

Real-Time Heart Failure Prediction: An Approach for Ambient Assisted Living

Cristiano Paschoalim de Almeida*
cristiano.paschoalim@estudante.ufjf.br
Universidade Federal de Juiz de Fora
Juiz de Fora, Brasil

Jairo Francisco de Souza*
jairo.souza@ufjf.br
Universidade Federal de Juiz de Fora
Juiz de Fora, Brasil

Heder Soares Bernardino*
heder.bernardino@ufjf.br
Universidade Federal de Juiz de Fora
Juiz de Fora, Brasil

Luciana Conceição Dias Campos*
luciana.campos@ufjf.br
Universidade Federal de Juiz de Fora
Juiz de Fora, Brasil

Abstract

Context: The integration of IoT in healthcare has enhanced the capability of Ambient Assisted Living by enabling reliable real-time health monitoring, particularly for heart failure identification. Predictive models play a crucial role in identifying potential heart failures, improving patient outcomes through continuous monitoring and analysis. **Problem:** Traditional predictive models rely on centralized servers, facing issues like network latency, disruptions, and data overload. These challenges hinder real-time health data processing, limiting their ability to provide timely heart failure risk predictions. **Solution:** This study proposes a framework that embeds machine learning models directly into mobile devices, leveraging edge computing for real-time heart failure risk assessment. By processing data locally, the solution reduces latency, enhances reliability, and ensures greater data privacy while maintaining predictive accuracy. **IS Theory:** The framework aligns with socio-technical IS theory by integrating technical innovations and user-centric needs. Embedding predictive models into mobile devices enhances real-time predictions and patient care, bridging technology and human interaction. **Method:** A heart failure prediction dataset was utilized, employing supervised classification algorithms—Random Forest, K-Nearest Neighbors (KNN), and Logistic Regression. Data preprocessing included handling missing values, feature scaling, and encoding. The trained models were deployed on mobile devices using ONNX Runtime for efficient real-time inference. **Summary of Results:** The proposed system successfully performed real-time heart failure risk prediction on mobile devices, achieving competitive accuracy. Random Forest outperformed other models, reaching an accuracy of 85.33%, demonstrating its effectiveness in edge computing environments. The approach significantly mitigates the connectivity and latency challenges of centralized systems while enhancing data security. **Impact in the IS Area:** This research highlights the potential of edge computing to enhance real-time healthcare applications by reducing reliance on cloud infrastructure. Future works includes conducting real-environment patient evaluations to validate the system's clinical applicability, integrating biomedical sensors, improving predictive models using deep learning, and exploring federated learning for privacy-preserving model training.

CCS Concepts

• Human-centered computing → Ubiquitous computing; • Applied computing → Health informatics; • Computing methodologies → Supervised learning; • Security and privacy → Privacy protections.

Keywords

Heart failure prediction, Edge computing, Machine learning, Internet of Things (IoT), Health monitoring, Mobile applications, Real-time systems, Privacy and security in healthcare

1 Introdução

A prevalência crescente de doenças cardiovasculares, uma das principais causas de mortalidade em todo o mundo, tem levado ao desenvolvimento de novas tecnologias para monitoramento e intervenção preventiva em saúde. Nesse contexto, a integração da Internet das Coisas (IoT) com sistemas de monitoramento de saúde em tempo real desempenha um papel crucial. A IoT permite que dispositivos inteligentes, como sensores vestíveis e monitores de saúde, coletem continuamente dados vitais de pacientes, possibilitando um acompanhamento mais próximo e uma resposta imediata em caso de emergência [1] [13]. A computação de borda, uma abordagem que realiza o processamento desses dados localmente, tem se destacado como uma solução promissora para superar os desafios impostos pela infraestrutura centralizada tradicional, como latência, segurança e confiabilidade [12].

Em sistemas de monitoramento de saúde tradicionais, os dados são frequentemente enviados para servidores centralizados na nuvem para análise e processamento. No entanto, esse modelo enfrenta limitações significativas, especialmente em aplicações críticas, como a predição de insuficiência cardíaca em tempo real. A latência da rede, as interrupções de conexão e a sobrecarga de dados são alguns dos principais desafios que comprometem a eficiência dos sistemas de monitoramento baseados em nuvem. Esses fatores são particularmente preocupantes em ambientes de vida assistida, onde a detecção precoce de eventos de insuficiência cardíaca pode salvar vidas [11] [19]. Estudos mostram que atrasos na transmissão de dados para servidores centrais podem impedir que alertas críticos sejam emitidos a tempo, colocando em risco a segurança dos pacientes [22].

Para lidar com esses desafios, a computação de borda surge como uma alternativa vantajosa ao realizar o processamento de dados próximo à fonte. Com a computação de borda, os dados capturados pelos dispositivos IoT são analisados diretamente nos dispositivos locais, eliminando a necessidade de transmissão para servidores remotos e reduzindo significativamente o tempo de resposta. Além de melhorar a latência, essa abordagem oferece vantagens em termos de privacidade e segurança, pois os dados permanecem nos dispositivos próximos ao usuário, reduzindo o risco de exposição durante a transmissão [21] [11]. Esse modelo é particularmente benéfico para pacientes que residem em áreas com infraestrutura de rede limitada ou instável, onde a dependência de uma conexão contínua com a nuvem pode comprometer a eficácia do sistema [13].

Neste trabalho, propomos uma abordagem baseada em computação de borda para a predição de insuficiência cardíaca em tempo real, utilizando um modelo de *Random Forest* embarcado em dispositivos móveis. Ao processar os dados localmente, nosso sistema reduz a latência e aumenta a confiabilidade dos alertas, tornando-o ideal para ambientes de vida assistida. A arquitetura proposta não só aumenta a acessibilidade e eficiência do monitoramento de saúde, mas também garante que os dados sensíveis dos pacientes sejam protegidos localmente no dispositivo.

Combinando técnicas de aprendizado de máquina com computação de borda, nosso sistema visa oferecer uma solução acessível, inclusiva e de alta performance para o monitoramento de insuficiência cardíaca, por meio de uma abordagem diferente e otimizada, implementável em diversos modelos de dispositivos móveis. A implementação nestes dispositivos permite que os alertas sejam emitidos diretamente aos pacientes e cuidadores em tempo real, aumentando a capacidade de resposta e a eficiência do tratamento. Estudos adicionais sobre o uso de *aprendizado federado*¹ e redes neurais em computação de borda poderão expandir ainda mais as capacidades e a precisão dos sistemas de monitoramento de saúde, promovendo um atendimento cada vez mais personalizado e preventivo [20].

2 Fundamentação Teórica

O aumento da incidência de doenças cardiovasculares tem incentivado o avanço de tecnologias voltadas para o monitoramento contínuo de pacientes, permitindo a detecção precoce de eventos críticos, como a insuficiência cardíaca. Nesse contexto, a integração da Internet das Coisas (IoT) com sistemas de monitoramento de saúde, aliada à computação de borda, desempenha um papel fundamental, viabilizando a coleta e análise contínua de dados vitais por dispositivos inteligentes, como sensores vestíveis e monitores de saúde. Essa abordagem permite um processamento local eficiente e proporciona um acompanhamento mais próximo e uma resposta imediata em situações de emergência [1] [13].

Os modelos tradicionais de monitoramento remoto de saúde frequentemente utilizam a computação em nuvem para processar e analisar dados transmitidos continuamente de dispositivos distribuídos. Embora essa abordagem possibilite maior capacidade de

processamento, ela impõe desafios significativos, incluindo latência na comunicação, dependência da conectividade com a internet e preocupações críticas com segurança e privacidade dos dados dos pacientes, especialmente devido à centralização das informações em servidores remotos [19] [11]. Diante dessas limitações, a computação de borda surge como uma alternativa viável, ao trazer o processamento para mais próximo da fonte dos dados, reduzindo atrasos e tornando o monitoramento mais confiável e seguro [1] [12].

