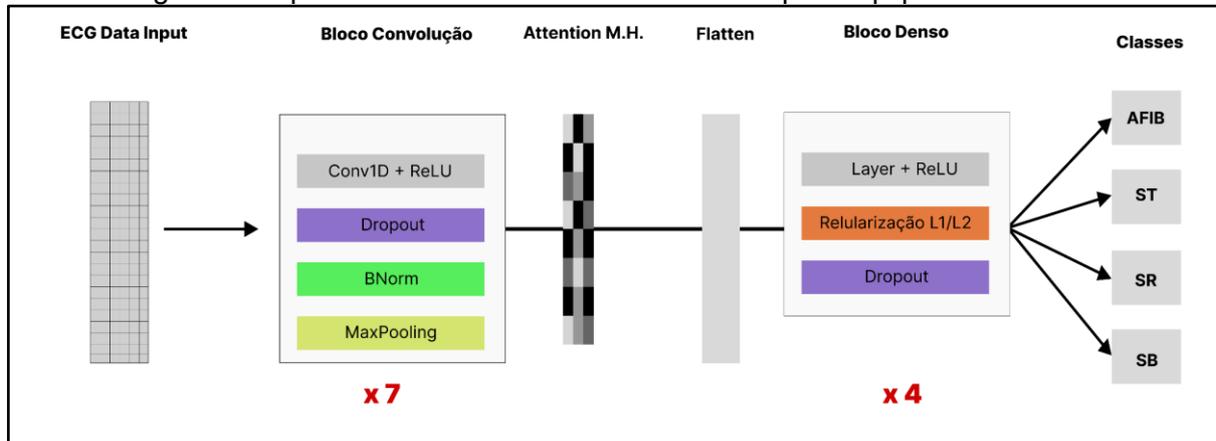
No primeiro bloco convolucional, aplicamos uma camada de convolução para detectar padrões locais relevantes. Usamos Normalização em Lote para estabilizar o aprendizado, incluindo Regularização Elastic-Net, que combina penalidades L1 e L2 (De Mol, De Vito, Rosasco, 2009) [19]. Após isso, aplicamos Max Pooling 1D para reduzir a dimensionalidade dos recursos. Para mitigar o overfitting, adicionamos camadas de Dropout após cada MaxPooling1D.

Enfrentamos desafios significativos durante o desenvolvimento, lidando com incompatibilidades entre partes da arquitetura, mas isso ajudou a encontrar a melhor arquitetura. As etapas de Convolução, Normalização, MaxPooling e Dropout se repetem em cada um dos sete blocos convolucionais, configurados individualmente com hiperparâmetros otimizados usando técnicas de otimização bayesiana. Isso enriquece a capacidade do modelo de aprender com os dados ao longo das camadas e lidar com os desafios da tarefa.

O módulo de atenção é essencial para identificar relações temporais nos sinais de ECG.

Depois da camada de atenção, os recursos extraídos passam por quatro camadas totalmente conectadas, seguidas de Dropout em cada uma, com tamanhos de neurônios (136, 68, 34 e 17). A última camada é uma camada de saída com quatro neurônios e ativação Softmax para classificar os ritmos cardíacos.

Imagem 7: Arquitetura da rede neural desenvolvida pela equipe



Próprio Autor, 2023.

