

Abordagem iCAD: Explorando Inferência Neuro-Fuzzy na Predição da Doença da Artéria Coronária no Cenário da IoT*

Rodrigo Lambrecht¹, Rogério Albandes^{1,2}, Renato Dilli³
Lizandro de Souza Oliveira¹, Renata Reiser², Adenauer Yamin²

¹Mestrado em Engenharia Eletrônica e Computação - UCPel

²Programa de Pós-Graduação em Computação - UFPel

³Instituto Federal Sul-rio-grandense - IFSul

Abstract. *Cardiovascular diseases, especially coronary artery disease (CAD), represent a major challenge to global health. The proposals that have been gaining recognition in the literature in predicting CAD are Neuro-Fuzzy inference systems. Considering this scenario, this article discusses the design of an approach, called iCAD, which explores a distributed architecture in IoT and makes use of ANFIS to assist in CAD prediction. This approach was evaluated based on its functionalities and alerts generated, in addition to metrics related to prediction. In this sense, the iCAD approach obtained 92.28% Accuracy, 92.39% Precision, 93.75% Specificity, 92.28% Sensitivity and 92.29% F1-Score.*

Resumo. *As doenças cardiovasculares, especialmente a doença da artéria coronária (CAD), representam um grande desafio para a saúde global. As propostas que vem ganhando reconhecimento na literatura na predição da CAD, são os sistemas de inferência Neuro-Fuzzy. Considerando este cenário, este artigo discute a concepção de uma abordagem, denominada iCAD, que explora uma arquitetura distribuída na IoT e faz uso de ANFIS para auxiliar na predição da CAD. A abordagem concebida foi avaliada a partir das suas funcionalidades e alertas gerados, além das métricas relacionadas à predição. Neste sentido, a abordagem iCAD obteve 92,28% de Acurácia, 92,39% de Precisão, 93,75% de Especificidade, 92,28% de Sensibilidade e 92,29% de F1-Score.*

1. Introdução

A Doença da Artéria Coronária (CAD) é uma grave doença que afeta uma grande parte da população no Brasil e no Mundo, sendo consequência da obstrução das artérias coronárias que suprem o coração com sangue rico em oxigênio, podendo ser obstruídas por coágulos ou placas de gordura. Seu tratamento demanda da necessidade de visitas recorrentes à médicos e outros profissionais de saúde para avaliação e monitoramento [Alves 2010].

A Internet das Coisas (IoT – *Internet of Things*) vem cada vez mais se consolidando como o novo paradigma da Internet por ser considerada uma evolução computacional que possui uma infinidade de objetos físicos embarcados com sensores e atuadores,

*O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES)

conectados por redes com ou sem fio e que se comunicam através da Internet. Como o próprio termo contempla, são várias “coisas” conectadas entre si, sem a obrigatoriedade de uma intervenção humana. Esta visão da IoT promove a integração do mundo físico ao digital, de maneira a criar uma rede na qual a captura e o processamento de informações possam acontecer de forma autônoma e regida por regras [Perera 2017].

Neste cenário a Lógica *Fuzzy* (LF) tem se mostrado um mecanismo oportuno, principalmente para tratamento de dados vagos, incertos ou ambíguos, semelhante às expressões humanas. A LF visa representar o conhecimento e o raciocínio humano de modo o mais real possível, facilitando assim a construção de sistemas mais complexos. Por sua vez, como parte da abordagem *Fuzzy* se faz necessário o emprego de regras, cuja especificação pode ganhar elevada complexidade quando o número de atributos a serem considerados aumenta. Esta elevação no número de atributos impõem esforços adicionais aos especialistas responsáveis pela geração e manutenção das regras [Silva et al. 2019].

Tendo em vista essa motivação associada a geração automática de regras *Fuzzy*, o objetivo central deste trabalho é a concepção de uma abordagem, denominada iCAD, que dentre outros aspectos irá prover uma abordagem para auxiliar na predição da doença da artéria coronária. A iCAD explora funcionalidades do *middleware* EXEHDA em desenvolvimento no G3PD¹, contemplando um protótipo de hardware e uma plataforma de nuvem para monitoramento do paciente, explorando através desta a geração dinâmica de regras por meio de Sistemas de Inferência Neuro-Fuzzy Adaptativo (ANFIS).