2.1 Limitações dos Sistemas Tradicionais

Os sistemas de monitoramento baseados em infraestrutura centralizada apresentam restrições que dificultam sua aplicabilidade em contextos que exigem respostas rápidas e confiáveis. O tempo necessário para que os dados coletados sejam transmitidos, processados e retornem como alertas pode ser um fator limitante em emergências médicas. Estudos indicam que atrasos na transmissão de dados para servidores centrais podem impedir que alertas sejam emitidos a tempo, comprometendo a segurança dos pacientes [22] [18]. A operação desses sistemas requer uma conexão estável com a internet. Em regiões com infraestrutura de rede limitada ou instável, a transmissão contínua de dados pode ser comprometida, prejudicando a funcionalidade do sistema e deixando pacientes sem monitoramento em momentos críticos [18]. O volume crescente de dados gerado por dispositivos IoT pode sobrecarregar a infraestrutura de servidores, impactando a escalabilidade dos sistemas e gerando custos operacionais elevados [19]. A transmissão contínua de informações médicas sensíveis para servidores remotos pode expor os sistemas de saúde a riscos elevados de ataques cibernéticos e vazamento de dados. A adoção de Computação de Borda pode reduzir essa exposição ao processar e armazenar informações médicas mais próximas à fonte, garantindo melhor privacidade [1] [19].

Essas limitações evidenciam a necessidade de arquiteturas descentralizadas que possam reduzir a latência, garantir a continuidade do monitoramento mesmo em locais com conectividade limitada e aumentar a privacidade e segurança dos dados dos pacientes.

2.2 Computação de Borda: Uma Alternativa Viável

A computação de borda tem sido explorada como uma solução para superar os desafios dos sistemas centralizados, oferecendo benefícios significativos para aplicações que exigem processamento eficiente e seguro. Nesse modelo, os dados são processados localmente nos próprios dispositivos IoT ou em servidores próximos à fonte de coleta, reduzindo a necessidade de transmissão para a nuvem, minimizando a latência e otimizando o desempenho do sistema [12].

A computação de borda reduz significativamente a latência ao permitir que os dados sejam processados localmente, sem depender de servidores remotos, tornando as respostas de alerta mais rápidas e eficientes [22].

Como o processamento ocorre localmente, os sistemas podem continuar funcionando mesmo em cenários onde a conectividade com a nuvem é limitada ou intermitente. Essa característica permite

¹O *Aprendizado Federado* é uma técnica de inteligência artificial que permite treinar modelos de aprendizado de máquina sem precisar enviar os dados dos usuários para um servidor central, permitindo treinar modelos eficientes sem comprometer a segurança dos dados dos usuários.

que aplicações sensíveis à latência, como monitoramento contínuo, sejam mantidas independentemente da infraestrutura de rede. [11].

A execução local dos modelos de aprendizado federado reduz a necessidade de compartilhamento de informações sensíveis com servidores remotos, minimizando o risco de vazamento de dados [19].

Ao distribuir a carga de processamento entre os dispositivos locais, evita-se a sobrecarga dos servidores centrais, permitindo a integração de um maior número de dispositivos sem comprometer a performance do sistema [13].

Dessa forma, a computação de borda não apenas supera os desafios das arquiteturas tradicionais, mas também permite a implementação de soluções mais eficientes para o monitoramento contínuo de pacientes. A abordagem descentralizada melhora a qualidade da assistência médica ao proporcionar alertas mais rápidos e confiáveis, garantindo uma alternativa mais segura e acessível para ambientes de vida assistida.

Neste estudo, propõe-se um modelo que incorpora aprendizado de máquina e computação de borda para a predição de insuficiência cardíaca em tempo real. A proposta visa não apenas mitigar as limitações das soluções convencionais, mas também oferecer um sistema mais responsivo e eficiente, que atenda às exigências de privacidade, segurança e escalabilidade no monitoramento remoto de saúde.

3 Trabalhos relacionados

A predição de insuficiência cardíaca no ambiente de Internet das Coisas (IoT) tem sido amplamente estudada, com diversas abordagens que exploram tanto a integração de sensores inteligentes quanto a utilização de aprendizado de máquina e computação de borda. A seguir, destacamos alguns trabalhos relevantes na área.

Hossain et al. (2023) [9] propuseram uma solução de inteligência de borda baseada em um modelo de aprendizado profundo, o *Over-sampled Quinary Feed Forward Network (OQFFN)*, para predição de insuficiência cardíaca em tempo real. Esta abordagem visa mitigar a dependência de servidores centrais, garantindo notificações rápidas e confiáveis, mesmo em situações de falha de rede.

Outro trabalho importante é o de SHUMBA, A.-T. et al. (2023) [14] que explora o uso de dispositivos vestíveis e tecnologias de inteligência artificial (IA) para a prevenção e gerenciamento da insuficiência cardíaca crônica. A computação de borda desempenha um papel crucial, permitindo a análise de dados em tempo real e preservando a privacidade dos pacientes ao reduzir a necessidade de envio de dados para a nuvem.

O artigo de BEBORTTA, S. et al. (2023) [3] introduz o "FedEHR", uma abordagem de aprendizado federado aplicada a registros eletrônicos de saúde (EHRs) integrados com IoT para a predição de doenças cardíacas. Esta abordagem foca na privacidade dos dados, treinando os modelos localmente nos dispositivos e, ao mesmo tempo, proporcionando aprendizado colaborativo entre diferentes nós.

Além disso, uma revisão sistemática de Cuevas-Chávez et al. (2023) [6] examina o uso de aprendizado de máquina e IoT para detecção e monitoramento de doenças cardiovasculares, com ênfase no uso de técnicas como *Random Forest* e *Support Vector Machine (SVM)*, que têm apresentado alta acurácia na predição de eventos

cardíacos. Essa revisão destaca a evolução das soluções tecnológicas e reforça o potencial de modelos de aprendizado de máquina para o monitoramento contínuo de pacientes em risco, enfatizando a importância de abordagens que combinem a computação de borda com IoT para superar desafios de latência e privacidade [15].

Esses trabalhos ilustram avanços significativos nas tecnologias aplicadas à predição de doenças cardíacas, como o uso de dispositivos IoT e técnicas de IA, com foco no monitoramento contínuo e predições em tempo real. No entanto, o presente trabalho diferencia-se ao propor uma abordagem que combina computação de borda e aprendizado de máquina embarcado em dispositivos móveis, otimizando o processamento local para superar limitações de latência e dependência de conectividade com servidores centrais. Essa solução oferece maior privacidade dos dados e robustez em ambientes com infraestrutura de rede limitada.

Ademais, a proposta se destaca por sua viabilidade prática e acessibilidade, demonstrada por meio da implementação de um modelo *Random Forest* diretamente em dispositivos móveis. Ao integrar sensores IoT e um aplicativo móvel, a arquitetura permite uma análise local, notificações em tempo real e maior precisão na detecção de insuficiência cardíaca, algo essencial em contextos de vida assistida.

Portanto, o diferencial deste trabalho está na aplicação de uma abordagem simplificada, eficiente e de baixo custo, focada em ambientes de computação de borda, destacando-se em cenários onde soluções centralizadas enfrentam desafios críticos. Além disso, a integração de um sistema de predição ágil e seguro reforça a relevância da proposta no aprimoramento do cuidado preventivo e personalizado, posicionando-se como uma alternativa prática e inovadora dentro do campo da saúde conectada.

