

# P-GRAFIT: Plataforma de Visualização de Grafos de Classificação para Auxiliar o Desenvolvimento de Aplicações de Internet das Coisas Médicas

Miguel Edson Ramos Lima<sup>1</sup>, Evilásio Costa Júnior<sup>1</sup>, Lara Vitória Lima Braga<sup>1</sup>, Jefferson de Aguiar Sousa<sup>1</sup>, Pedro Eric Carneiro<sup>1</sup>, Manoel Farias de Oliveira<sup>1</sup>, Leonardo Sampaio Rocha<sup>2</sup>, Rossana Maria de Castro Andrade<sup>1</sup>

<sup>1</sup>Universidade Federal do Ceará (UFC)

<sup>2</sup>Universidade Estadual do Ceará

{migueledson, lara.lbraga, jeffersonaguiar}@alu.ufc.br

{pedroericcarneiro, manoelfariaspr}@alu.ufc.br

{evilasiojunior, rossana}@ufc.br, leonardo.sampaio@uece.br

**Abstract.** *The advancement of the Internet of Health Things (IoHT) has revolutionized continuous health monitoring. However, manipulating sensor data from different sources and relating them to health states is a complex task. Classification graphs are structures that can aid in the manipulation of this data, identifying relationships between sensors, smart algorithms, and health states. However, these structures are not simple to interpret and require adequate visualizations, but such solutions are uncommon. This paper presents P-GRAFIT, a platform designed to assist in the interpretation, visualization, and creation of classification graphs for ioHT systems. The solution acts as an abstraction layer that automatically converts complex data into visual representations, assisting from requirements elicitation to the selection of Artificial Intelligence algorithms. To evaluate the proposal and prove the platform's functionality, a proof of concept was implemented with samples of pre-generated classification graphs. In addition, we explore a usage scenario the platform to assist the development of IoHT application.*

**Resumo.** *O avanço da Internet das Coisas Médicas (IoHT) revolucionou o monitoramento contínuo da saúde. Entretanto, manipular dados de sensores de fontes distintas e relacioná-los com estados de saúde é uma tarefa complexa. Grafos de classificação são estruturas que podem auxiliar a manipulação desses dados, identificando relações entre sensores, algoritmos inteligentes e estados de saúde. No entanto, essas estruturas não são simples de interpretar e demandam visualizações adequadas, mas soluções desse tipo são pouco comuns. Este artigo apresenta a P-GRAFIT, uma plataforma projetada para auxiliar na interpretação, visualização e criação de grafos de classificação para sistemas IoHT. A solução atua como uma camada de abstração que converte dados complexos em representações visuais de forma automática, auxiliando desde a elicitação de requisitos até a seleção de algoritmos de Inteligência Artificial.*

*Para avaliar a proposta, e comprovar a funcionalidade da plataforma, foi implementada uma prova de conceito com amostras de grafos de classificação pré-gerados. Além disso, exploramos um cenário de uso da plataforma para auxiliar o desenvolvimento de uma aplicação IoHT.*

## **1. Introdução**

A Internet das Coisas Médicas (do inglês, *Internet of Health Things* - IoHT) [Oliveira et al. 2025, Islam et al. 2025] compreende um ecossistema de dispositivos e sensores conectados, dedicados ao monitoramento e rastreamento contínuo de indicadores de saúde. As soluções de IoHT podem ser usadas para identificar problemas de saúde antes que se tornem graves, bem como para monitorar e gerenciar doenças crônicas [Kandukuri et al. 2025]. Essas soluções podem compreender o uso de dispositivos que variam de vestíveis, como *smartwatches*, a equipamentos médicos, como monitores cardíacos e bombas de insulina, e até aplicativos e serviços que permitem aos usuários monitorar sua dieta e exercícios. Os dados coletados por esses dispositivos são analisados para obter informações sobre o estado de saúde de uma pessoa e ajudá-la a tomar decisões informadas sobre sua qualidade de vida e saúde [de Oliveira et al. 2022].

O desenvolvimento de soluções IoHT envolve muitos desafios, um dos quais é a interoperabilidade de dados. Esse desafio está relacionado à garantia de que os dados de diferentes dispositivos conectados sejam compatíveis e possam ser compartilhados e manipulados de maneira adequada [Rubí and Gondim 2020]. A interoperabilidade deve ser considerada pela equipe de desenvolvimento desde as etapas de levantamento de requisitos e projeto até a implementação, teste e implantação da solução IoHT [Gürdür and Asplund 2018, Abukwaik and Rombach 2017].

A construção de artefatos de *software* reutilizáveis é uma maneira conhecida e bem explorada na comunidade de desenvolvimento para padronizar soluções bem aceitas, reduzir custos de desenvolvimento e auxiliar a construção de novas soluções de *software* [Natarajan 2025]. Numerosos artefatos de *software* estão sendo propostos para minimizar os desafios relacionados ao desenvolvimento de aplicações IoHT recentemente [de Oliveira et al. 2025, Junior et al. 2024, Bahbouh et al. 2023], entre os quais alguns propõem abordar a questão da interoperabilidade em contextos específicos [Rajagopal and Subramanian 2025, Junior et al. 2023].