2. Trabalhos Relacionados

Abaixo são caracterizados os principais trabalhos encontrados na literatura que tratam da predição da CAD, priorizando aqueles que fazem o uso de sistemas híbridos Neuro-Fuzzy.

O estudo de [Ziasabounchi and Askerzade 2014] - [A1] - visou desenvolver um modelo de previsão baseado em ANFIS para avaliar o grau de risco associado da CAD, utilizando o *dataset* “*Heart Disease UCI*”, contendo informações de 303 pacientes, utilizando sete parâmetros como entrada do modelo de previsão. Os dados foram pré-processados utilizando o método de normalização e inseridos com seus graus de pertinência, utilizando a função gaussiana para descrever cada um dos conjuntos de entrada *Fuzzy*. O modelo de previsão foi desenvolvido utilizando a ferramenta disponível no ambiente do *software* MATLAB e foi avaliado utilizando o método de validação cruzada do tipo *k-fold*, onde 80% dos dados foram utilizados para treinamento e 20% para teste. O desempenho foi medido pelo menor erro médio quadrático (MSE), tendo obtido um MSE de 0,01 para o conjunto de treinamento e 0,15 para o conjunto de testes.

O trabalho de [Sonal et al. 2022] - [A2] - apresenta uma proposta para abordar a detecção precoce de defeitos cardíacos congênitos em pacientes neonatais utilizando uma arquitetura de rede de três camadas baseada em WBAN (*Wireless Body Area Network*), monitorando parâmetros como o nível de oxigenação, a frequência cardíaca e a frequência respiratória. Estes parâmetros coletados mediante sensores são processados e analisados usando sistema de inferência Neuro-Fuzzy. Não é mencionado no texto o *dataset* utilizado para realizar o treinamento e geração de regras *Fuzzy* e também não é apresentada uma interface para operação distribuída. O estudo informa que os resultados obtidos foram

¹Grupo de Pesquisa em Processamento Paralelo e Distribuído da UCPel

capazes de ter uma boa capacidade de identificar corretamente anomalias cardíacas nos pacientes neonatais, porém as métricas de avaliação se concentram na performance da rede WBAN, considerando a eficiência de: (i) consumo de energia; (ii) probabilidade de canais disponíveis; (iii) tempo de *delay*; e (iv) tempo de *delay* médio.

O trabalho de [Khan and Algarni 2020] - [A3] - propõe uma estrutura baseada em uma solução IoMT (*Internet of Medical Things*) para aplicar um modelo de auxílio à predição da CAD com a combinação do uso de ANFIS e do algoritmo de otimização chamado de MSSO (*modified salp swarm optimization*). Para treinamento e validação também foi utilizado o *dataset* “*Heart Disease UCI*”. O método de avaliação do modelo proposto é realizado utilizando as plataformas Java e MATLAB, onde o mesmo apresentou resultados de: Sensibilidade de 97,89%, Especificidade de 97,88%, Precisão de 96,54% e Acurácia de 99,45%. Com relação à integração com dispositivos IoMT, os autores salientam que irão ser utilizadas tecnologias vestíveis e soluções já disponíveis no mercado.

O artigo [Baihaqi et al. 2016] - [A4] - propõe a utilização de algoritmos de árvore de decisão (*C4.5*, *CART* e *RIPPER*) para gerar regras *Fuzzy* para diagnóstico da CAD. Os autores utilizaram dois conjuntos de dados (*Hungarian Institute of Cardiology - Budapest* e *Cleveland Clinic*) com um total de 597 registros de pacientes para treinamento e teste do modelo proposto e durante o pré-processamento foram realizadas imputação manual de dados ausentes. Os autores utilizaram o *software* *MATLAB 7.12 (R2011a)* para projetar o sistema *Fuzzy* proposto e o *Weka 3.6* para gerar as regras dos algoritmos *C4.5*, *CART* e *RIPPER*. A comparação dos resultados foi realizada usando métricas de matriz de confusão com sensibilidade, especificidade, precisão, acurácia e *F-score*.

