

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Thiago Goldoni Thomé

**Um Estudo da Arquitetura Edge-Fog-Cloud com Foco na Otimização
Distribuída do Processamento e na Redução da Latência**

Juiz de Fora

2024

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Thomé, Thiago Goldoni.

Um Estudo da Arquitetura Edge-Fog-Cloud com Foco na Otimização Distribuída do Processamento e na Redução da Latência / Thiago Goldoni Thomé. – 2024.

57 f. : il.

Orientador: Mario Antonio Ribeiro Dantas

Coorientador: Victor Ströele de Andrade Menezes

Dissertação (Mestrado) – Universidade Federal de Juiz de Fora, Instituto de Ciências Exatas. Programa de Pós-Graduação em Ciência da Computação, 2024.

1. Arquitetura Edge-Fog-Cloud. 2. Otimização Distribuída. 3. Redução de Latência. 4. IoT. 5. IIoT. I. Dantas, Mario Antonio Ribeiro. II. Menezes, Victor Ströele de Andrade. III. Título.

Thiago Goldoni Thomé

Um Estudo da Arquitetura Edge-Fog-Cloud com Foco na Otimização
Distribuída do Processamento e na Redução da Latência

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Ciência da Computação. Área de concentração: Engenharia de Software e Banco de Dados

Orientador: Prof. Dr. Mario Antonio Ribeiro Dantas

Coorientador: Prof. Dr. Victor Ströele de Andrade Menezes

Juiz de Fora

2024

Thiago Goldoni Thomé

Um Estudo da Arquitetura Edge-Fog-Cloud com Foco na Otimização Distribuída do Processamento e Redução da Latência

Dissertação apresentada ao Programa de Pós-graduação em Ciência da Computação da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Ciência da Computação. Área de concentração: Ciência da Computação.

Aprovada em 25 de março de 2024.

BANCA EXAMINADORA

Prof. Dr. Mario Antonio Ribeiro Dantas - Orientador

Universidade Federal de Juiz de Fora

Prof. Dr. Victor Ströele de Andrade Menezes - Coorientador

Universidade Federal de Juiz de Fora

Prof. Dr. Edelberto Franco Silva

Universidade Federal de Juiz de Fora

Prof. Dr. Roberto Pinto Souto
Laboratório Nacional de Computação Científica

Juiz de Fora, 13/03/2024.



Documento assinado eletronicamente por **Mario Antonio Ribeiro Dantas, Professor(a)**, em 25/03/2024, às 13:09, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Victor Stroele de Andrade Menezes, Professor(a)**, em 25/03/2024, às 13:48, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Edelberto Franco Silva, Professor(a)**, em 25/03/2024, às 16:01, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Thiago Goldoni Thomé, Usuário Externo**, em 07/05/2024, às 16:57, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Roberto Pinto Souto, Usuário Externo**, em 24/05/2024, às 14:57, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **1748992** e o código CRC **18BEB644**.

Dedico este trabalho aos meus pais, Ana Lúcia e Robson, por todo encorajamento, amor e apoio. À minhas avós, Kleydes e Nilza, que sempre estão me encorajando e torcendo por mim. Aos meus avôs, Amilcar e Hernani que, mesmo não presentes, são grandes fontes de inspiração. À Lorena, por todo apoio incondicional que foi essencial para que eu chegasse até aqui.

AGRADECIMENTOS

Agradeço ao meu orientador, Professor Mario, pelas oportunidades, direcionamentos e ensinamentos. Ao meu co-orientador, Professor Victor, pela orientação, paciência e aprendizagem. Ao Professor Felipe Schneider Costa, do Instituto Federal de Santa Catarina, por permitir a execução dos testes no ambiente especializado do cluster Raspberry Pi, contribuindo significativamente para o sucesso desta pesquisa. Aos professores do Departamento de Ciência da Computação pelos seus ensinamentos e aos funcionários da universidade, que durante esses anos, contribuíram para o nosso enriquecimento pessoal e profissional.

“We can only see a short distance ahead, but we can see plenty there that needs to be done.” (Alan Turing).