4 Método

Este estudo propõe um sistema para a predição de insuficiência cardíaca em tempo real, integrando dispositivos IoT, aprendizado de máquina e computação de borda. O método adotado abrange etapas de coleta e preparação de dados, escolha e treinamento de algoritmos, integração com dispositivos móveis e validação prática. As etapas detalhadas do método estão descritas a seguir:

4.1 Treinamento

4.1.1 Coleta dos Dados: O conjunto de dados *Heart Failure Prediction Dataset*, disponível no Kaggle, foi utilizado como base para este estudo. Este dataset contém 1190 registros médicos de pacientes com insuficiência cardíaca, sendo 272 registros duplicados, incluindo informações de pacientes relacionadas a doenças cardíacas, como idade, tipo de dor no peito, colesterol, frequência cardíaca máxima, entre outras. A variável de saída é binária, indicando presença (1) ou ausência (0) de insuficiência cardíaca.

O Kaggle é uma plataforma reconhecida tanto pela realização de competições de ciência de dados quanto pelo seu extenso repositório de conjuntos de dados e códigos colaborativos. Por meio dela, pesquisadores e profissionais têm acesso a diversos datasets públicos e podem executar e compartilhar notebooks na nuvem, o que facilita a experimentação e a validação de modelos de aprendizado de máquina sem a necessidade de uma infraestrutura computacional local robusta [10].

4.1.2 Seleção e processamento: O conjunto de dados empregado para o treinamento do modelo resulta da integração de cinco bases de dados clássicas (Statlog, Cleveland, Hungarian, Long Beach VA e Switzerland) e inclui 11 variáveis clínicas e laboratoriais essenciais para a previsão da insuficiência cardíaca. A harmonização dessas variáveis entre os diferentes conjuntos de dados possibilitou a criação de um modelo preditivo robusto e generalizável, capaz de refletir com precisão os fatores de risco associados à insuficiência cardíaca. Abaixo, apresentamos as principais variáveis utilizadas e sua respectiva descrição:

- **Idade (Age):** Representa a idade do paciente em anos.
- **Sexo (Sex):** Variável categórica indicando o gênero do paciente (masculino ou feminino).
- **Tipo de Dor no Peito (ChestPainType):** Indica o tipo de dor torácica sentida pelo paciente, categorizada como angina típica, angina atípica, dor não anginosa ou assintomática.
- **Pressão Arterial em Repouso (RestingBP):** Mede a pressão arterial sistólica do paciente em repouso, um dos principais indicadores de hipertensão arterial e risco cardiovascular.
- **Colesterol (Cholesterol):** Indica o nível de colesterol total no sangue. Níveis elevados estão associados a um maior risco de obstrução arterial [17].
- **Glicose em Jejum (FastingBS):** Variável binária que indica se o paciente possui níveis elevados de glicose em jejum, um fator de risco para diabetes e complicações cardiovasculares [2].
- **Eletrocardiograma de Repouso (RestingECG):** Registra a atividade elétrica do coração em repouso.
- **Frequência Cardíaca Máxima (MaxHR):** Representa a frequência cardíaca máxima atingida durante o exercício.
- **Angina Induzida por Exercício (ExerciseAngina):** Variável binária que indica se o paciente apresentou angina durante o teste de esforço.
- **Depressão do Segmento ST² (Oldpeak):** Mede a depressão do segmento ST no eletrocardiograma durante o esforço.
- **Inclinação do Segmento ST (STslope):** Indica a inclinação do segmento ST durante o teste de esforço.

No pré-processamento dos dados, as variáveis categóricas foram codificadas usando *One-Hot Encoding*, enquanto as variáveis numéricas foram normalizadas para garantir uma escala uniforme e melhorar o desempenho do modelo.

Embora essas variáveis tenham sido selecionadas com base em sua relevância para a predição de insuficiência cardíaca, é essencial que estudos futuros contem com a participação de especialistas da área da saúde para validar a importância clínica dessas variáveis. Como os testes realizados neste estudo foram exclusivamente por simulação, futuras avaliações em cenários reais poderão refinar a escolha das variáveis e aprimorar a robustez do modelo.

²O termo segmento ST é usado na eletrocardiografia (ECG) para descrever uma parte do traçado elétrico do coração. Ele representa a fase entre a despolarização e a repolarização ventricular, ou seja, o intervalo entre a contração e o relaxamento dos ventrículos. Médicos utilizam a análise do segmento ST para diagnosticar problemas cardíacos e definir tratamentos emergenciais. Elevação do ST pode indicar infarto agudo do miocárdio (IAM), um ataque cardíaco.

4.1.3 Pré-processamento dos dados: Verificação e Tratamento de Dados Ausentes: Dados ausentes foram tratados utilizando estratégias como preenchimento com a mediana para valores numéricos ou a categoria mais frequente para variáveis categóricas.

Escalonamento e Normalização: Dados numéricos foram escalonados para a faixa [0, 1] usando *MinMaxScaler*, melhorando a eficiência do aprendizado dos algoritmos.

Codificação de Variáveis Categóricas: As variáveis categóricas foram transformadas em binárias utilizando o *OneHotEncoder*, criando colunas adicionais para cada categoria. Por exemplo, o atributo "sexo" foi expandido para colunas "masculino" e "feminino", reduzindo a ambiguidade na interpretação dos dados.

Balanceamento dos Dados: Para mitigar o impacto do desbalanceamento das classes no conjunto de dados, foi aplicada a técnica SMOTE (Synthetic Minority Over-sampling Technique), gerando novas instâncias sintéticas da classe minoritária e equilibrando a distribuição das classes. Esse processo contribuiu para melhorar a capacidade do modelo de identificar corretamente ambas as classes, reduzindo o viés em favor da classe majoritária e melhorando a métrica de recall para a classe minoritária.

4.1.4 Algoritmos Avaliados para Compor o Modelo da Proposta:

- (1) **Random Forest:** Proposto por Leo Breiman em 2001 [4], o *Random Forest* constrói múltiplas árvores de decisão, utilizando a técnica de *baggin* para melhorar a precisão. Este modelo é robusto a dados ruidosos e *outliers*, reduzindo o risco de *overfitting* ao combinar as previsões de várias árvores.
- (2) **K-Nearest Neighbors (KNN):** Introduzido por Fix e Hodges em 1951 [8], o *KNN* é um classificador baseado em instâncias, que classifica novos pontos com base nos k vizinhos mais próximos no conjunto de treinamento. Ele calcula a distância entre os pontos de dados, frequentemente utilizando a distância Euclidiana, para determinar a classe da nova instância.
- (3) **Logistic Regression:** Proposto por David Cox em 1958 [5], a Regressão Logística modela a probabilidade de uma classe binária como uma função linear de seus preditores, utilizando a função sigmoide para garantir que os valores preditos estejam entre 0 e 1. Esse modelo é amplamente utilizado para problemas de classificação binária, permitindo a interpretação direta dos coeficientes das variáveis.

Os modelos foram treinados e validados utilizando as métricas acurácia, precisão, *recall* e *F1-Score*. Com isso, foi possível fazer uma análise comparativa dos modelos e identificar aquele com os melhores resultados para a aplicação de interesse.