Nesse sentido, o modelo proposto em [Junior et al. 2023] foi utilizado como um artefato conceitual para o desenvolvimento da P-GRAFIT, uma plataforma concebida para a criação, visualização e gestão de grafos de classificação. Dessa forma, a P-GRAFIT é baseada numa versão atualizada do modelo de construção de grafos de classificação proposto em [Junior et al. 2023] que facilita a tomada de decisão relacionada a interoperabilidade de sensores e a análise de dados, oferecendo uma solução reutilizável por diversas aplicações de IoHT.

O grafo de classificação proposto relaciona sensores, *features*, algoritmos de classificação, atividades ou estados de saúde. Os grafos gerados utilizando esse modelo podem auxiliar etapas do desenvolvimento, desde a elicitação de requisitos até a escolha de modelos de IA para inferência de estados de saúde que podem ser monitorados em diferentes contextos. Nesse sentido, a plataforma P-GRAFIT permite a visualização em alto nível dos grafos gerados usando esse modelo, servindo como uma ferramenta de análise

e auxiliando os desenvolvedores na tomada de decisão. A P-GRAFIT atua como uma camada de abstração que automatiza o processamento de dados e oferece uma representação visual interativa do fluxo de inferência da solução IoHT.

Para avaliar a plataforma proposta, implementamos uma prova de conceito a partir de uma instância do grafo de classificação. Este grafo foi gerado com base em dois *datasets* de IoHT voltados a análise de padrões de movimento, e contempla quatro algoritmos de classificação, incluindo uma Rede Neural Artificial (RNA), uma Árvore de Decisão (AD), uma Floresta Aleatória (FA) e uma Máquina de Vetores de Suporte (em inglês, *Support Vector Machine* - SVM). Também exploramos um cenário de uso da plataforma e do grafo para construção de uma aplicação IoHT para dispositivos móveis.

## 2. Trabalhos Relacionados

Muitos estudos propõem o uso de artefatos de *software* para auxiliar o desenvolvimento de aplicações IoHT. Esses estudos se relacionam ao nosso trabalho em diferentes contextos, como a modelagem e reuso de aplicações IoHT [Mukherjee et al. 2021], uso de grafos e aprendizado de máquina em tarefas clínicas (com foco em quedas) [Egawa et al. 2023] e o desenvolvimento de aplicações orientadas a grafos para monitoramento e segurança em ecossistemas de saúde conectados [Lamichhane et al. 2022] [Ravikumar et al. 2026] .

Mukherjee *et al.* (2021) discutem uma arquitetura IoHT integrada *edge-fog-cloud* para monitoramento personalizado, com preocupações de latência e eficiência. Apesar do foco em infraestrutura, o trabalho reforça um aspecto central para este projeto: aplicações IoHT operam sobre fluxos conectados e decisões distribuídas. A P-GRAFIT aborda o mesmo desafio por outra lente, oferecendo mecanismos de navegação e observabilidade do grafo para apoiar atividades de engenharia de *software*.

Já Egawa *et al.* (2023) propõem uma abordagem baseada em operações espaço-temporais e atenção para detecção automática de quedas, explorando relações estruturais do movimento. Embora esse tipo de solução tenda a elevar desempenho, também aumenta complexidade e pode reduzir interpretabilidade operacional para o desenvolvedor. A proposta da P-GRAFIT se diferencia deste trabalho, ao mirar na interpretabilidade, permitindo inspeção de entidades e conexões do grafo, leitura de probabilidades e localização rápida de pontos críticos, favorecendo validação e manutenção do sistema.

Estruturas de grafo vêm sendo empregados também para analisar comportamento, risco e anomalias em IoHT. Em [Lamichhane et al. 2022] são investigados padrões de violação (*breach patterns*) por meio de modelagem em grafo e técnicas de aprendizado de máquina, reforçando que a estrutura relacional dos eventos é um sinal tão relevante quanto métricas isoladas. De maneira correlata, em [Ravikumar et al. 2026] é discutido um modelo baseado em convoluções em grafos dinâmicos para monitoramento em *fog computing*, evidenciando uma tendência prática: grafos deixam de ser apenas forma de visualização e passam a ser também objeto computacional da solução.

Podemos observar que a literatura aborda artefatos de reuso para IoHT. Porém, poucos trabalhos focam na visualização de alto nível dos elementos desses artefatos de reuso, como os grafos. Uma visualização adequada é fundamental para auxiliar a explicabilidade e a tomada de decisão com base nesses artefatos, especialmente quando o grafo cresce em densidade e diversidade de entidades. Nesse contexto, a P-GRAFIT se posi-

ciona como uma solução de visualização de alto nível para grafos de classificação que podem ser usados para auxiliar o desenvolvimento de soluções IoHT.