O artigo de [Manogaran et al. 2018] - [A5] - propõe o uso combinado de um classificador ANFIS com o algoritmo *Multiple Kernel Learning (MKL)* para predição da CAD. O método MKL é utilizado para reduzir a dimensão dos dados de entrada, dividindo os parâmetros em pacientes cardiopatas e indivíduos normais. O trabalho foi testado em um *dataset* com 250 observações e comparado com outras metodologias híbridas. Posteriormente, o ANFIS-MKL foi testado em 12 diferentes *datasets*, sendo que o *dataset* *KEGG Metabolic Reaction Network* obteve o melhor desempenho individual em Sensibilidade, Especificidade e Erro Quadrado Médio, alcançando 98%, 99% e 0,01, respectivamente. Os autores não especificam as plataformas ou linguagens utilizadas para realizar os testes.

A partir das características e funcionalidades dos Trabalhos Relacionados a Tabela 1 apresenta uma comparação entre os mesmos, tendo por base os principais aspectos considerados na concepção da abordagem iCAD, as quais são: (i) Predição de Doença Cardíaca; (ii) Uso de Lógica *Fuzzy*; (iii) Geração Automática de Regras; (iv) Uso de Neuro-Fuzzy; (v) Disponibilização de interface para Operação; (vi) Operação Distribuída; e (vii) Geração Dinâmica de Regras.

É possível observar que todos os trabalhos compartilham entre si e com a iCAD o emprego de Lógica *Fuzzy* para auxiliar na predição da doença da artéria coronária ou doença cardíaca. Também pode-se observar que todos os trabalhos contemplam a estratégia de geração automática de regras *Fuzzy*. Estes dois aspectos foram os centrais quando do estabelecimento de critérios para proximidade entre os trabalhos.

Dentre as metodologias utilizadas para geração de regras, apenas o A4 não faz

Tabela 1. Comparação dos Trabalhos Relacionados

Características	A1	A2	A3	A4	A5	iCAD
Predição de Doença Cardíaca	✓	✓	✓	✓	✓	✓
Lógica <i>Fuzzy</i>	✓	✓	✓	✓	✓	✓
Geração Automática de Regras	✓	✓	✓	✓	✓	✓
Neuro-Fuzzy	✓	✓	✓	×	✓	✓
Interface para Operação	×	×	×	×	×	✓
Operação Distribuída	×	✓	✓	×	×	✓
Geração Dinâmica de Regras	×	×	×	×	×	✓

uso especificamente de Neuro-Fuzzy, optando pelo uso de algoritmos baseados em árvore de decisões. Os trabalhos A2 e A3 apresentam propostas de um sistema distribuído explorando o cenário de IoT. Porém, em A2 o foco está voltado para a performance de funcionamento da rede de sensores sem fio, por sua vez o trabalho A3 não deixa claro como é gerenciada a aquisição distribuída de informações, tendo como foco principal a avaliação da metodologia híbrida desenvolvida, denominada MSSO-ANFIS.

Por sua vez, destacam-se como diferenciais na abordagem concebida para a iCAD a premissa de uma arquitetura de um sistema distribuído, bem como o seu uso em monitoramento de pacientes, permitindo o auxílio à predição da CAD de forma preventiva ao invés de análises de dados *Post-mortem*, com uma interface para operação por pacientes e profissionais da saúde. Além disso, outro diferencial da iCAD consiste na geração dinâmica de regras *Fuzzy*, permitindo que o sistema como um todo tenha uma realimentação por parte do especialista, aumentando assim a probabilidade futura de geração de regras com maior precisão.

3. iCAD: Concepção

A abordagem iCAD auxilia na predição da Doença da artéria coronária (CAD) empregando a geração dinâmica de regras *Fuzzy* a partir dos sistemas de inferência Neuro-Fuzzy. Fazendo uso de uma arquitetura distribuída que explora o ambiente IoT. Para tanto, foi utilizado o *middleware* EXEHDA em desenvolvimento no grupo de pesquisa G3PD.