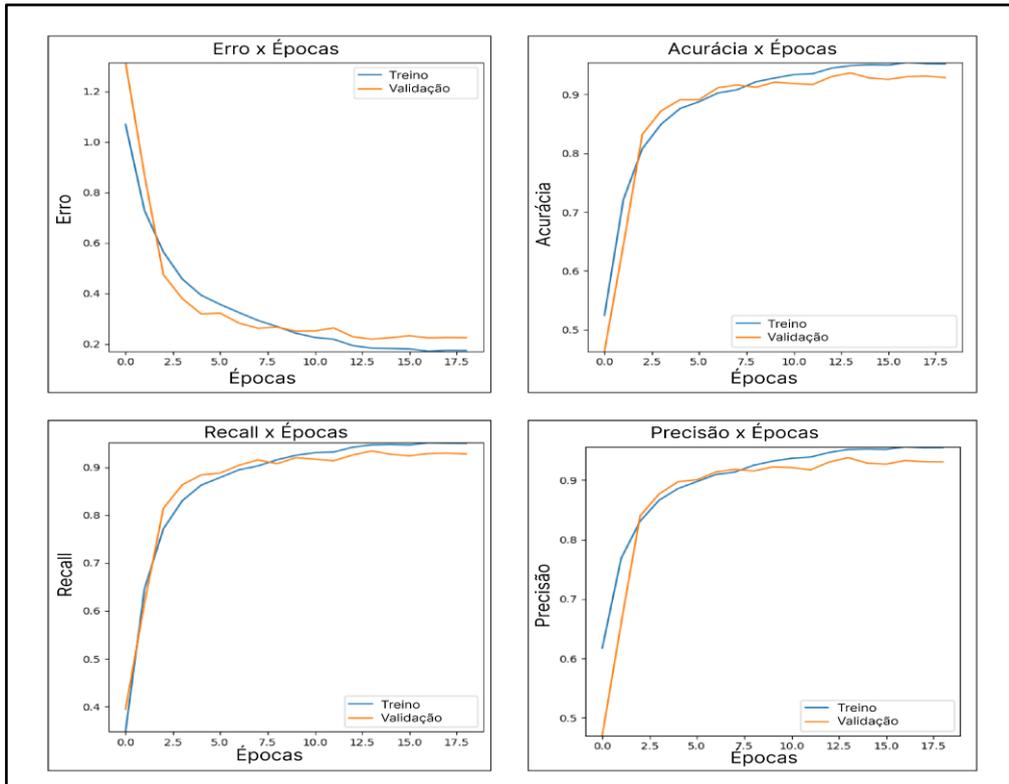
5. Resultados

O desempenho do modelo foi avaliado usando o conjunto de dados do (Zheng et al., 2020) [9], alcançando uma precisão 0,935 e um escore F1 de 0,940 para ambos. Os experimentos demonstraram que a função de Entropia Cruzada Categórica se ajusta bem às flutuações nos dados, atingindo uma acurácia categórica superior a 95% nos dados de teste.

A rede foi treinada e ajustada com dados de treinamento e validação, otimizando seu desempenho. Os dados de teste foram usados posteriormente, sem exposição prévia. Além disso, 1% dos dados foram reservados para uso futuro pelos usuários do AutoBeat que não possuem um arquivo em sua máquina para fazer o upload.

Na Figura 8, é possível observar o desempenho das métricas ao longo das épocas. Todos os gráficos exibem um crescimento exponencial, indicando um rápido aprendizado inicial do modelo. Após 17 épocas, as taxas de sensibilidade e especificidade atingiram níveis notáveis, indicando uma eficaz capacidade na identificação de múltiplas categorias de ritmos cardíacos. A alta precisão reduziu ao mínimo os erros de classificação, e a acurácia geral do modelo na classificação de diversas categorias de ECGs foi evidente. Além disso, o modelo manteve sua estabilidade de aprendizado, apesar da quantidade limitada de parâmetros treináveis na rede e do início com pesos aleatórios, refletindo os esforços bem-sucedidos da equipe para alcançar esses objetivos durante o projeto.