### 3. Metodologia

Para desenvolvimento da plataforma P-GRAFIT foi utilizada uma abordagem de *Design Thinking* e um processo de desenvolvimento iterativo incremental.

O *Design Thinking* [Verganti et al. 2021] define por cinco etapas: Na primeira (Empatia) o foco é entender o problema e os usuários que vão utilizar a solução. Nesta fase buscamos compreender a fundo o modelo proposto em [Junior et al. 2023] e a demanda por uma visualização de alto nível dos grafos de classificação, bem como identificamos como essa visualização poderia ser utilizada pelo desenvolvedor da solução IoHT.

Na segunda etapa (Análise), avaliamos as informações coletadas na fase anterior e as organizamos para na terceira etapa (Definição) definirmos uma solução e montar um documento com os requisitos principais da plataforma, além de definir as tecnologias a serem utilizadas. Então, na quarta fase (Prototipação) desenvolvemos um protótipo, utilizando o processo de desenvolvimento iterativo e incremental para desenvolver a primeira versão da plataforma. Na fase final (Avaliação e Testes) avaliamos o protótipo utilizando uma prova de conceito como validação inicial, para posterior validação em um cenário de uso real.

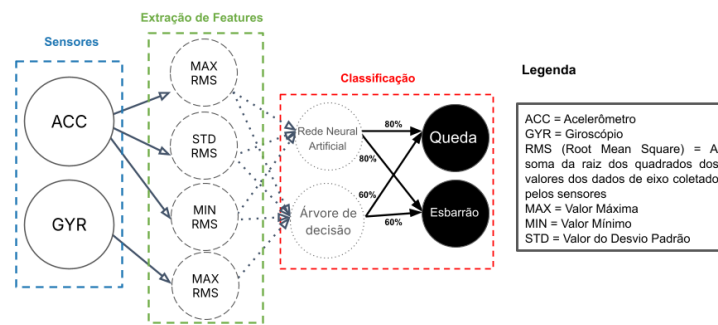
Os artefatos gerados durante o desenvolvimento da plataforma, incluindo requisitos, arquitetura e exemplos das visualizações geradas pelo P-GRAFIT são apresentadas na seção 4, no resto dessa seção iremos apresentar o modelo de grafo de classificação que embasa a plataforma em sua versão mais atualizada.

#### Modelo do Grafo de Classificação

O modelo proposto em [Junior et al. 2023] tem como objetivo criar uma representação das relações entre alguns elementos fundamentais para criação de aplicações IoHT modernas com objetivo de auxiliar a tomada de decisão durante as etapas de desenvolvimento da aplicação e criar uma possível representação de conhecimento que pode ser reutilizadas diretamente pela aplicação para inferência de estados de saúde.

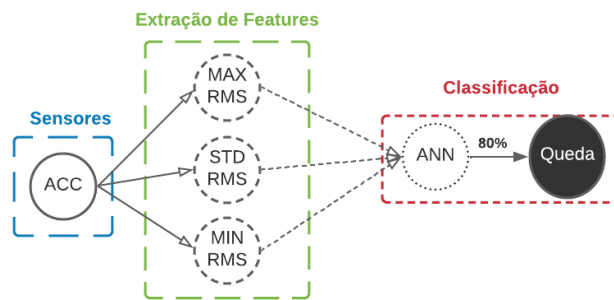
A Figura 1 apresenta um exemplo do grafo de classificação gerado com o modelo proposto. Esse modelo gera um grafo em quatro camadas: na primeira camada temos a representação dos sensores dos dispositivos IoHT; na segunda camada temos um conjunto de *features* que podem ser extraídas dos dados coletados por esses sensores e que podem ser usados como entradas para os modelos de aprendizado de máquina; na terceira camada temos um conjunto de modelos de aprendizado de máquina (algoritmos de classificação) que podem ser usados para inferir o estado de saúde; finalmente na quarta camada temos os estados finais que aplicação IoHT deseja identificar.

Cada camada do grafo é representada por um conjunto de vértices e arestas (na Figura 1 podem ser vistos tracejados específicos para diferenciar cada camada). Vale destacar que nas arestas que ligam os algoritmos de classificação e os estados finais (representados pelos vértices) são rotuladas as probabilidades que indicam a acurácia obtida durante a avaliação dos modelos de aprendizado de máquina treinados quando o grafo é criado. Ao criarmos o grafo, os modelos de aprendizado de máquina treinados também são armazenados, caso o desenvolvedor deseje utilizá-lo em sua aplicação.



**Figura 1. Exemplo de Grafo de Classificação**

Em alguns casos, o desenvolvedor da aplicação IoHT pode desejar utilizar apenas alguns sensores presentes no grafo ou utilizar apenas um conjunto reduzido dos modelos de aprendizado de máquina pré-treinados. Nesse caso também é possível gerar uma versão otimizada do grafo, como pode ser visto na Figura 2.