3.1. Middleware EXEHDA

O EXEHDA consiste de um *middleware* baseado em serviços, o qual visa criar e gerenciar um ambiente computacional largamente distribuído, bem como promover a execução de aplicações ciente de situação sobre ele. Este *middleware* vem sendo explorado em frentes de pesquisa que tratam desafios da IoT. O EXEHDA possui uma organização composta por um conjunto de células de execução. Cada célula, no que diz respeito ao provimento de Ciência de Situação, é composta por um Servidor de Contexto (SC), e por diversos Servidores de Borda (SB) e *Gateways* [de Souza et al. 2019].

Os *Gateways*, também chamados de Dispositivos de Borda, coletam informações contextuais, provenientes de sensores físicos ou lógicos e têm a finalidade de tratar a heterogeneidade dos diversos tipos de sensores, em aspectos tanto de *hardware* como de protocolo, e transferir estas informações coletadas de forma normalizada aos Servidores de Borda. No EXEHDA os *Gateways* são implementados sobre um *hardware* embarcado específico para a finalidade de interoperar com sensores e atuadores.

3.2. Arquitetura

A Figura 1 apresenta os blocos que compõem a arquitetura concebida para a abordagem iCAD. O Servidor iCAD consiste de uma instância do Servidor de Contextos do EXEHDA, processado em um equipamento do tipo EXEHDAbase. Na sequência serão detalhados seus blocos e módulos.

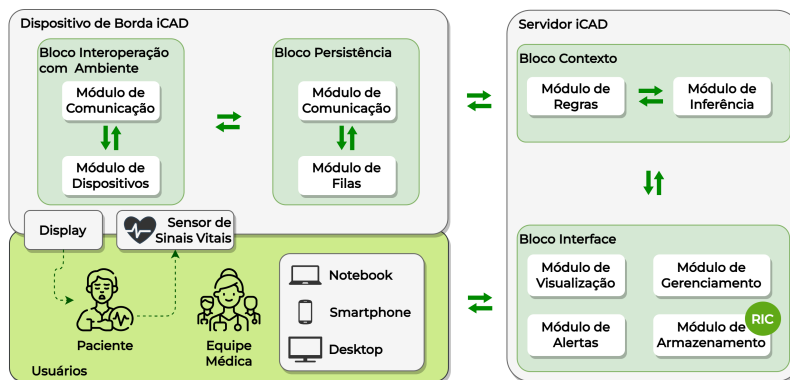


Figura 1. iCAD: Visão Arquitetural

Bloco Interface

O Bloco Interface é composto pelos módulos de Armazenamento, Gerenciamento, Visualização e Alertas.

Através do Módulo de Visualização, é possível prover suporte de interface com o usuário por meio de uma plataforma de nuvem. Mediante um procedimento de *login*, o usuário obtém acesso a informações para monitorar dados que auxiliam na predição da CAD. Isso é facilitado por *dashboards* e históricos que proporcionam uma visualização intuitiva e abrangente dos dados.

O Módulo de Armazenamento, conforme sugere seu próprio nome, assume a responsabilidade de armazenar as informações provenientes tanto do Dispositivo de Borda, por meio do Bloco de Persistência, quanto dos Módulos de Visualização e Gerenciamento, desempenhando um papel de RIC (Repositório de Informações Contextuais) do *middleware* EXEHDA.

O Módulo de Alertas tem por finalidade de interagir aos usuários, podendo ser profissionais de saúde e o próprio paciente sobre a sua condição, principalmente em caso de alguma situação em que seja percebida uma possível condição de risco, podendo serem enviados tanto via e-mail ou por meio do *display* incorporado ao Dispositivo de Borda.

O Módulo de Gerenciamento é responsável por gerenciar remotamente o Dispositivo de Borda. Isso inclui a capacidade de realizar atualizações relevantes para o seu funcionamento, como atualizações de *firmware* e configurações do intervalo de tempo entre o envio de informações contextuais.