Imagem 8: Desempenho do Modelo nas Épocas de Treinamento e Validação

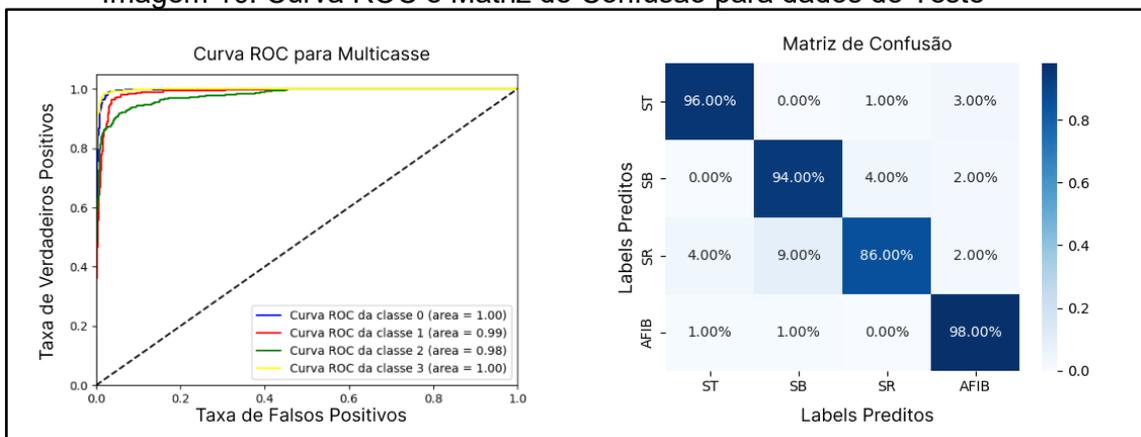


Próprio Autor, 2023.

A avaliação da acurácia do modelo foi conduzida utilizando o método de bootstrap, essencial para garantir estimativas confiáveis em cenários com possíveis outliers. Com 50 iterações, obtivemos uma média estável de 95,66% de acurácia, indicando consistência no desempenho do modelo.

A imagem 9 apresenta a Curva ROC para Múltiplas Categorias e a Matriz de Confusão do modelo avaliado. Essas representações gráficas oferecem insights importantes sobre o desempenho da classificação multiclasse. O modelo mostra habilidade geral para distinguir as classes, indicando boa capacidade de discriminação. No entanto, enfrenta dificuldades ao diferenciar entre as classes 'Bradicardia Sinusal' (SB) e 'Ritmo Sinusal' (SR), conforme evidenciado na Matriz de Confusão. Isso destaca a necessidade de uma análise mais detalhada para compreender os padrões específicos de confusão e considerar estratégias de melhoria para a distinção entre essas classes em futuras iterações do modelo.

Imagem 10: Curva ROC e Matriz de Confusão para dados de Teste



Próprio Autor, 2023.

6. Limitações e Considerações

O sistema AutoBeat, uma rede neural para classificação de arritmias, apresenta desafios comuns em modelos de aprendizado de máquina, como degradação ao longo do tempo e esquecimento. Sugere-se o Treinamento Incremental como solução. O estudo também aponta limitações relacionadas ao tamanho da amostra e variedade de ritmos cardíacos, afetando a generalização. Validações clínicas e colaborações com profissionais de saúde são cruciais. A interpretabilidade do modelo é uma preocupação, exigindo técnicas para tornar o AutoBeat transparente. Apesar das limitações, o compromisso com expansão de dados, validação clínica e interpretabilidade promete tornar o AutoBeat uma ferramenta valiosa. Na imagem 11 abaixo é possível observar a captura de tela na aba de relatórios do sistema. O projeto alcançou os objetivos levantados no seu início, atingindo mais de 90% de precisão na classificação de ritmos cardíacos, oferecendo uma interface amigável e segura em conformidade com a LGPD, aprimorando o diagnóstico e tratamento de doenças cardíacas, superando expectativas.

Imagem 11: Prints do Sistema AutoBeat na aba de Relatórios.



Próprio Autor, 2023.

7.) Referências Bibliográficas:

[1] Electrocardiogram. Disponível em:

<https://www.hopkinsmedicine.org/health/treatment-tests-and-therapies/electrocardiogram>. Acesso em: 18 fev. 2023.

[2] Raghunath, S. et al. (2020). Prediction of mortality from 12-lead electrocardiogram voltage data using a deep neural network. *Nature Medicine*. <https://www.nature.com/articles/s41591-020-0870-z>. Acesso em: 10 fev. 2023.

[3] Yildirim, O., Baloglu, U. B., Tan, R. S., Ciaccio, E. J., & Acharya, U. R. (2019). A new approach for arrhythmia classification using deep coded features and LSTM networks. *Europe PMC*. <https://europepmc.org/article/MED/31200900>. Acesso em:

10 abr. 2023.

[4] Yildirim O, Talo M, Ciaccio EJ, Tan RS, Acharya UR. (2019). Accurate deep neural network model to detect cardiac arrhythmia on more than 10,000 individual subject ECG records. Europe PMC. <https://europepmc.org/article/pmc/7477611>. Acesso em: 11 abr. 2023.