**Figura 2. Exemplo de Grafo de Classificação otimizado**

Além de apresentar a representação do modelo de grafo, em [Junior et al. 2023] também é proposto um processo para criação do grafo. O processo começa com a coleta de informações de *datasets* com dados de experimentos previamente executados. A partir desses *datasets* é possível coletar a lista de sensores e estados finais. Após a coleta dos dados nos *datasets*, deve ser executada a fase de pré-processamento e extração de *features*. Com isso, é obtido o conjunto de *features* que serão usadas como entradas para o treinamento dos algoritmos de aprendizado de máquina.

Os algoritmos de aprendizado de máquina que serão utilizados devem ser selecionados pelo desenvolvedor. Há diversos estudos que indicam algoritmos que se comportam melhor para diferentes aplicações IoHT, inclusive alguns trabalhos recomendando a combinação de diferentes algoritmos para obter melhor acurácia [Fu et al. 2025] [Kandukuri et al. 2025].

Uma vez treinados e avaliados os modelos, podemos gerar a versão final do grafo de classificação e armazenar também os modelos pré-treinados para uso futuro, caso seja desejo dos desenvolvedores. Em [Junior et al. 2023], foi gerada uma prova de conceito de grafos de classificação. Porém, todas as versões foram disponibilizadas em linguagem de marcação (XML) que pode dificultar o entendimento da visualização a fim de auxiliar a tomada de decisão.

## 4. P-GRAFIT

A plataforma P-GRAFIT permite a manipulação e visualização de alto nível dos grafos de classificação gerados com base no modelo de construção de grafos de classificação proposto em [Junior et al. 2023]. A seguir, detalhamos e discutimos as principais etapas do processo de desenvolvimento, incluindo *design* e implementação da P-GRAFIT.

### 4.1. Requisitos e *Design* Centrado no Usuário

A leitura direta de arquivos em linguagem de marcação mostra-se uma atividade exaustiva e complexa, podendo prejudicar a interpretabilidade e a tomada de decisão baseada nesses artefatos. Diante desse cenário, a construção da interface da P-GRAFIT foi orientada por princípios de *User Experience* (UX), visando otimizar a interpretação de fluxos de dados e garantir uma navegação fluida e intuitiva para o desenvolvedor.

O fluxo visual foi planejado para estabelecer um mapeamento lógico que reflete a sequência real de processamento da leitura do grafo de classificação de sistemas de IoHT. Dessa forma, a trajetória da informação é apresentada de maneira intuitiva, iniciando-se na representação dos sensores e encerrando nos estados finais.



Figura 3. Padronização cromática das categorias de nós para redução da carga cognitiva.

Adotou-se uma padronização cromática fixa para melhor compreensão do usuário. Ao atribuir cores específicas para cada categoria de nó: azul para sensores (*sensor*), laranja para *features*, verde para modelos (*model*) e vermelho para estados finais (*final status*), a plataforma permite a identificação imediata da natureza do dado sem a necessidade de leitura exaustiva de rótulos, como ilustrado nesse esquema da Figura 3. Essa categorização visual permite que o usuário filtre informações relevantes antes mesmo da leitura dos rótulos textuais, otimizando a análise de sistemas IoHT.




Figura 4. Interface da P-GRAFIT destacando as ferramentas de navegação: busca, centralização e controles de escala.

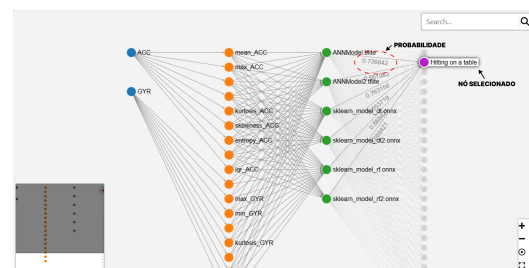


Figura 5. *Feedback* interativo da plataforma: destaque visual (*hover*) de um nó e suas conexões diretas.

Acrescido da padronização das cores, a interface foi organizada em quatro colunas verticais fundamentadas no modelo proposto em [Junior et al. 2023], estabelecendo um

mapeamento natural do processo de inferência. Essa disposição promove a linearidade da leitura do usuário, uma vez que o fluxo da informação ocorre da esquerda para a direita, partindo da coleta física nos sensores até as probabilidades do estado final.

E para que o usuário possa visualizar esse grafo de forma otimizada, a plataforma disponibiliza um conjunto de ferramentas de suporte, incluindo busca por nós com centralização automática, controles de aproximação e distância, mini mapa e opção de visualização em tela cheia conforme ilustrado na Figura 4.

Dessa forma, a interatividade é reforçada pelo *feedback* imediato ao usuário; ao interagir com uma entidade específica, o sistema isola visualmente o caminho do dado (Figura 5), permitindo uma análise clara das probabilidades de predição associadas.