RESUMO

Este estudo investiga a eficácia das arquiteturas Edge-Fog-Cloud em ambientes distribuídos, com foco na otimização do processamento de dados e na redução da latência em aplicações críticas, como cidades inteligentes, fábricas e hospitais. O objetivo principal é avaliar como diferentes configurações dessas arquiteturas influenciam a capacidade de resposta do sistema em situações que demandam processamento de dados em tempo real e decisões ágeis. Utilizando uma metodologia que envolve a simulação de ambientes com uma variação de 1 a 25 dispositivos Edge e mantendo constante o número de Fogs em três e uma única Cloud, este trabalho explora a dinâmica de processamento e comunicação de dados em grande escala. O método empregado compreende a análise de diferentes bases de dados, cada uma representando um tipo específico de carga de trabalho em termos de volume e complexidade dos dados, desde parâmetros simples de saúde até dados complexos de monitoramento industrial. Através da quantificação do tempo de resposta e do desempenho geral do sistema em várias configurações, foi possível identificar pontos críticos de saturação e eficiência nas camadas de Fog e Cloud. Os resultados demonstram que, enquanto a computação em Fog oferece melhorias significativas na latência e no processamento local de dados, sua capacidade é limitada pela quantidade de recursos computacionais disponíveis, levando à necessidade de escalabilidade e planejamento adequado dos nós Fog. As conclusões do estudo destacam a importância de uma infraestrutura Edge-Fog-Cloud bem dimensionada e adaptada às necessidades específicas de cada aplicação. Além disso, é reforçado que a possível independência da conexão com a internet oferecida pela computação em Fog pode ser decisiva em ambientes com conectividade limitada ou instável e que necessitem de respostas críticas para tomadas de decisão.

Palavras-chave: Arquitetura Edge-Fog-Cloud. Otimização Distribuída. Redução de Latência. IoT. IIoT.

ABSTRACT

This study investigates the effectiveness of Edge-Fog-Cloud architectures in distributed environments, focusing on optimizing data processing and reducing latency in critical applications such as smart cities, factories, and hospitals. The main objective is to assess how different configurations of these architectures influence the system's responsiveness in situations that require real-time data processing and agile decision-making. This work explores the dynamics of large-scale data processing and communication by using a methodology that involves simulating environments with a variation of 1 to 25 Edge devices and maintaining a constant number of three Fogs and a single Cloud. The employed method includes the analysis of different databases, each representing a specific type of workload in terms of data volume and complexity, from simple health parameters to complex industrial monitoring data. By quantifying response time and the system's overall performance in various configurations, it was possible to identify critical saturation points and efficiency in the Fog and Cloud layers. The results show that while Fog Computing offers significant improvements in latency and local data processing, its capacity is limited by the amount of available computational resources, leading to the need for scalability and proper planning of Fog. The study's conclusions highlight the importance of a well-dimensioned and adapted Edge-Fog-Cloud infrastructure to the specific needs of each application. Furthermore, it is emphasized that the potential independence from the internet connection offered by Fog Computing can be decisive in environments with limited or unstable connectivity and requiring critical decision-making responses.

Keywords: Edge-Fog-Cloud Architecture. Distributed Optimization. Latency Reduction. IoT. IIoT.