Bloco Contexto

O Bloco Contexto desempenha uma função fundamental ao realizar a análise dos dados do paciente, utilizando tanto o Módulo de Regras quanto o Módulo de Inferência. A integração desses módulos permite a análise das informações coletadas por meio de

sensores físicos. O resultado dessa análise não apenas fornece dados isolados a serem armazenados, mas provê um contexto à esta informação.

O Módulo de Regras é central para a abordagem iCAD. O mesmo gerencia tanto as regras *Fuzzy* empregadas pelo ANFIS, como também gerencia as regras do tipo ECA (Evento-Condição-Ação) utilizadas para disparos de ações diversas, as quais possuem seus gatilhos definidos através da interface da plataforma de nuvem. Também neste Módulo são registrados os parâmetros empregados na rede Neuro-Fuzzy, onde as mesmas são geradas a partir do treinamento utilizando o sistema híbrido ANFIS. Cada novo registro coletado pelo sistema de inferência pode ser utilizado para realimentar o *dataset* contribuindo assim para novos dados a serem treinados. Salienta-se que este novo registro necessita de avaliação de um médico ou profissional de saúde com a devida capacidade para o mesmo. Ao identificar um novo registro no dataset, é realizado um novo treinamento a fim de gerar novas regras *Fuzzy* para o sistema.

O conceito ANFIS foi proposto inicialmente por Jang [Jang 1993] e é uma técnica de aprendizado adaptativa que utiliza a lógica *Fuzzy* para transformar entradas de um sistema em valores desejados de saída através do aprendizado supervisionado e o ajuste das funções de associação é feito mediante treinamento das redes neurais. Sua estrutura é composta por cinco camadas, como demonstrado na Figura 2. A primeira e a quarta camadas são constituídas por nós adaptativos, enquanto as outras são compostas por nós fixos.




Figura 2. Exemplo de Estrutura de uma rede ANFIS

Fonte: Adaptado de [Jang 1993]

O Módulo de Inferência é responsável por concentrar as informações provenientes do paciente, tanto inseridas no perfil através do Módulo Visualização do Bloco Interface e Contexto, quanto dos sinais vitais provenientes do Bloco Interação com Ambiente. Estes dados serão utilizados como entrada para o sistema de inferência *Fuzzy*, o qual irá realizar o processo de Fuzzificação desta entrada, consultar e aplicar as regras geradas pelo Módulo de Regras, chegando assim ao resultado da condição de risco do paciente. Esta condição de risco é submetida ao processo de Defuzzificação e enviada ao Bloco Interface para exibição.

Bloco Persistência

O Bloco Persistência é instanciado no Dispositivo de Borda do EXEHDA e é responsável por intermediar a comunicação entre os Bloco Interface e Contexto com o restante do *middleware* EXEHDA. Essa interconexão é realizada por meio do protocolo MQTT e do padrão JSON, proporcionando uma comunicação eficiente e estruturada entre os diversos componentes da arquitetura.

O Módulo de Filas realiza o armazenamento local dos dados provenientes do Bloco Interoperação com Ambiente para que os mesmos possam ser enviados apenas quando a comunicação com os Blocos Interface e Contexto esteja estável. Para garantir essa sincronização eficiente, é periodicamente verificado o *status* da comunicação com os Blocos Interface e Contexto.

O Módulo de Comunicação é responsável por interoperar com o Bloco Interoperação com Ambiente e os Blocos Interface e Contexto através do protocolo MQTT. No que diz respeito à sua relação com o Bloco Interoperação com Ambiente, a escrita se refere à atualização das informações de contexto e situação processadas pelo ANFIS a respeito do grau de risco associado a CAD. Já a respeito dos Blocos Interface e Contexto, a escrita se refere aos dados coletados do Bloco Interoperação com Ambiente, e a leitura se refere à leitura de informações provenientes do Módulo de Gerenciamento e Módulo Visualização.