## 4.2. Arquitetura e Implementação Técnica

A implementação da plataforma P-GRAFIT adotou uma arquitetura desacoplada, orientada à performance e escalabilidade, separando o processamento de dados da interface de visualização. Dessa forma, foi separado em duas frentes principais: O processamento e Conversão de Dados (*Back-end*) e Ambiente *Front-end* de Visualização.

Devido à complexidade dos arquivos XML utilizados na modelagem original do modelo proposto em [Junior et al. 2023], a manipulação direta desses dados apresentou limitações. Para contornar esse problema, a gestão de dados da plataforma é sustentada por um algoritmo em *Python* desenvolvido para realizar a conversão automática de arquivos XML para o formato JSON. Este conversor foi integrado a uma estrutura de *backend* que automatiza o processamento dos arquivos no momento do *upload*, garantindo a geração instantânea da representação visual. Consequentemente, a estrutura de dados resultante permite o mapeamento preciso das interdependências entre os sensores na origem, o processamento das *features*, a inferência dos modelos e os estados finais.

Paralelamente, a camada de usuário foi desenvolvida utilizando o *framework* *Next.js*, escolhido por sua modularidade e facilidade de manutenção em relação ao *React* puro empregado nas versões iniciais. A renderização dos grafos utiliza a biblioteca *React Sigma*, que permite a manipulação de grafos interativos de alta performance via *WebGL*. Para garantir estabilidade, foi necessária a reestruturação do ciclo de vida dos componentes no *framework*, evitando vazamentos de memória durante as renderizações.

Durante o desenvolvimento da P-GRAFIT, vale ressaltar que o projeto foi migrado da versão 4.0 para a versão 5.0 da biblioteca *React Sigma*. Apesar da necessidade de reestruturação dos pacotes de busca, essa atualização possibilitou que funcionalidades avançadas de navegação fossem incorporadas para otimizar a exploração de grafos complexos, como a implementação de um minimapa para orientação espacial e um sistema de busca que permite localizar e centralizar automaticamente nós específicos. Além disso, foram desenvolvidas customizações de interação, como o destaque (*hover*) de nós e arestas. Tais melhorias garantem uma visualização clara das conexões sistêmicas e facilitam a interpretação das probabilidades associadas a cada modelo de classificação.

## 5. Avaliação e Resultados

A plataforma P-GRAFIT foi validada por meio de uma prova de conceito (do inglês, *Proof of Concept* - PoC) onde foram testadas diferentes visualizações do grafo de classificação gerado com base na versão atualizada da PoC utilizada em [Junior et al. 2023].

## 5.1. Grafo de Classificação

O grafo de classificação foi gerado utilizando uma versão atualizada do código da PoC apresentada em [Junior et al. 2023]. Esse grafo tem como fonte base dois *datasets* de IoHT, o primeiro gerado a partir da leitura dos dados de acelerômetro e giroscópio [Linhares et al. 2020], enquanto o segundo foi gerado apenas com dados de acelerômetro [Bruno et al. 2013]. Esses dados foram utilizados para inferência de padrões de movimento e situações de risco à saúde. Para cada sensor (giroscópio e acelerômetro) foram extraídas nove *features* (média, valor máximo, valor mínimo, desvio padrão, *kurtosis*, *skewness*, entropia, desvio absoluto médio e intervalo interquartil).

As *features* foram usadas como entrada para quatro algoritmos de aprendizado de máquina, uma rede neural artificial, uma árvore de decisão, uma floresta aleatória e uma SVM, esse último foi adicionado especificamente para essa nova versão. Para cada um desses algoritmos foram gerados dois modelos, um utilizando como entrada as dezoito *features* (as nove *features* extraídas de cada sensor) e tendo como saída dezessete estados finais; e outro modelo utilizando como entrada apenas as nove *features* extraídas dos dados coletados com o sensor de acelerômetro e tendo como saída trinta estados finais (incluindo os dezessete do primeiro modelo). Desse modo, foi gerado um grafo de classificação com dois sensores associados a dezoito *features*, oito modelos de aprendizado de máquina treinados e trinta estados finais. Foram também armazenados os oito modelos treinados, caso os desenvolvedores queiram reutilizá-los em suas aplicações.

## 5.2. Prova de Conceito

O *backend* da prova de conceito foi desenvolvido em Python e teve como principal funcionalidade o processamento dos arquivos do grafo em formato JSON, possibilitando o processamento e a visualização dos dados na plataforma. Também, foi desenvolvido um mecanismo de conversão dos arquivos de grafo em XML para objetos JSON manipuláveis. Todas as relações originais entre *sensor*, *features*, *model* e *final status* foram preservadas durante a transição entre os formatos, garantindo não somente a integridade dos dados mas também a visualização fiel ao modelo matemático subjacente.

Na versão mais atual do P-GRAFIT, após o processamento dos objetos JSON é feita a reestruturação dos componentes do sistema para o ambiente *WebGL* eliminando as falhas de memória observadas nas versões preliminares da plataforma, permitindo a atualização fluida dos grafos.