LISTA DE ILUSTRAÇÕES

Figura 1 - Dispositivos <i>IoT</i>	18
Figura 2 - Dispositivos <i>IIoT</i>	18
Figura 3 - Arquitetura <i>Edge-Fog-Cloud</i>	19
Figura 4 - Exemplo de estrutura da aplicação de HDF5	20
Figura 5 - Classificação de um ambiente <i>Edge-Fog-Cloud</i>	21
Figura 6 - Arquitetura <i>Edge-Fog-Cloud</i> considerada	22
Figura 7 - Abordagem considerada para <i>Edge-Fog-Cloud</i>	23
Figura 8 - Abordagem considerada para <i>Edge-Cloud</i>	24
Figura 9 - Arquitetura proposta para <i>Edge-Cloud</i>	32
Figura 10 - Trecho da base de dados ' <i>IIOT Data of Wind Turbine</i> '	33
Figura 11 - Trecho da base de dados ' <i>An Open Dataset for Human Activity Analysis</i> '	34
Figura 12 - Trecho da base de dados ' <i>Longitudinal indoor personal comfort preferences</i> '	35
Figura 13 - Trecho da base de dados ' <i>Pulse Time Series Under Different Conditions</i> '	35
Figura 14 - Ambiente <i>AWS Lambda</i>	36
Figura 15 - Cluster	37
Figura 16 - Disposição dos elementos do cluster	38
Figura 17 - Ambiente de teste <i>Edge-Fog-Cloud</i>	39
Figura 18 - Ambiente de teste <i>Edge-Cloud</i>	40
Figura 19 - Código em execução no nodo01, simulando um <i>Edge</i>	40
Figura 20 - Código em execução no nodo02, simulando uma <i>Fog</i>	41
Figura 21 - Tempo médio (s) da resposta da requisição em cada base pela quantidades de dispositivos <i>Edge</i> no ambiente <i>Fog</i>	46
Figura 22 - Tempo médio (s) da resposta da requisição em cada base pela quantidades de dispositivos <i>Edge</i> no ambiente <i>Cloud</i>	47
Figura 23 - Tempo médio (s) da resposta da requisição em cada base pela quantidades de dispositivos <i>Edge</i> no ambiente <i>Cloud</i>	48
Figura 24 - Quantidade de <i>outliers</i> por cada uma das configurações	49

LISTA DE TABELAS

Tabela 1 – Comparação das tecnologias utilizadas e propostas entre os trabalhos relacionados e o trabalho atual	31
Tabela 2 – Quantidade de parâmetros analisados de acordo com as bases de dados	42
Tabela 3 – Quantidade de requisições enviadas no período de 2 horas para cada base de dados e para as diferentes quantidades de dispositivos <i>Edge</i> momentâneos	43
Tabela 4 – Tempo médio da duração da requisição até a resposta no ambiente <i>Fog</i>	43
Tabela 5 – Desvio padrão da duração da requisição até a resposta no ambiente <i>Fog</i>	44
Tabela 6 – Tempo médio da duração da requisição até a resposta no ambiente <i>Cloud</i>	44
Tabela 7 – Desvio padrão da duração da requisição até a resposta no ambiente <i>Cloud</i>	45
Tabela 8 – Quantidade de <i>outliers</i> por configuração de ambiente	45
Tabela 9 – Diferença no tempo médio e porcentagem de aumento no ambiente <i>Fog</i>	49
Tabela 10 – Diferença no tempo médio e porcentagem de aumento no ambiente <i>Cloud</i>	50

LISTA DE ABREVIATURAS E SIGLAS

IoT	Internet das Coisas
IIoT	Internet Industrial das Coisas
HDF5	Formato de Dados Hierárquicos
AI	Inteligência Artificial
ML	Aprendizado de Máquina
QoE	Qualidade da Experiência
GDPR	Regulamento Geral sobre a Proteção de Dados
LGPD	Lei Geral de Proteção de Dados
CNN	Rede Neural Convolucional
mHealth	Saúde Móvel
LSTM	Memória de Curto Longo Prazo
AGV	Veículo Guiado Automaticamente
I/O	Entrada e Saída de Dados
AWS	Amazon Web Services