4.2 Implementação e Inferência em Dispositivos Móveis

Após a fase de treinamento, o melhor modelo, o *Random Forest*, foi selecionado e exportado utilizando o *ONNX Runtime* [7] para ser implementado em aplicativos móveis. A utilização do *ONNX Runtime* [7] é fundamental para viabilizar a inferência local em tempo real, fornecendo suporte para otimizações específicas de hardware. Estudos indicam que a implementação do *ONNX Runtime*

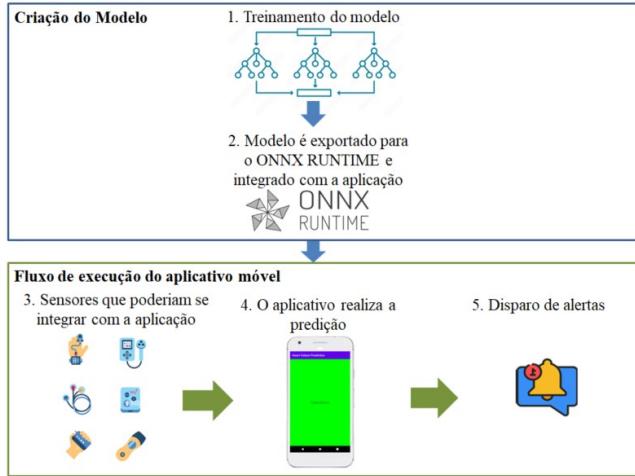


Figura 1: Desenho da arquitetura proposta

[7] possibilita um desempenho eficiente de inferência em dispositivos com recursos computacionais limitados, como sistemas embarcados, mantendo a precisão do modelo [16]. O modelo foi então integrado a um aplicativo móvel. Esse aplicativo móvel permite que os usuários insiram dados equivalentes ao conjunto de atributos do dataset original, e o modelo embarcado no aplicativo móvel gera uma predição local, sem a necessidade de processamento externo em servidores. Em caso de predizer problemas cardíacos, o aplicativo móvel pode notificar o paciente diretamente e disparar alertas para que medidas preventivas sejam tomadas de imediato, garantindo rapidez e eficiência na detecção e resposta ao risco de doenças cardíacas.

4.3 Arquitetura Proposta

A arquitetura da solução proposta integra dispositivos IoT de monitoramento de sinais vitais com um modelo de aprendizado de máquina embarcado em dispositivos móveis, permitindo a predição de insuficiência cardíaca em tempo real utilizando computação de borda. Abaixo, detalhamos cada componente e o fluxo de dados representados na Figura 1.

4.3.1 Dispositivos de Monitoramento de Sinais Vitais: A primeira etapa envolve a coleta de dados de saúde dos pacientes através de dispositivos IoT, como monitores de pressão arterial, eletrocardiogramas (ECGs), monitores de frequência cardíaca e outros sensores vestíveis. Esses dispositivos capturam informações críticas em tempo real, que são usadas para identificar sinais potenciais de insuficiência cardíaca.

4.3.2 Modelo de Aprendizado de Máquina: O modelo escolhido para a predição de insuficiência cardíaca é o *Random Forest*, um algoritmo de aprendizado de máquina baseado em árvores de decisão. Esse modelo é treinado para identificar padrões em dados de saúde que podem indicar um risco de insuficiência cardíaca. Após o treinamento, o modelo é convertido para um formato compatível com a execução em dispositivos móveis.

4.3.3 ONNX Runtime [7]: O modelo treinado é exportado para o formato ONNX (*Open Neural Network Exchange*), o que facilita sua integração e execução em diferentes plataformas. Utilizando o *ONNX Runtime* [7], o modelo *Random Forest* pode ser executado diretamente no dispositivo, sem a necessidade de enviar dados para um servidor remoto. Isso permite que o processamento e a análise dos dados sejam realizados localmente, reduzindo a latência e aumentando a eficiência do sistema.

4.3.4 Aplicativo Móvel: A etapa final da arquitetura é a implementação do modelo de predição em um aplicativo. O aplicativo móvel coleta os dados dos dispositivos IoT e, com o auxílio do modelo *Random Forest*, realiza uma predição em tempo real. Caso seja detectado um risco elevado de insuficiência cardíaca, o aplicativo móvel pode gerar notificações instantâneas para o usuário ou profissional de saúde responsável, permitindo uma resposta rápida e eficaz.

Essa arquitetura combina a coleta de dados em tempo real com a análise local utilizando computação de borda, garantindo um sistema de monitoramento de saúde ágil, eficiente e acessível para ambientes de vida assistida.

4.4 Considerações Metodológicas

Embora o sistema tenha demonstrado alta precisão, pode-se detectar algumas limitações:

Generalização: O desempenho pode variar em dispositivos móveis e populações distintas devido à representatividade do *dataset* utilizado.

Complexidade Computacional: A integração de algoritmos mais avançados, como redes neurais, pode requerer dispositivos móveis com maior capacidade de processamento.

Perspectivas para Integração de Sensores Biomédicos: Dispositivos como monitores de pressão arterial, eletrocardiogramas (ECGs), monitores de frequência cardíaca e outros sensores vestíveis representam potenciais integrações compatíveis com a aplicação proposta. No entanto, esses dispositivos não foram incluídos nos testes experimentais. A avaliação do sistema em cenários reais, com a participação de especialistas da área de saúde e a incorporação desses sensores adicionais, está prevista como parte de trabalhos futuros.

Escalabilidade e Eficiência Computacional: A metodologia adotada destaca-se por seu potencial de escalabilidade e capacidade de operação em dispositivos móveis com recursos computacionais limitados. No entanto, é importante ressaltar que os experimentos realizados foram conduzidos por meio de simulações, sem testes em larga escala ou em cenários reais de aplicação clínica. A avaliação da escalabilidade baseou-se na compatibilidade do modelo com dispositivos de diferentes configurações, bem como na utilização do *ONNX Runtime* [7] para otimização do desempenho. A definição de “poucos recursos computacionais” foi estabelecida com base nos requisitos mínimos de *hardware* utilizados nos testes, que incluíram um *smartphone* contendo sistema operacional Android com 2 GB de RAM e um processador de médio desempenho e um *smartwatches* com sistema operacional Android com 512 MB de RAM e processador de médio desempenho. Durante os experimentos, observou-se que a inferência do modelo *Random Forest* ocorreu em tempo reduzido e sem consumo excessivo de memória, garantindo viabilidade para aplicações móveis. Entretanto, a eficácia dessa abordagem em um contexto clínico real, com uma carga maior de processamento

e variabilidade nos dispositivos utilizados pelos pacientes, ainda precisa ser validada.

Esclarecimento sobre a Validação e Mensuração da Responsividade: É importante destacar que os testes realizados até o momento foram conduzidos exclusivamente em ambiente simulado, sem a participação de usuários reais. Dessa forma, os resultados apresentados – que evidenciam alta responsividade e precisão do aplicativo, com geração imediata de alertas ao identificar riscos de insuficiência cardíaca – referem-se apenas ao desempenho técnico do sistema sob condições controladas. Em outras palavras, o termo “responsivo” indica a capacidade do aplicativo de processar os dados e emitir alertas com baixa latência, isto é, o tempo entre a entrada dos dados e a emissão do alerta foi medido e constatado como muito curto, mesmo quando executado em dispositivos virtuais com configurações mínimas. Ressalta-se que a validação do sistema com a participação de pessoas não foi realizada nesta fase. O aprimoramento e a avaliação do aplicativo em cenários reais, envolvendo profissionais de pesquisa na área da saúde, estão planejados para trabalhos futuros. Essa etapa será fundamental para avaliar não apenas a eficiência técnica, mas também a usabilidade, a interação com os usuários e a eficácia dos alertas em condições clínicas reais.

Para consolidar essa análise, futuros estudos deverão incluir testes empíricos que avaliem o impacto do modelo em diferentes dispositivos e cenários de uso contínuo. Além disso, o acompanhamento de especialistas da área da saúde será essencial para validar a aplicabilidade prática da solução, garantindo que sua adoção não comprometa a confiabilidade e precisão da predição em ambientes reais.