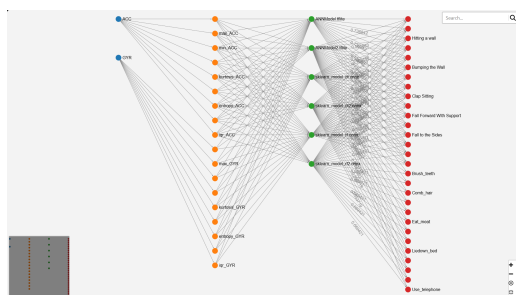
Os resultados visuais obtidos com a plataforma indicam que as escolhas de *design* definidas facilitam significativamente a interpretação dos dados do grafo de classificação. A organização do grafo em quatro colunas verticais, possibilita uma leitura linear e clara do fluxo de dados, percorrendo desde a coleta inicial pelos sensores até o processo final de inferência. Essa clareza é reforçada pela padronização cromática adotada, que permite a identificação imediata das entidades do grafo, eliminando a necessidade de consulta constante a legendas externas para a compreensão da arquitetura do sistema.

Além disso, a plataforma promove maior transparência no processo de decisão por meio de mecanismos de *feedback* interativo. A implementação do destaque visual ao realizar o *hover* (passar o cursor) sobre os nós relacionados, somada à exibição das probabilidades diretamente nas arestas entre a coluna dos modelos e estados finais, for-

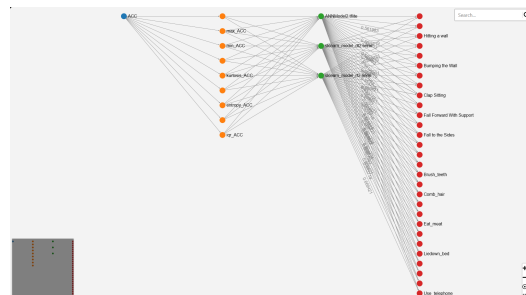
nece ao usuário um retorno imediato sobre o nível de confiança das classificações geradas, auxiliando diretamente na tomada de decisão baseada nos dados coletados.

Ademais, para lidar com o elevado volume de informações característico dos sistemas de IoHT, os resultados demonstraram a eficácia das ferramentas de apoio à navegação implementadas na plataforma. O mecanismo de busca rápida possibilitou a localização e a centralização imediata de nós específicos, o que otimizou significativamente o fluxo de trabalho ao reduzir o tempo necessário para a navegação manual. Complementarmente, a inclusão de um minimapa forneceu uma visão periférica constante da estrutura global do grafo, facilitando a orientação do usuário durante a exploração de detalhes em alta escala através do uso de *zoom* em regiões específicas da visualização.

A Figura 6 ilustra o grafo gerado a partir da leitura combinada de sensores de giroscópio e acelerômetro, apresentando uma estrutura densa e completa de interdependências. Em contraste, a Figura 7 exhibe um cenário do mesmo grafo otimizado, utilizando exclusivamente dados de acelerômetro.



**Figura 6. Visualização do grafo de classificação completo**



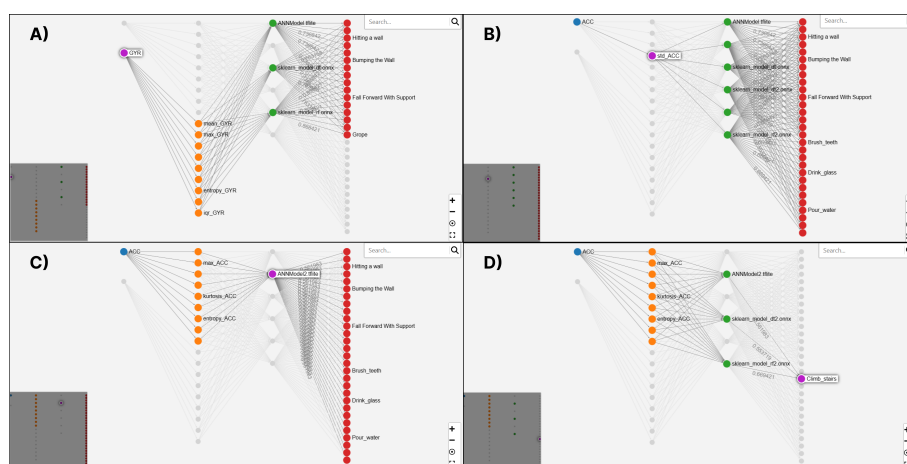
**Figura 7. Visualização do grafo de classificação otimizado**

A Figura 8 utiliza o cenário otimizado para exemplificar os mecanismos de *feedback* interativo da plataforma, especificamente a função de destaque (*hover*) ao interagir com os elementos do grafo. Na Parte (A), observa-se o destaque de um sensor, onde o sistema evidencia tanto o nó selecionado quanto todas as suas conexões adjacentes, facilitando o rastreamento do fluxo de dados. Em seguida, a Parte (B) ilustra a interação com uma *feature*, onde, neste cenário, o componente é realçado enquanto os demais nós sem relação direta são visualmente atenuados para reduzir o ruído visual. Já na Parte (C), é evidenciado um modelo e por fim, na Parte (D), demonstra-se a seleção de um nó na coluna de estado final, na qual, além do destaque do nó, são exibidas as probabilidades associadas àquele desfecho clínico nas arestas correspondentes.