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OBJETIVOS	15
1.1.1	Objetivo geral	15
1.1.2	Objetivos específicos	15
1.2	ESTRUTURA DO TRABALHO	15
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	DESCRIÇÃO TECNOLÓGICA	17
2.1.1	<i>IoT e IIoT</i>	17
2.1.2	Arquitetura <i>Edge-Fog-Cloud</i>	18
2.1.3	HDF5	19
2.1.4	Processamento e armazenamento paralelo e distribuído	19
2.2	APLICAÇÃO DAS TECNOLOGIAS	21
2.3	RELEVÂNCIA PARA AMBIENTES APLICÁVEIS	24
2.4	CONSIDERAÇÕES	25
3	TRABALHOS RELACIONADOS	26
3.1	REVISÃO DA LITERATURA	26
3.1.1	Aplicações na saúde	26
3.1.2	Estratégias de otimização	27
3.1.3	Inovações em automação	28
3.1.4	Avanços em biomedicina	29
3.2	APLICAÇÕES E LACUNAS NAS PESQUISAS EXISTENTES	29
3.3	CONSIDERAÇÕES	30
4	AMBIENTE E RESULTADOS EXPERIMENTAIS	32
4.1	ARQUITETURA PROPOSTA	32
4.2	ESPECIFICAÇÕES DOS COMPONENTES NO AMBIENTE DE TESTE	32
4.2.1	Base de dados	33
4.2.2	<i>Cloud</i>	36
4.2.3	<i>Fog</i>	36
4.2.4	<i>Edge</i>	38
4.3	AMBIENTES DE TESTE	38
4.4	EXECUÇÃO	39
4.5	RESULTADOS	42
4.6	DISCUSSÃO	45
4.7	CONSIDERAÇÕES	50
5	CONCLUSÕES	51
5.1	CONTRIBUIÇÃO	51
5.2	DIRECIONAMENTOS FUTUROS	51

REFERÊNCIAS	53
APÊNDICE A – PUBLICAÇÕES	56

1 INTRODUÇÃO

A Internet das Coisas (*IoT*) refere-se à rede crescente de dispositivos físicos conectados à internet, capazes de coletar e compartilhar dados. Desde eletrodomésticos inteligentes até sistemas de monitoramento de saúde, a *IoT* está transformando a vida cotidiana, facilitando a automação residencial, melhorando a eficiência energética e promovendo cuidados de saúde personalizados. Por meio da *IoT*, dispositivos anteriormente isolados agora podem se comunicar e interagir por meio da internet, oferecendo conveniência e eficiência sem precedentes (1, 2).

Por outro lado, a Internet Industrial das Coisas (*IIoT*) leva essa conectividade para o ambiente industrial, integrando máquinas e dispositivos em sistemas de manufatura e produção. A *IIoT* está revolucionando setores como manufatura, logística e agricultura, possibilitando a automação de processos, monitoramento em tempo real de equipamentos e otimização da cadeia de suprimentos. Através da coleta e análise de dados em grande escala, a *IIoT* permite uma tomada de decisão mais informada, aumentando a eficiência operacional e reduzindo custos (1).

Essas tecnologias são essenciais para a transformação digital, redefinindo as interações entre pessoas, processos e dispositivos, e estabelecendo a base para um futuro mais conectado e automatizado. A transformação digital tem sido um fator crucial na redefinição de indústrias e negócios ao redor do mundo, marcando uma transição significativa da dependência de processos analógicos e mecânicos para soluções digitais avançadas. Essa evolução não apenas otimiza operações existentes, mas também desbloqueia novas oportunidades de inovação e eficiência (2).

No entanto, o processamento e análise desses dados em tempo real apresentam desafios significativos, especialmente em termos de latência e capacidade de processamento e armazenamento. É aqui que entram as arquiteturas de *Edge Computing* e *Fog Computing*, oferecendo soluções para o processamento de dados mais próximo à fonte, reduzindo a latência e distribuindo a carga de trabalho de maneira mais eficiente (3, 4).

Edge Computing, ou computação de borda, é uma tecnologia que coleta e processa dados perto da fonte de onde eles são gerados, como câmeras de segurança e sensores em máquinas industriais. Isso não só acelera a resposta aos dados coletados, permitindo ações quase instantâneas, como também reduz a necessidade de enviar grandes quantidades de dados para a *Cloud*, economizando largura de banda. Um exemplo prático é o uso em cidades inteligentes, onde o processamento de dados de tráfego em tempo real pode melhorar o fluxo veicular e a segurança pública (5, 6).