Bloco Interoperação com Ambiente

Este bloco é responsável pela interoperação com o ambiente, mediante coleta de parâmetros fisiológicos do paciente através de sensores, e também através da exibição de informações provenientes do resultado da predição associada da CAD exibidos no *display* do dispositivo de borda utilizado pelo paciente.

O Módulo de Comunicação é responsável por intermediar a relação entre o Bloco Interoperação com Ambiente e o Bloco Persistência. É um bloco que possui fluxo bidirecional, realizando a escrita no Bloco Persistência dos sinais vitais coletados pelo Módulo de Dispositivos e recebendo informações a serem exibidas no *display*.

O Módulo de Dispositivos é responsável por adquirir sinais vitais do paciente, com o propósito de, posteriormente, transmiti-los ao Módulo de Comunicação do Bloco de Persistência. Além disso, cabe a ele a função de estabelecer comunicação com o dispositivo *display*, com o intuito de exibir as informações relacionadas à condição do paciente.

4. Avaliação Realizada

Considerando as alternativas presentes na literatura da área de ciência da computação, neste trabalho optou-se pelo emprego de uma avaliação baseada em cenários. Destacam-se como principais razões para esta escolha os seguintes critérios: (i) ser considerada uma alternativa madura para ser empregada em ambientes como os da IoT [Patidar and Suman 2015]; e (ii) ser explorada para avaliar a utilização de uma arquitetura de software em relação às demandas de um conjunto de aplicações [Shanmugapriya and Suresh 2012].

Neste sentido, as funcionalidades desta abordagem iCAD foram avaliadas explorando dois cenários de uso:

- Revisão das funcionalidades da abordagem iCAD, particularmente as diferentes interfaces oferecidas para a comunidade usuária, bem como a emissão de alertas, tanto via recursos físicos junto ao paciente (Dispositivo de Borda), como pela plataforma de nuvem da iCAD;
- Discussão do impacto da geração dinâmica de regras, com base nos resultados das métricas consideradas na avaliação.

Protótipo de Hardware

A partir do projeto de hardware, foi realizada a prototipação do Dispositivo de Borda baseado no *SOC ESP32*, conforme demonstrado na Na Figura 3, contendo Sensor de Frequência Cardíaca MAX30100, *Display SSD1306* e Carregador de Baterias TP4056. Para desenvolvimento do *firmware* foi utilizada a linguagem C pelo fato de a mesma ser nativa para o *SOC ESP32* e possuir suporte, também de forma nativa, ao *FreeRTOS*, o qual possibilita um melhor gerenciamento de multi tarefas nas aplicações do sistema embarcado, assim como o recurso de filas (*queues*) utilizadas no Módulo Persistência.


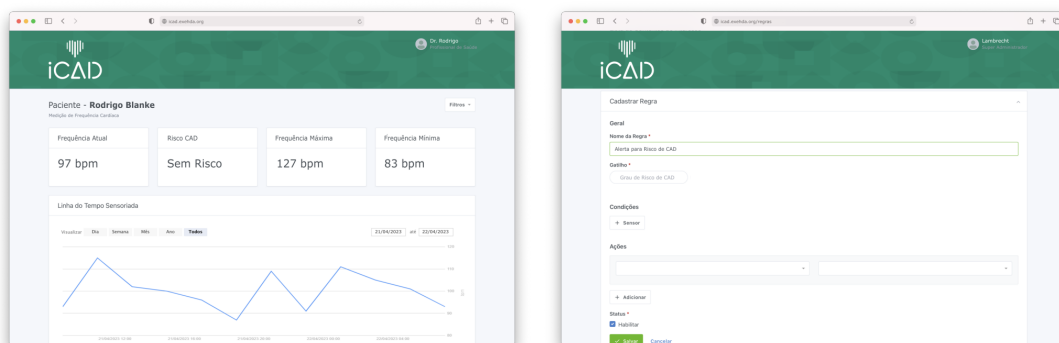


Figura 3. Funcionamento do dispositivo de borda iCAD

Plataforma de Nuvem

A avaliação das funcionalidades da plataforma de nuvem para interface operacional oferecida pela iCAD está organizada a partir da percepção disponibilizada ao usuário, utilizando uma abordagem que prioriza uma visão do geral ao mais específico, baseada na visualização que os usuários têm ao utilizarem a plataforma da nuvem da iCAD. Conforme demonstrado no exemplo de suas telas na Figura 4. As principais tecnologias de software empregadas utilizadas na concepção da abordagem iCAD foram: *JavaScript Object Notation - JSON*, Linguagem *Python* e C, Protocolo *MQTT*, e o sistema gerenciador de banco de dados *PostgreSQL*.