Essa PoC demonstra que a plataforma cumpre com êxito o objetivo de proporcionar uma visualização facilitada, acessível e interativa do grafo de classificação. A capacidade de carregar e visualizar dinamicamente diferentes arquivos de grafos de classificação reafirma a P-GRFIT como uma ferramenta de suporte à decisão eficaz para desenvolvedores e pesquisadores na área de saúde digital e especialmente na área de IoHT.

### 5.3. Cenário de Uso

Aqui iremos explorar um cenário de uso da plataforma P-GRFIT em conjunto com a prova de conceito gerada, com o objetivo de demonstrar como a plataforma P-GRFIT



**Figura 8. Exemplificação da função *hover* (A. sensor destacado, B. *feature* destacada, C. modelo destacado, D. estado final destacado)**

pode ser usada para auxiliar o desenvolvimento de aplicações IoHT. Nesse cenário o objetivo é explorar como usar a P-GRAFIT para auxiliar o desenvolvimento de uma aplicação para celulares que identifica ocorrências de quedas.

A partir da visualização do grafo já é possível identificar quais sensores do celular podemos utilizar para inferir a ocorrência de queda. Também vemos que é possível identificar uma queda ou alguns tipos específicos de queda, como “queda para frente com e sem apoio” e “queda para trás com e sem apoio”. Além disso, é possível escolher fazer *download* de uma versão otimizada do grafo em XML ou JSON no dispositivo móvel para que a escolha do modelo de aprendizado de máquina a ser utilizado seja feita de maneira adaptada a algum cenário. Por exemplo, caso haja pouca energia na bateria, podemos utilizar apenas os modelos treinados que consideram só o acelerômetro. Essas informações podem ser utilizadas tanto para compor o documento de requisitos, quando para criação do projeto da arquitetura da aplicação.

O desenvolvedor pode treinar um novo modelo de aprendizado de máquina usando os algoritmos indicados no grafo ou usar um dos modelos já pré-treinados quando o grafo foi gerado. E caso não queira fazer o *download* do grafo, mas apenas de um modelo pré-treinado, é possível pela visualização da plataforma identificar o modelo que tem melhor acurácia na identificação dos movimentos de queda e gerar uma aplicação para uso deste modelo de aprendizado de máquina específico. A plataforma P-GRAFIT permite, nesse caso, que o desenvolvedor identifique previamente quais modelos se comportam melhor com conjuntos específicos de sensores e *features*. Com essas informações é possível implementar o mecanismo de inferência para identificar a situação de risco com base nos modelos pré-treinados, que podem ser disponibilizados em um servidor e apenas utilizados para inferência no dispositivo.

## 6. Considerações Finais

Este trabalho apresentou a P-GRAFIT, uma plataforma voltada à gestão, visualização e criação de grafos de classificação baseados no modelo proposto em [Junior et al. 2023]. A plataforma foi avaliada com base em uma prova de conceito e os resultados indicam que a solução fornece ferramentas capazes de auxiliar a visualização, de maneira rápida e in-

terativa, de todos os elementos do grafo de classificação, proporcionando maior facilidade aos desenvolvedores que desejam usar essa estrutura no desenvolvimento de aplicações IoHT.

Como trabalhos futuros, planeja-se incorporar uma API à plataforma adicionando as funcionalidade de automatização das etapas de pré-processamento e inclusão de novos *datasets*, para que seja possível facilitar também a geração dos grafos de classificação. Para aprimorar a experiência do usuário, planeja-se a implementação de recursos visuais de filtragem de grafos otimizados, baseados nos sensores disponíveis e na probabilidade de acerto de cada modelo. Por fim, devido a falta de validação por usuários reais, pretende-se aplicar a ferramenta com desenvolvedores em cenários reais de projetos de sistemas IoHT para verificar a eficácia da aplicação.

## Agradecimentos

Os autores agradecem à Pró-Reitoria de Assuntos Estudantis (PRAE) da Universidade Federal do Ceará (UFC) e à Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP) pelo auxílio financeiro e ajuda de custo concedidos para a realização desta pesquisa.