Já *Fog Computing*, ou computação de névoa, por sua vez, atua como uma extensão da *Edge Computing*, criando uma rede de nós intermediários que processam dados entre os dispositivos *Edge* e a *Cloud*. Isso permite um processamento mais eficiente e distribuído,

ideal para aplicações que exigem processamento de dados complexos ou análise em tempo real em grande escala. Um exemplo de sua aplicação é na agricultura, onde é possível gerenciar dados de diversos sensores espalhados por uma fazenda, podendo otimizar a irrigação e o uso de fertilizantes, aumentando a eficiência e a produção (3, 7).

Cloud Computing, também conhecida como computação em nuvem, é uma tecnologia que permite o acesso remoto a recursos de computação, como servidores, armazenamento e bancos de dados, por meio da internet. Com aplicações desde serviços de armazenamento até plataformas de computação em nuvem, possibilitando revolucionar a maneira como armazenamos dados e executamos aplicações, oferecendo escalabilidade, flexibilidade e eficiência para empresas e consumidores(8, 9, 10).

A tecnologia HDF5, com sua capacidade de armazenar e organizar grandes volumes de dados de maneira eficiente, apresenta-se como uma solução robusta para ambientes de computação distribuída, como os sistemas *Edge-Fog-Cloud*. Permitindo a integração de dados complexos de diversas fontes e formatos, o HDF5 facilita a gestão, análise e compartilhamento de informações em tempo real, essenciais para o monitoramento e controle de processos em diversos setores. Seu uso em tais arquiteturas potencializa a eficiência do processamento de dados, minimizando a latência e otimizando o armazenamento, o que é crucial para aplicações críticas que demandam respostas rápidas e decisões baseadas em dados confiáveis e abrangentes (11).

A combinação dessas tecnologias - *IoT*, *IIoT*, HDF5, *Edge*, *Fog* e *Cloud Computing* - cria um ecossistema robusto para a transformação digital, onde pode ser aproveitado a coleta de dados em tempo real e o processamento e armazenamento distribuído, sendo capaz de suportar uma ampla gama de aplicações em tempo real, desde veículos autônomos até monitoramento ambiental e sistemas de saúde inteligentes.

De forma complementar, a integração da Inteligência Artificial (*AI*) em ambientes *Edge-Fog-Cloud* pode ser vista como fundamental para enfrentar os crescentes desafios impostos pela expansão da Internet das Coisas. A capacidade de distribuir inteligência e computação - incluindo Aprendizado de Máquina (*ML*), análises de *big data* e tomada de decisão - ao longo desta arquitetura hierárquica e colaborativa, não apenas otimiza a solução para as restrições existentes, como a compensação entre latência e energia, mas também habilita uma gama mais ampla de aplicações *IoT* a operar de maneira eficiente e escalável. Esta flexibilidade é crucial para aplicações compostas por *IoT* e *AI*, pois permite uma resposta rápida a situações críticas e suporta computações complexas a distância, melhorando significativamente a utilização dos recursos e a Qualidade da Experiência (*QoE*) dos serviços (12).

1.1 OBJETIVOS

A integração dessas tecnologias abre caminho para inovações sem precedentes, permitindo que empresas e sociedades aproveitem o potencial total da digitalização. A capacidade de processar e analisar dados em tempo real, perto de onde são gerados, transforma completamente a maneira como decisões são tomadas e serviços são entregues, marcando o início de uma nova era na computação e na interação digital.

Nesse contexto, esse trabalho busca responder à seguinte questão de pesquisa: *De que maneira a implementação de uma arquitetura Edge-Fog-Cloud pode contribuir para a redução efetiva da latência e otimização do processamento de dados em ambientes de Internet das Coisas (IoT) e Internet Industrial das Coisas (IIoT), garantindo interoperabilidade e eficiência operacional?*

1.1.1 Objetivo geral

O objetivo geral deste estudo é explorar o potencial de redução de latência e otimização do processamento em sistemas *IoT* e *IIoT* por meio de uma arquitetura *Edge-Fog-Cloud* avançada. Busca-se desenvolver e implementar estratégias eficazes que minimizem o tempo de resposta e maximizem a eficiência do processamento de dados, sem comprometer a interoperabilidade e a flexibilidade das aplicações.