5 Experimentos

Os resultados alcançados nos experimentos computacionais ao aplicar os modelos *Random Forest*, *K-Nearest Neighbors* (*KNN*) e Regressão Logística na base de dados *Heart Failure Prediction Dataset* são apresentados nesta seção. Além dos resultados de acurácia, precisão, *recall* e *F1-Score*, são apresentadas as curvas ROC e as áreas sob as respectivas curvas. No que se refere ao melhor modelo obtido, são apresentadas a sua matriz de confusão e suas variáveis mais importantes. Para que seja possível avaliar a aplicabilidade da arquitetura proposta, também são mostrados resultados usando um *smartphone* e um *smartwatch*.

5.1 Resultados

Os resultados alcançados pelos modelos *Random Forest*, *KNN* e *Logistic Regression* são apresentados em termos de acurácia, precisão, *recall* e *F1-Score* na Tabela 1. Como pode ser observado, a *Random Forest* alcançou os melhores resultados em todas as métricas analisadas, com exceção da precisão, na qual a *Logistic Regression* tem um resultado um pouco melhor (2,49% de diferença relativa).

A Curva ROC (*Receiver Operating Characteristic*) é uma representação gráfica que avalia a sensibilidade (taxa de verdadeiros positivos) em relação à especificidade (1 - taxa de falsos positivos) para diferentes limiares de decisão. A área sob a curva ROC (AUC) é uma métrica que indica a capacidade do modelo de diferenciar entre pacientes com e sem risco de insuficiência cardíaca. Um AUC próximo de 1 indica um desempenho excelente, enquanto um valor próximo de 0,5 sugere um desempenho aleatório. As curvas

Tabela 1: Métricas de avaliação para todos os modelos considerados aqui. Os melhores valores para cada métrica são destacadas em negrito.

Modelo	Acurácia (%)	Precisão (%)	Recall (%)	<i>F1-Score</i> (%)
<i>Random Forest</i>	88,59	93,00	86,92	89,86
<i>K-Nearest Neighbors</i>	58,70	67,03	57,01	61,62
<i>Logistic Regression</i>	84,78	90,72	82,24	86,27

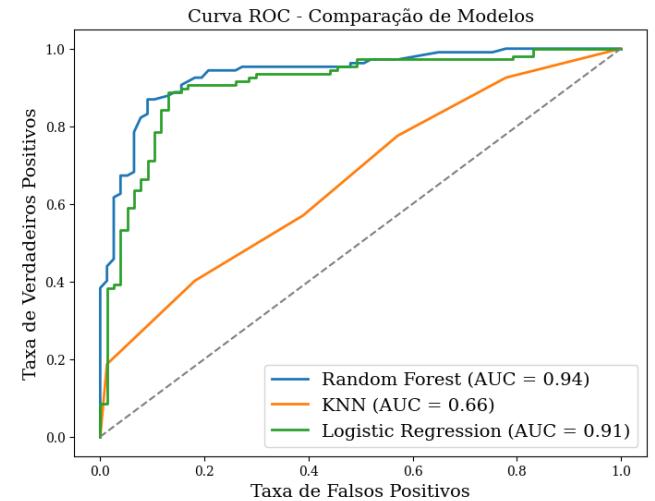


Figura 2: Curvas ROC e áreas sob suas respectivas curvas (AUC).

ROC dos modelos considerados aqui são apresentadas na Figura 2. Neste estudo, o *Random Forest* obteve uma curva ROC que mostra uma inclinação significativa em direção ao canto superior esquerdo, indicando alta sensibilidade e especificidade. Isso reforça a capacidade do modelo na detecção de insuficiência cardíaca, oferecendo segurança para alertas em situações de risco.

A matriz de confusão é uma ferramenta visual que permite avaliar o desempenho do modelo, mostrando a distribuição dos verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos. Desta forma, a matriz de confusão do melhor modelo obtido (*Random Forest*) é apresentada na Figura 3. No contexto deste estudo, a matriz indica a eficácia do modelo *Random Forest* em identificar corretamente casos de insuficiência cardíaca (verdadeiros positivos) e em classificar corretamente pacientes saudáveis (verdadeiros negativos).

A matriz revela o baixo valor de falsos negativos do modelo, o que é essencial em um sistema de monitoramento de saúde para evitar que casos graves de insuficiência cardíaca passem despercebidos. Interpretando a matriz, pode-se observar que o modelo apresentou uma taxa satisfatória de erros, reforçando sua confiabilidade para aplicações em tempo real.

5.2 Importância das Variáveis

A importância das variáveis representam as características mais relevantes para a predição de insuficiência cardíaca no modelo *Random Forest*. Durante o treinamento, o *Random Forest* identifica e

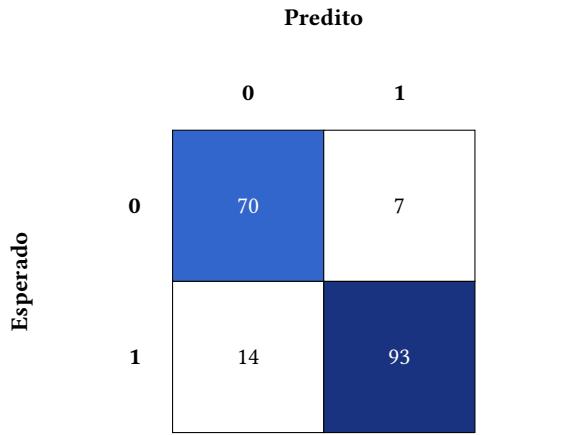
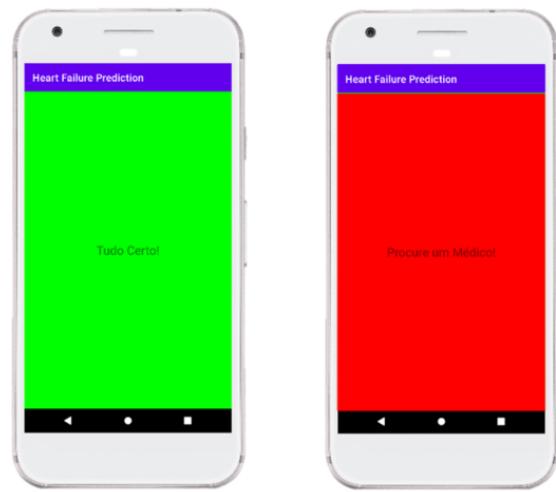
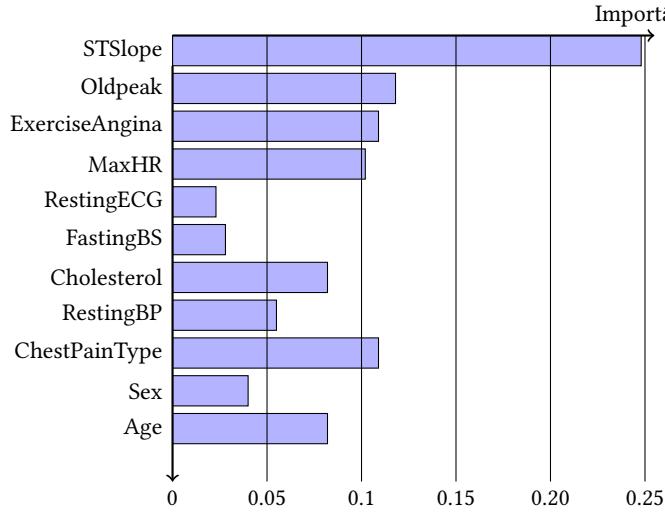
Figura 3: Matriz de confusão da *Random Forest*.