## Referências

- Abukwaik, H. and Rombach, D. (2017). Software interoperability analysis in practice: a survey. In *Proceedings of the 21st International Conference on Evaluation and Assessment in Software Engineering*, pages 12–20.
- Bahbouh, N. M., Compte, S. S., Valdes, J. V., and Sen, A. A. A. (2023). An empirical investigation into the altering health perspectives in the internet of health things. *International Journal of Information Technology*, 15(1):67–77.
- Bruno, B., Mastrogiovanni, F., Sgorbissa, A., Vernazza, T., and Zaccaria, R. (2013). Analysis of human behavior recognition algorithms based on acceleration data. In *2013 IEEE International Conference on Robotics and Automation*, pages 1602–1607. IEEE.
- de Oliveira, P. A. M., Andrade, R. M., Neto, P. d. A. S., Junior, E. C., Santos, I. S., Oliveira, V. T., Castro, W., and Carneiro, L. (2025). Healful dataset: Integrating wearable data with self-reported quality of life assessments. In *BIOSTEC (2): HEALTHINF*, pages 611–622.
- de Oliveira, P. A. M., Andrade, R. M., Neto, P. d. A. S., and Oliveira, B. S. (2022). Internet of health things for quality of life: Open challenges based on a systematic literature mapping. In *HEALTHINF*, pages 397–404.
- Egawa, R., Miah, A. S. M., Hirooka, K., Tomioka, Y., and Shin, J. (2023). Dynamic fall detection using graph-based spatial temporal convolution and attention network. *Electronics*, 12(15):3234.
- Fu, H., Rao, J., Deng, F., Wang, Y., Zhao, B., Liu, Z., Guan, H., Malinowski, P. H., and Xu, L. (2025). Aiot: Artificial intelligence and the internet of things for monitoring and prognosis of systems and structures. *IEEE Transactions on Instrumentation and Measurement*, 74:1–32.

- Gürdür, D. and Asplund, F. (2018). A systematic review to merge discourses: Interoperability, integration and cyber-physical systems. *Journal of Industrial information integration*, 9:14–23.
- Islam, M. M., Raju, S. T. U., Nooruddin, S., Karray, F., and Muhammad, G. (2025). Internet of health things: an introduction. In *Blockchain and Digital Twin for Smart Healthcare*, pages 19–44. Elsevier.
- Junior, E. C., da Silva Pinheiro, F. V., Oliveira, R. A., de Sousa Santos, I., and de Castro Andrade, R. M. (2024). Partner: Development platform for self-adaptive ioht In *ICAI Workshops*, pages 347–362.
- Junior, E. C., de Castro Andrade, R. M., and Rocha, L. S. (2023). Classification graph to the internet of health things applications. In *2023 IEEE 11th International Conference on Healthcare Informatics (ICHI)*, pages 118–127.
- Kandukuri, P., Abdul, A., Kumar, K. P., Sreenivas, V., Ramesh, G., and Gundu, V. (2025). Deep learning based ragae-svm for chronic kidney disease diagnosis on internet of health things platform. *Multimedia Tools and Applications*, 84(20):22853–22891.
- Lamichhane, K., Mannering, N., and Eberle, W. (2022). Discovering breach patterns on the internet of health things: A graph and machine learning anomaly analysis. In *Proceedings of the Thirty-Fifth International Florida Artificial Intelligence Research Society Conference (FLAIRS-35)*, pages 132–137.
- Linhares, I., Andrade, R., Costa Junior, E., Oliveira, P. A., Oliveira, B., and Aguilar, P. (2020). Lessons learned from the development of mobile applications for fall detection. In *GLOBAL HEALTH 2020, The Ninth International Conference on Global Health Challenges*, pages 18–25. ThinkMind.
- Mukherjee, A., Ghosh, S., Behere, A., Ghosh, S. K., and Buyya, R. (2021). Internet of health things (ioht) for personalized health care using integrated edge-fog-cloud network. *Journal of Ambient Intelligence and Humanized Computing*, 12:943–959.
- Natarajan, V. (2025). Computations and methods. In *Computational Artificial Intelligence and Methods for industries: A Machine-Generated Literature Overview*, pages 79–189. Springer.
- Oliveira, P. A. M., Andrade, R. M., Santos Neto, P. A., Santos, I. S., Junior, E. C., and Oliveira, V. T. (2025). Internet of health things and machine learning for continuous quality of life monitoring. *Health and Quality of Life Outcomes*, 23(1):92.
- Rajagopal, D. and Subramanian, P. K. T. (2025). Ai augmented edge and fog computing for internet of health things (ioht). *PeerJ Computer Science*, 11:e2431.
- Ravikumar, G., Giriprasad, S., and Gokul, S. (2026). Hybrid optimized dynamic graph convolutional recurrent imputation network for fog computing in health monitoring using internet of medical things. *Expert Systems with Applications*, 299:130072.
- Rubí, J. N. S. and Gondim, P. R. d. L. (2020). Interoperable internet of medical things platform for e-health applications. *International Journal of Distributed Sensor Networks*, 16(1):1550147719889591.
- Verganti, R., Dell’Era, C., and Swan, K. S. (2021). Design thinking: Critical analysis and future evolution. *Journal of Product Innovation Management*, 38(6):603–622.