1.1.2 Objetivos específicos

Para atingir o objetivo geral, os seguintes objetivos específicos foram estabelecidos:

- Implementar uma abordagem que integre as tecnologias *Edge*, *Fog* e *Cloud*, visando a otimização do processamento de dados e a redução da latência nas comunicações.
- Avaliar o desempenho da arquitetura proposta em diferentes cenários de carga de trabalho e configurações de rede, comparando os tempos de resposta e eficiência de processamento com arquiteturas tradicionais *Edge-Cloud*.
- Examinar o impacto da arquitetura *Edge-Fog-Cloud* na interoperabilidade das aplicações, assegurando que a introdução de otimizações de processamento e redução de latência não interfira na capacidade de integração e comunicação entre diferentes sistemas e plataformas.

1.2 ESTRUTURA DO TRABALHO

Este trabalho está estruturado em cinco capítulos principais, visando proporcionar uma compreensão lógica da pesquisa realizada. O Capítulo 1, 'Introdução', estabelece o contexto, destacando as tecnologias abordadas, os desafios tecnológicos enfrentados e

os objetivos deste estudo. O Capítulo 2, ‘Fundamentação Teórica’, descreve os conceitos tecnológicos fundamentais e as metodologias adotadas. O Capítulo 3, ‘Trabalhos Relacionados’, compara este estudo com pesquisas semelhantes, identificando intersecções valiosas. O Capítulo 4, ‘Ambiente e Resultados Experimentais’, detalha os procedimentos experimentais e analisa os resultados obtidos. Finalmente, o Capítulo 5, ‘Conclusões’, conclui o trabalho, resumindo as descobertas e sugerindo direções futuras para pesquisa.

2 FUNDAMENTAÇÃO TEÓRICA

Este estudo incorpora uma abordagem conjunta de variados conceitos, utilizando diversas tecnologias e métodos para explorar as capacidades da arquitetura *Edge-Fog-Cloud*, visando otimizar o processamento e o armazenamento de dados em ambientes distribuídos, além de reduzir a latência de toda a aplicação. A integração cooperativa das camadas *Edge*, *Fog* e *Cloud* surge como uma solução compreensiva, destinada a superar os objetivos propostos no estudo. Este trabalho destaca a relevância de uma estratégia que adota otimização distribuída, visando aprimorar a eficiência de aplicações compostas por *IoT* e *IIoT*, enfatizando a importância de uma implementação composta por tecnologias e conceitos definidos através de estudos direcionados.

2.1 DESCRIÇÃO TECNOLÓGICA

Nesta seção, detalha-se as tecnologias e métodos essenciais adotados neste estudo, abrangendo desde a Internet das Coisas (*IoT*) e a Internet Industrial das Coisas (*IIoT*) até o emprego de *Fog Computing*, *Cloud Computing* e soluções de armazenamento como HDF5. Discute-se os conceitos de cada tecnologia e como as mesmas podem ser aplicadas dentro do ecossistema de pesquisa, elucidando como contribuem especificamente para o cumprimento dos objetivos estabelecidos.

2.1.1 *IoT* e *IIoT*

A Internet das Coisas (*IoT*), cuja história e criação do termo é descrita em (13), representa o início do fluxo de dados e é fundamental neste estudo, atuando como base para a coleta de dados em tempo real. Essa tecnologia engloba uma vasta gama de dispositivos, desde sensores ambientais até wearables para monitoramento da saúde, que capturam e transmitem dados continuamente. A capacidade de coletar informações de forma tão diversificada e em grande escala é crucial para alimentar os processos de análise e decisão em tempo real, possibilitando uma compreensão mais profunda e imediata do ambiente em que estão inseridos. A Figura 1 exemplifica alguns dos diversos dispositivos *IoT* atuais.

Por outro lado, a Internet Industrial das Coisas (*IIoT*) atua com a coleta de dados em um nível mais estratégico, focando em aplicações industriais onde a precisão e a confiabilidade são essenciais. Equipamentos como sensores em maquinários industriais e sistemas de controle automático representam os pilares da *IIoT*, fornecendo dados vitais para a otimização de processos, manutenção preditiva e eficiência operacional. Já para dispositivos *IIoT*, a Figura 2 exemplifica algumas de suas aplicações.