Figura 5: Funcionamento do aplicativo em um smartphone.

Figura 4: Importâncias das variáveis para o modelo *Random Forest* gerado aqui.

prioriza características que mais contribuem para a acurácia do modelo. Nesta análise, observou-se que variáveis como o valor de ST no pico do exercício, o nível de ST em depressão e o colesterol foram especialmente significativas. Isso indica que essas características desempenham um papel crucial na identificação de risco de insuficiência cardíaca, orientando o modelo a focar nos sinais mais associados à condição cardíaca. Visualizando a importância das variáveis em um gráfico de barras, apresentado na Figura 4, podemos ver claramente a hierarquia dessas características, permitindo uma compreensão mais profunda sobre quais fatores de saúde têm maior peso na predição.

5.3 Resultado Obtido no Aplicativo Móvel

O resultado obtido no aplicativo móvel reflete a eficácia da implementação do modelo *Random Forest* em um ambiente de computação de borda. Com a integração do modelo ao aplicativo, o

sistema permite que os dados do paciente sejam inseridos diretamente, fornecendo uma predição em tempo real. Nos testes, o aplicativo demonstrou alta responsividade e precisão, gerando alertas imediatos quando um risco de insuficiência cardíaca é identificado. As notificações são enviadas diretamente ao paciente ou cuidador, proporcionando uma camada adicional de segurança e permitindo intervenções rápidas. Este resultado confirma a viabilidade da abordagem de computação de borda para aplicações de saúde, destacando-se como uma solução prática para monitoramento contínuo em ambientes com infraestrutura limitada.

Para os testes com um *smartphone*, foi usado um dispositivo virtual com 2 GB de RAM e sistema operacional Android 10. A Figura 5 ilustra os resultados observados para as simulações.

Quando foi considerado um *smartwatch*, os testes foram realizados em um dispositivo virtual com sistema operacional Wear OS, 512 GB de RAM e tela AMOLED de 1,2 polegadas e sistema operacional Android 11. Os resultados observados para as simulações são ilustrados na Figura 6.

Em ambos os dispositivos móveis, o aplicativo foi configurado para receber os dados do paciente, processá-los localmente utilizando o modelo *Random Forest* integrado via ONNX Runtime [7] e gerar previsões em tempo real. Durante os experimentos, foram inseridos dados simulados correspondentes às características do conjunto de dados original, e as respostas do aplicativo foram avaliadas quanto à precisão, responsividade e consistência das notificações.

5.4 Análise da Latência

A latência é um fator crítico em sistemas de predição de insuficiência cardíaca em tempo real, especialmente em ambientes de vida assistida. Para avaliar o impacto da computação de borda na latência das previsões em tempo real, realizamos testes comparando a execução local do modelo com servidores remotos. Para isso, foram utilizadas 15 amostras retiradas do conjunto de testes do *Heart Failure Prediction Dataset*, representando diferentes perfis de pacientes com

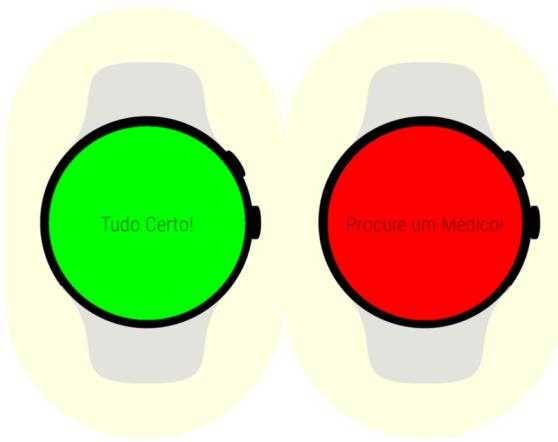


Figura 6: Funcionamento do aplicativo em um smartwatch

variações nas características clínicas. Estes testes visam demonstrar os desafios de latência e conectividade ao comparar a execução de inferências remotas, que dependem da comunicação constante com servidores, com a computação de borda, que processa as inferências diretamente em dispositivos móveis.

5.4.1 Configuração dos Dispositivos dos Testes: Para avaliar o impacto dessa abordagem, realizamos testes de latência utilizando as seguintes configurações:

- Dispositivo Móvel (Execução Local): *Smartphone* com 2 GB de RAM, processador octa-core de 2,20 GHz, rodando o sistema operacional Android. Este dispositivo foi utilizado para executar as inferências localmente.
- Ambiente Remoto (SA-EAST-1): Servidor com 2 GB de RAM, 2 vCPUs, rodando o sistema operacional Linux, localizado em São Paulo - BR.
- Ambiente Remoto (NYC1): Servidor com 2 GB de RAM, 2 vCPUs, rodando o sistema operacional Linux, localizado em Nova Iorque - EUA.
- Ambiente Remoto (US-WEST-2): Servidor com 2 GB de RAM, 2 vCPUs, rodando o sistema operacional Linux, localizado em Norte da Virgínia - EUA.
- Ambiente Remoto (Execução Remota): Aplicação hospedada no Google Colab na versão gratuita, que fornece um ambiente de notebook. Nesta configuração, o Colab disponibiliza aproximadamente 12,7 GB de RAM e uma CPU Intel Xeon de núcleo único com hyper-threading a 2,3 GHz, localizado no Oregon - EUA.

5.4.2 Resultados Obtidos: A realização de testes contínuos e sem interrupções é fundamental para garantir medições precisas de latência e desempenho em aplicações de tempo real. Satyanarayanan et al. (2017) [12] destacam que a latência pode ser significativamente afetada pela distância entre os dispositivos e os servidores de processamento, tornando essencial a proximidade para minimizar atrasos imprevisíveis e garantir respostas rápidas em aplicações interativas. Além disso, Zhao et al. (2021) [22] apontam que a latência excessiva pode comprometer a eficácia de sistemas críticos, especialmente em aplicações médicas baseadas em IoT, onde respostas em tempo

real são essenciais para garantir a confiabilidade e a segurança do sistema. Com base nessas diretrizes, os testes realizados neste estudo foram estruturados de forma a garantir a execução contínua das inferências, evitando qualquer introdução de atrasos artificiais que pudessem comprometer a validade dos resultados.

A Figura 7 apresenta a comparação da latência (em milissegundos) para diferentes quantidades de previsões realizadas nos ambientes local e remoto. Observa-se que a execução local manteve tempos de resposta baixos e constantes ao longo das amostras testadas, enquanto o processamento remoto apresentou um aumento linear da latência à medida que o número de previsões aumentou.

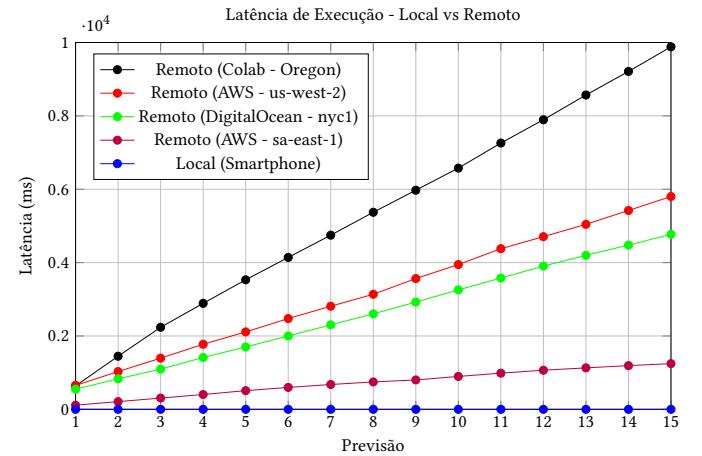


Figura 7: Comparação da latência de execução (em ms) em diferentes ambientes remotos (Colab, AWS, DigitalOcean) e local (smartphone), variando o número de previsões.