(a) Dashboard do Paciente

(b) Gerenciamento de Regras

Figura 4. Exemplo de Telas da Plataforma de Nuvem

Impacto da Geração Dinâmica de Regras

Para avaliar o impacto da Geração Dinâmica de Regras *Fuzzy*, utilizando linguagem *Python*, foram utilizados dados do *Heart Cleveland dataset - UCI*, assim como a grande

parte dos trabalhos relacionados. Este conjunto de dados possui um total de 303 amostras, cada uma contendo 76 parâmetros, porém apenas 14 destes são utilizados nos estudos de *machine learning*, sendo que 13 parâmetros são utilizados como entrada, e 1 como saída que indica o grau de risco da CAD associado àquele paciente. Ainda que este *dataset* possua uma quantidade de amostras considerada baixa, o mesmo é amplamente utilizado em diversos trabalhos na literatura [Aljanabi et al. 2018].

Para o uso deste *dataset* faz-se necessário seguir algumas etapas de preparação do mesmo, somente após esta preparação é possível submetê-lo ao processo de treinamento, o qual irá gerar o conjunto de regras *Fuzzy* a ser empregado pela iCAD. A **primeira etapa** consiste em remover os registros com dados faltantes ou inválidos; A **segunda etapa** envolve identificar os atributos que possuem maior relevância para determinar uma condição de risco associado da CAD. Para isto foi utilizado o mapa de correlação entre os atributos de entrada e o valor de saída; Na **terceira etapa** foram removidos os registros que possuem *outliers* em algum dos atributos selecionados. Os *outliers* são valores que se diferenciam drasticamente dos demais valores para um mesmo atributo, afetando diretamente na performance de treinamento e nos resultados dos testes.

Com isso, restaram 285 registros para serem utilizados na avaliação do impacto da geração dinâmica de regras. Para esta avaliação estes dados foram separados em dois conjuntos: 80% para treinamento e 20% para testes. A geração dinâmica ocorre quando novos dados são inseridos em um sistema de inferência, desta forma para simular este comportamento, os dados de treinamento foram subdivididos em seis conjuntos contendo respectivamente 90%, 92%, 94%, 96%, 98% e 100% do conjunto de treinamento.

Para avaliar cada um dos seis conjuntos de treino do modelo proposto, foram utilizadas as principais métricas de avaliação, sendo elas: acurácia, precisão, especificidade, sensibilidade e *F1-Score*, assim como a maioria dos trabalhos realizados também o fazem. Para o treinamento e geração de regras, o sistema ANFIS foi configurado com 20 épocas e funções de pertinência do tipo gaussiana, obtendo assim os seguintes resultados para cada um dos seis conjuntos de treinamento:

- **Acurácia:** Obteve uma elevação de resultado em 2,33%, comparando os 90,17% iniciais com os 92,28% finais;
- **Precisão:** Também obteve um bom aumento em seu percentual, aumentando de 90,44% para 92,39%, representando 2,15%;
- **Especificidade:** Inicialmente havia-se um valor de 92,96% e ao final obteve-se 93,75%, um aumento de apenas 0,84%;
- **Sensibilidade:** Obteve aumento também próximo de 2,33%, resultado da comparação entre o resultado do primeiro treino de 90,17% para o resultado do último treino de 92,28%;
- **F1-Score:** Também se mostrou com aumento na faixa de 2,32%, onde inicialmente havia obtido um resultado de 90,19% e por fim 92,29%.