Figura 1 - Dispositivos *IoT*

Fonte: De autoria própria (2024)

Figura 2 - Dispositivos *IIoT*

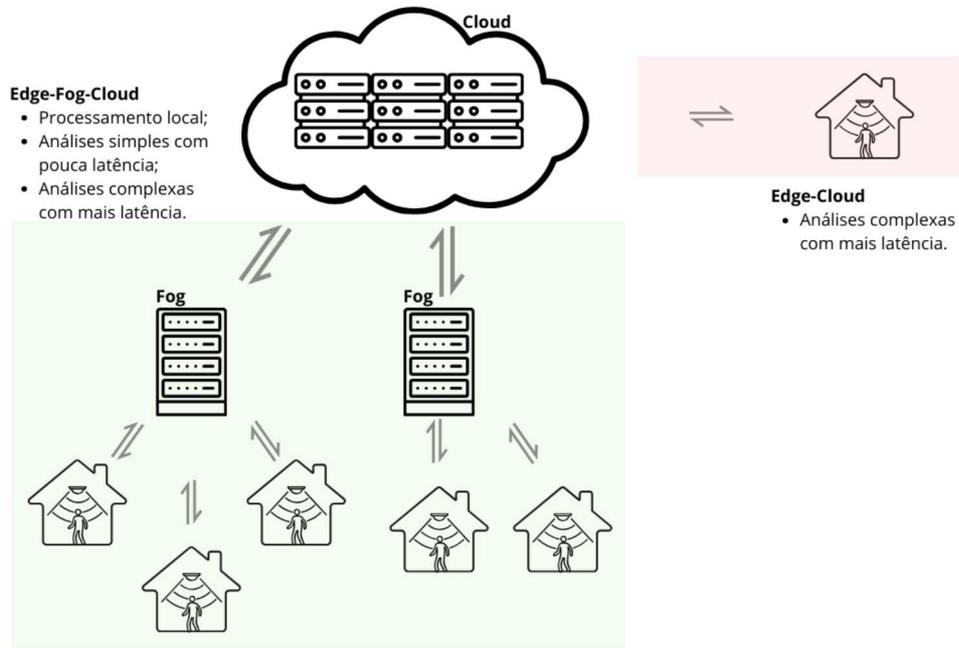
Fonte: De autoria própria (2024)

2.1.2 Arquitetura *Edge-Fog-Cloud*

A arquitetura *Edge-Fog-Cloud* destaca-se pela sua capacidade de reduzir a latência e manter a funcionalidade mesmo na ausência de conexão com a internet, diferenciando-se significativamente da abordagem tradicional *Edge-Cloud*. Enquanto a *Edge-Cloud* permite o processamento de dados na borda, reduzindo a necessidade de envio constante para a nuvem, a inclusão da camada de *Fog* amplia essa capacidade, processando dados mais perto da fonte e permitindo respostas rápidas mesmo sem conexão. Além disso, a estrutura

Edge-Fog-Cloud mantém a flexibilidade de acessar a *Cloud* para análises mais complexas, proporcionando um equilíbrio ideal entre processamento local eficiente e capacidades analíticas avançadas na nuvem. Tais características podem ser percebidas na Figura 3.

Figura 3 - Arquitetura *Edge-Fog-Cloud*



Fonte: De autoria própria (2024)