Os principais pontos dessa análise incluem:

- A latência na execução local permaneceu inferior a 1 ms, indicando uma resposta praticamente instantânea do modelo implementado no dispositivo móvel.
- A latência na execução remota aumentou proporcionalmente ao número de previsões, atingindo 100.000 ms em alguns testes para um conjunto de 15 previsões.
- O tempo médio de resposta da predição local foi 99,8% menor do que o da predição remota (Colab - Oregon), destacando a eficiência da computação de borda na redução do tempo de inferência.
- A influência da localização do servidor de processamento em relação à fonte dos dados, percebeu-se uma queda considerável na latência quanto mais próximo o processamento foi realizado. Esse resultado confirma a teoria de que a proximidade entre a origem dos dados e o ambiente de inferência reduz significativamente a latência, garantindo respostas mais rápidas e eficientes.

5.5 Discussão

Os resultados obtidos neste estudo demonstraram a eficácia da abordagem proposta para predição de insuficiência cardíaca em tempo real utilizando computação de borda e aprendizado de máquina. O modelo *Random Forest*, integrado a dispositivos móveis, apresentou

um desempenho competitivo com uma acurácia de 85,33%, superando outros algoritmos avaliados, como o *K-Nearest Neighbors* e a *Regressão Logística*. No entanto, ao comparar com o modelo *Oversampled Quinary Feed Forward Network (OQFFN)*, descrito por Hossain et al. (2023) [9], nossa abordagem obteve uma acurácia inferior ao método baseado em aprendizado profundo, que alcançou 89,25%.

Embora o modelo *OQFFN* tenha apresentado melhor desempenho em termos de acurácia, nosso estudo destaca-se pela adoção de uma abordagem diferente, focada em acessibilidade e otimização para dispositivos móveis. A escolha pelo *Random Forest*, combinado com o uso do *ONNX Runtime* [7], garantiu uma implementação leve e eficiente, viabilizando o funcionamento em uma gama mais ampla de dispositivos, desde *smartphones* a equipamentos menos avançados tecnologicamente. Essa característica torna a solução proposta mais acessível, especialmente em regiões onde o custo de dispositivos ou a infraestrutura tecnológica limitada representam barreiras significativas.

Além disso, o modelo *Random Forest* é mais robusto em cenários com restrições computacionais, demandando menos recursos do que os modelos de aprendizado profundo como o *OQFFN*. Essa eficiência permite reduzir o custo de implementação e manutenção, facilitando a adoção em larga escala em ambientes de vida assistida e regiões com infraestrutura limitada. A acessibilidade dessa solução reforça sua relevância prática, uma vez que amplia o alcance do monitoramento de saúde em tempo real para populações que, de outra forma, teriam acesso restrito a sistemas mais sofisticados.

Portanto, ainda que o estudo não tenha superado a acurácia do modelo *OQFFN*, a abordagem proposta oferece uma alternativa prática e escalável, alinhada às necessidades de acessibilidade e eficiência. Esses fatores destacam a importância da computação de borda como uma solução viável e inovadora, capaz de transformar o monitoramento de saúde contínuo e personalizado em contextos variados, sem comprometer a qualidade do atendimento. O trabalho contribui, assim, para a expansão das possibilidades no campo da saúde conectada, promovendo um modelo mais inclusivo e adaptável às diferentes realidades socioeconômicas.

6 Conclusão

Este estudo propôs uma solução inovadora para a predição de insuficiência cardíaca em tempo real, utilizando computação de borda e aprendizado de máquina, especialmente projetada para ambientes de vida assistida e monitoramento contínuo de pacientes. Integrando dispositivos IoT para coleta de dados vitais com um modelo de aprendizado de máquina, o *Random Forest*, diretamente em dispositivos móveis, nossa abordagem elimina a dependência de servidores centrais, reduzindo significativamente a latência e oferecendo uma solução eficaz para regiões com infraestrutura de rede limitada ou instável [13] [12] [11].

Os resultados demonstraram que o modelo Random Forest alcançou alta precisão na predição de insuficiência cardíaca, com uma acurácia de 85,33%. Em comparação com outros algoritmos, como o *K-Nearest Neighbors (KNN)* e a *Regressão Logística*, o *Random Forest* apresentou melhor equilíbrio entre precisão, revocação e *F1-score*, consolidando-se como uma opção robusta para aplicações de monitoramento de saúde que exigem resposta rápida e confiável. Esse

desempenho destaca o modelo como uma excelente escolha para implementação em ambientes de computação de borda, permitindo uma identificação precisa e em tempo real de riscos iminentes à saúde dos pacientes [22].

Ao realizar o processamento dos dados diretamente nos dispositivos móveis, nossa solução promove maior privacidade e segurança das informações, uma vez que reduz a necessidade de transmissão de dados sensíveis para a nuvem. Esse aspecto é particularmente relevante em sistemas de saúde, onde a proteção dos dados pessoais é essencial. Além disso, o uso de computação de borda reduz a sobrecarga da rede e a dependência de uma conexão constante, permitindo que o sistema funcione de forma eficiente mesmo em áreas com conectividade intermitente [1] [21].

Outro destaque desta pesquisa é a implementação prática em um aplicativo móvel, que mostrou ser uma solução acessível e de fácil uso para pacientes e profissionais de saúde. O aplicativo permite a inserção e análise dos dados em tempo real e emite notificações automáticas quando um risco de insuficiência cardíaca é detectado. Esse sistema de alerta imediato é vital para prevenir eventos adversos, possibilitando que os usuários recebam cuidados rapidamente e aumentando a probabilidade de intervenções precoces em situações críticas [13].

Embora os resultados sejam promissores, o estudo também abre caminho para futuras melhorias e avanços.

Em síntese, este trabalho contribui para o avanço das soluções de monitoramento de saúde em tempo real, propondo uma alternativa eficiente às abordagens centralizadas e destacando o potencial da computação de borda em ambientes de vida assistida. Ao oferecer um sistema de predição de insuficiência cardíaca mais acessível, ágil e seguro, este estudo estabelece uma base sólida para o desenvolvimento de tecnologias de saúde conectada, capazes de atender às crescentes necessidades de um atendimento preventivo e personalizado. Essa abordagem tem o potencial de revolucionar o monitoramento de saúde em áreas com infraestrutura limitada, melhorando significativamente a qualidade de vida dos pacientes e a eficácia dos cuidados médicos [11].

7 Trabalhos Futuros

Embora os resultados apresentados neste estudo tenham demonstrado a viabilidade e a eficiência da abordagem baseada em computação de borda para a predição em tempo real de insuficiência cardíaca, diversas direções de aprimoramento e expansão são identificadas ao longo do artigo.

A eficácia do sistema, atualmente avaliada em ambiente simulado, precisa ser confirmada por meio de testes empíricos em cenários clínicos reais. A participação de especialistas da área da saúde e a avaliação do desempenho do modelo em dispositivos móveis com diferentes capacidades computacionais serão fundamentais para validar a robustez e a aplicabilidade da solução.

Embora o estudo tenha utilizado um conjunto predefinido de atributos clínicos, futuros trabalhos podem ampliar a gama de dispositivos integrados, incorporando sensores como monitores de pressão arterial e outros dispositivos vestíveis. Essa integração pode contribuir para uma análise mais completa e personalizada dos sinais vitais dos pacientes.