[5] BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Dispõe sobre a proteção de dados pessoais e altera a Lei nº 12.965, de 23 de abril de 2014 (Marco Civil da Internet). Diário Oficial da União, Brasília, DF, 15 ago. 2018. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm. Acesso em: 02 out. 2023.

[img 1.1] <https://cdn1.byjus.com/wp-content/uploads/2021/05/Electrocardiogram.png>. Acesso em: 02 set. 2023.

[img 1.2] <https://th.bing.com/th/id/R.d01adeab44df2afe25636cf6c6219fd9?rik=OtS6SISpIxfC Ug&pid=ImgRaw&r=0>. Acesso em: 02 set. 2023.

[6] Cardiovascular diseases. Disponível em: https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_1. Acesso em 15/10/2023.

[7] V-HANKI. What is machine learning? Disponível em: <https://learn.microsoft.com/en-us/azure/cloud-adoption-framework/innovate/best-practices/machine-learning>. Acesso em: 2 abr. 2023.

[8] Supervised vs. Unsupervised learning: What's the difference? Disponível em: <https://www.ibm.com/cloud/blog/supervised-vs-unsupervised-learning>. Acesso em: 2 abr. 2023.

[9] Zheng, J., Zhang, J., Danioko, S., Yao, H., Guo, H., & Rakovski, C. (2020). A 12-lead electrocardiogram database for arrhythmia research covering more than 10,000 patients. Scientific Data, <https://doi.org/10.1038/s41597-020-0386-x>.

[10] Deep learning vs. machine learning - Azure Machine Learning. Disponível em: <https://learn.microsoft.com/en-us/azure/machine-learning/concept-deep-learning-vs-machine-learning>. Acesso em: 20 apr. 2023.

[img 3] Implementando a estrutura de uma Rede Neural Convolutacional utilizando o MapReduce do Spark. Rafael Sakurai, 20 dez. 2017. Disponível em: <https://www.sakurai.dev.br/assets/images/posts/2017-12-20-cnn-mapreduce.png>. Acesso em: 17 abr. 2023.

[11] Greenhill, S., Rana, S., Gupta, S., Vellanki, P., & Venkatesh, S.(2020). Bayesian Optimization for Adaptive Experimental Design: A Review. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8957442>. Acesso em: 02 out. 2023.

[12] Ashish Vaswani, et al. 2017. Attention Is All You Need. Disponível em: <https://arxiv.org/abs/1706.03762>. Acesso em: 07 out. 2022.

[13] Serkan Kiranyaz, et al. 2020. 1D convolutional neural networks and applications: A survey. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0888327020307846>. Acesso em: 02 out. 2023.

[14] Agarap, Abien Fred, 2018. Deep learning using rectified linear units (relu). Disponível em: <https://arxiv.org/abs/1803.08375>. Acesso em: 07 set. 2023.

[15] Hecht-Nielsen, "Theory of the backpropagation neural network," International 1989 Joint Conference on Neural Networks, Washington, DC, USA, 1989, pp. 593-605 vol.1, doi: 10.1109/IJCNN.1989.118638.

[16] Diederik P. Kingma, Jimmy Lei Ba, 2015. Adam: A method for stochastic optimization. Disponível em: <https://arxiv.org/pdf/1412.6980.pdf>. Acesso em: 07 set. 2023.

[17] Zheng, Jianwei; Rakovski, Cyril; Danioko, Sidy; Zhang, Jianming; Yao, Hai; Hangyuan, Guo (2019). A 12-lead electrocardiogram database for arrhythmia research covering more than 10,000 patients. figshare. Collection. <https://doi.org/10.6084/m9.figshare.c.4560497>. Acesso em: 02 fev. 2023.

[18] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich, 2014. Going Deeper with Convolutions. Disponível em: <https://arxiv.org/abs/1409.4842>. Acesso em: 07 abr. 2023.

[19] Christine De Mol, Ernesto De Vito, Lorenzo Rosasco, 2009. Elastic-net regularization in learning theory. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0885064X0900003X>. Acesso em: 03 out. 2023