5. Conclusões

Este artigo discutiu as principais características da abordagem iCAD, uma arquitetura distribuída fazendo uso de ANFIS e IoT para auxílio na predição da doença da artéria coronária (CAD). Os resultados obtidos permitem concluir que a abordagem é viável, apontando para a continuidade das pesquisas na área.

Além disto, esta abordagem possui pontos cruciais ainda não explorados pelos trabalhos encontrados na literatura, onde se destaca a possibilidade de acompanhamento remoto do paciente e uma operação efetivamente distribuída, na qual os dados coletados são tratados em diferentes instâncias, gerando retornos dinâmicos tanto para pacientes, como para profissionais de saúde.

Entretanto, é essencial ressaltar que, a aplicação prática da iCAD requer um rigoroso processo de validação e adaptação ao ambiente clínico real, tendo que considerar cuidadosamente questões éticas e de privacidade em uma ferramenta de auxílio ao diagnóstico médico. Além disso, para um pleno aproveitamento da arquitetura provida pela iCAD, seria fundamental a conscientização e o treinamento adequado para profissionais de saúde, garantindo que sua operação seja feita de forma responsável e eficiente.

Como trabalhos futuros, a interoperação com profissionais de saúde, apontou um foco no dispositivo de borda, com as seguintes perspectivas: implementação de demais sensores de sinais vitais para contemplar todos os usualmente empregados em acompanhamento clínico e a otimização do *hardware* para baixar o consumo e assim aumentar a autonomia do dispositivo de borda usualmente operado a bateria.

Referências

- Aljanabi, M., Qutqut, M. H., and Hijjawi, M. (2018). Machine learning classification techniques for heart disease prediction: a review. *International Journal of Engineering & Technology*, 7(4):5373–5379.
- Alves, C. (2010). *Cardiologia do Exercício: do Atleta Ao Cardiopata*.
- Baihaqi, W. M., Setiawan, N. A., and Ardiyanto, I. (2016). Rule extraction for fuzzy expert system to diagnose coronary artery disease. pages 136–141.
- de Souza, R. S., Barbará Lopes, J. L., Resin Geyer, C. F., da Rosa Silveira João, L., Afonso Cardozo, A., Corrêa Yamin, A., Gadotti, G. I., and Victoria Barbosa, J. L. (2019). Continuous monitoring seed testing equipments using internet of things. *Computers and Electronics in Agriculture*, 158:122 – 132.
- Jang, J.-S. R. (1993). Anfis adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems Man and Cybernetics*, 23(3):665–685.
- Khan, M. A. and Algarni, F. (2020). A healthcare monitoring system for the diagnosis of heart disease in the iomt cloud environment using msoo-anfis. *IEEE Access*, 8:122259–122269.
- Manogaran, G., Varatharajan, R., and Priyan, M. K. (2018). Hybrid recommendation system for heart disease diagnosis based on multiple kernel learning with adaptive neuro-fuzzy inference system. *Multimedia Tools and Applications*, 77(4):4379–4399.
- Patidar, A. and Suman, U. (2015). A survey on software architecture evaluation methods. In *2015 2nd International Conference on Computing for Sustainable Global Development (INDIACom)*, pages 967–972. IEEE.
- Perera, C. (2017). *Sensing as a Service for Internet of Things: A Roadmap*. Leanpub Publishers.
- Shanmugapriya, P. and Suresh, R. (2012). Software architecture evaluation methods-a survey. *International Journal of Computer Applications*, 49(16).
- Silva, M., Cardoso, M. A., Machado, M. C., and Ferreira, A. P. L. (2019). Sistema de inferência fuzzy para estimativa de crescimento populacional. *Anais do Salão Internacional de Ensino, Pesquisa e Extensão*, 11(2).
- Sonal, Reddy, S., and Kumar, D. (2022). Early congenital heart defect diagnosis in neonates using novel wban based three-tier network architecture. *Journal of King Saud University - Computer and Information Sciences*, 34(6, Part B):3661–3672.
- Ziasabounchi, N. and Askerzade, I. (2014). Anfis based classification model for heart disease prediction. *International Journal of Engineering & Computer Science IJECS-IJENS*, 14:146402–7373.