A atual implementação com *Random Forest* demonstrou resultados promissores; contudo, a incorporação de modelos de aprendizado profundo, como redes neurais convolucionais (CNN) e redes neurais recorrentes (RNN), pode potencialmente melhorar a precisão e a sensibilidade na identificação de padrões complexos. A comparação entre essas abordagens poderá identificar a estratégia ideal para a predição de eventos cardíacos.

O aprendizado federado surge como uma alternativa inovadora para permitir o treinamento colaborativo de modelos em dispositivos distribuídos, sem comprometer a privacidade dos dados dos pacientes. Essa abordagem possibilitaria atualizações contínuas do modelo, adaptando-o dinamicamente às variações dos dados clínicos e melhorando sua performance de forma descentralizada.

Apesar dos testes simulados terem confirmado a baixa latência e o consumo reduzido de recursos, é necessário avaliar a escalabilidade do sistema em cenários com maior variabilidade de dispositivos e cargas de processamento reais. Investigações futuras deverão explorar a capacidade do modelo em manter seu desempenho sob condições de uso intensivo e heterogêneo.

Essas perspectivas não apenas apontam caminhos para o aprimoramento técnico do sistema, mas também reforçam a importância de uma abordagem multidisciplinar que integre avanços tecnológicos com as necessidades clínicas. A evolução contínua dessas direções pode contribuir significativamente para a criação de soluções de monitoramento de saúde mais robustas, acessíveis e adaptáveis aos desafios dos ambientes de vida assistida.

Agradecimentos

Os autores expressam sua gratidão ao CNPq, CAPES, FAPEMIG e UFJF pelo suporte financeiro e incentivo à pesquisa científica, fundamentais para a realização deste estudo.

Referências

- [1] A. A. Abdellatif, A. Mohamed, C. F. Chiasseroni, M. Tili, and A. Erbad. 2019. Edge computing for smart health: Context-aware approaches, opportunities, and challenges. *IEEE network* 33, 3 (2019), 196–203. <https://doi.org/10.1109/mnet.2019.1800083>
- [2] American Diabetes Association. 2020. Standards of Medical Care in Diabetes—2020. *Clinical Diabetes* 38, 1 (2020), 10–17. <https://doi.org/10.2337/cd20-0062>
- [3] S. Bebortha and et al. 2023. FedEHR: A Federated Learning Approach towards the Prediction of Heart Diseases in IoT-based Electronic Health Records. *Diagnostics* 13, 20 (2023), 3166. <https://doi.org/10.3390/diagnostics13203166>
- [4] L. Breiman. 2001. Random Forests. *Machine Learning* 45, 1 (2001), 5–32. <https://doi.org/10.1023/A:1010933404324>
- [5] D. R. Cox. 1958. The Regression Analysis of Binary Sequences. *Journal of the Royal Statistical Society: Series B (Methodological)* 20, 2 (1958), 215–242.
- [6] A. Cuevas-Chávez and et al. 2023. A Systematic Review of Machine Learning and IoT Applied to the Prediction and Monitoring of Cardiovascular Diseases. *Healthcare* 11, 16 (2023), 2240. <https://doi.org/10.3390/healthcare11162240>
- [7] ONNX Runtime developers. 2021. ONNX Runtime. <https://onnxruntime.ai/>. Version: x.y.z.
- [8] E. Fix and J. L. Hodges. 1951. *Discriminatory Analysis*. Technical Report Technical Report 4, Project 21-49-004. USAF School of Aviation Medicine, Randolph Field, Texas. Nonparametric Discrimination: Consistency Properties.
- [9] M. I. A. Hossain, A. Tabassum, and Z. U. Shamsaman. 2023. Deep Edge Intelligence-based Solution for Heart Failure Prediction in Ambient Assisted Living. *Discover Internet of Things* 3, 11 (2023), 43. <https://doi.org/10.1007/s43926-023-00043-4>
- [10] L. Quaranta, F. Calefato, and F. Lanubile. 2021. KGTorrent: A Dataset of Python Jupyter Notebooks from Kaggle. *International Conference on Mining Software Repositories (MSR)* 18 (2021), 550–554.
- [11] R. Lopez Roman and M. Mambo. 2018. Mobile Edge Computing, Fog et al.: A Survey and Analysis of Security Threats and Challenges. *Future Generation Computer Systems* 78 (2018), 680–698. <https://doi.org/10.1016/j.future.2016.11.009>
- [12] M. Satyanarayanan. 2017. The Emergence of Edge Computing. *Computer* 50, 1 (2017), 30–39. <https://doi.org/10.1109/MC.2017.9>
- [13] W. Shi, J. Cao, Q. Zhang, Y. Li, and L. Xu. 2016. Edge Computing: Vision and Challenges. *IEEE Internet of Things Journal* 3, 5 (2016), 637–646. <https://doi.org/10.1109/JIOT.2016.2579198>
- [14] A.-T. Shumba and et al. 2023. Wearable Technologies and AI at the Far Edge for Chronic Heart Failure Prevention and Management: A Systematic Review and Prospects. *Sensors* 23, 15 (2023), 6896. <https://doi.org/10.3390/s23156896>
- [15] A. Singh and K. Chatterjee. 2023. Edge computing based secure health monitoring framework for electronic healthcare system. *Cluster Computing* 26 (2023), 1205–1220. <https://doi.org/10.1007/s10586-022-03717-w>
- [16] P. Spinosa. 2023. Implantação de modelos de aprendizado de máquina no formato ONNX utilizando diferentes frameworks. *Universidade Federal do Ceará* 1 (2023), 46. Trabalho de Conclusão de Curso.
- [17] N. J. Stone, J. G. Robinson, A. H. Lichtenstein, C. N. Bairey Merz, C. B. Blum, R. H. Eckel, A. C. Goldberg, D. Gordon, D. Levy, D. M. Lloyd-Jones, P. McBride, J. S. Schwartz, S. T. Sherlo, S. C. Jr Smith, K. Watson, and P. W. F. Wilson. 2014. ACC/AHA guideline on the treatment of blood cholesterol to reduce atherosclerotic cardiovascular risk in adults. *Circulation* 129, Suppl 2 (2014), S1–S45. <https://doi.org/10.1161/01.cir.0000437738.63853.7a>
- [18] S. Tuli, N. Basumatary, S. S. Gill, M. Kahan, R. C. Arya, G. S. Wander, and R. Buyya. 2020. HealthFog: An ensemble deep learning based Smart Healthcare System for Automatic Diagnosis of Heart Diseases in integrated IoT and fog computing environments. *Future Generations Computer Systems* 104 (2020), 187–200. <https://doi.org/10.1016/j.future.2019.10.043>
- [19] X. Wang and et al. 2020. Convergence of Edge Computing and Deep Learning: A Comprehensive Survey. *IEEE Communications Surveys & Tutorials* 22, 2 (2020), 869–904. <https://doi.org/10.1109/COMST.2020.2974448>
- [20] Q. Yang, Y. Liu, T. Chen, and Y. Tong. 2019. Federated Machine Learning: Concept and Applications. *ACM Transactions on Intelligent Systems and Technology* 10, 2 (2019), 12:1–12:19. <https://doi.org/10.1145/3298981>
- [21] S. Yi and et al. 2015. Security and Privacy Issues of Fog Computing: A Survey. In *Lecture Notes in Computer Science*. Springer International Publishing, Cham, 685–695. https://doi.org/10.1007/978-3-319-21837-3_6
- [22] Y. Zhao and et al. 2021. Edge Intelligence for Internet of Things in Healthcare: A Survey. *IEEE Access* 9 (2021), 45 – 59. <https://doi.org/10.1109/ACCESS.2020.3045115>

Received 16 Março 2025