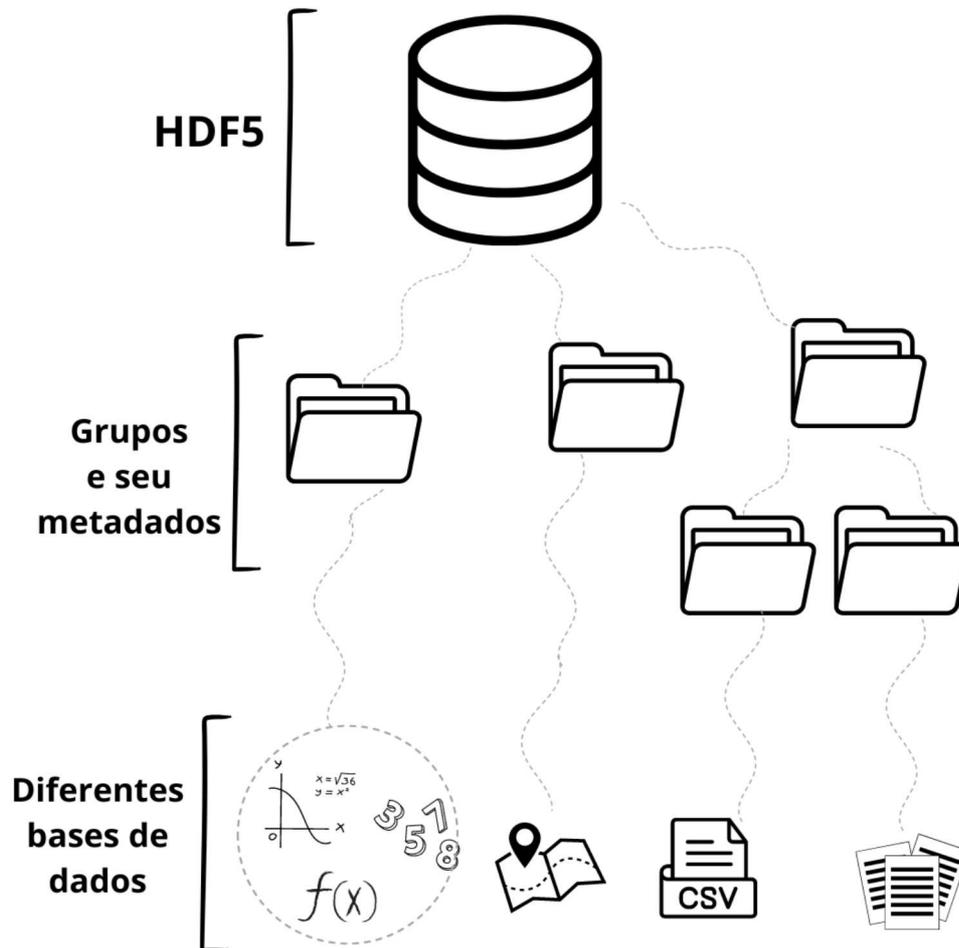
2.1.3 HDF5

De forma complementar, a tecnologia HDF5 é utilizada para o gerenciamento dos dados coletados e processados. O HDF5 permite o armazenamento de grandes volumes de dados multidimensionais de maneira estruturada e acessível, facilitando tanto a análise instantânea quanto a posterior dos dados. Esse formato é particularmente benéfico em nossa arquitetura distribuída, pois suporta a manipulação eficaz de dados complexos e volumosos em todas as camadas de processamento, desde a *Fog* até a *Cloud*. Sua estrutura e modelo de funcionamento é visto na Figura 4.

2.1.4 Processamento e armazenamento paralelo e distribuído

A relevância do processamento paralelo e do armazenamento paralelo em ambientes de computação distribuída tem se tornado cada vez mais evidente com o crescimento exponencial no volume de dados gerados por dispositivos conectados globalmente. Essas tecnologias são fundamentais para lidar com a complexidade e as demandas de processamento de dados em grande escala, permitindo que sistemas distribuídos realizem cálculos complexos de maneira mais eficiente e rápida(18).

Figura 4 - Exemplo de estrutura da aplicação de HDF5



Fonte: De autoria própria (2024)

O processamento paralelo permite que tarefas computacionais sejam divididas em partes menores e executadas simultaneamente em múltiplos processadores ou núcleos de processamento. Isso não só acelera significativamente o tempo de processamento, mas também possibilita a análise em tempo real de grandes conjuntos de dados, um requisito essencial para muitas aplicações críticas na atualidade, como monitoramento ambiental, sistemas de recomendação e análise financeira(8).

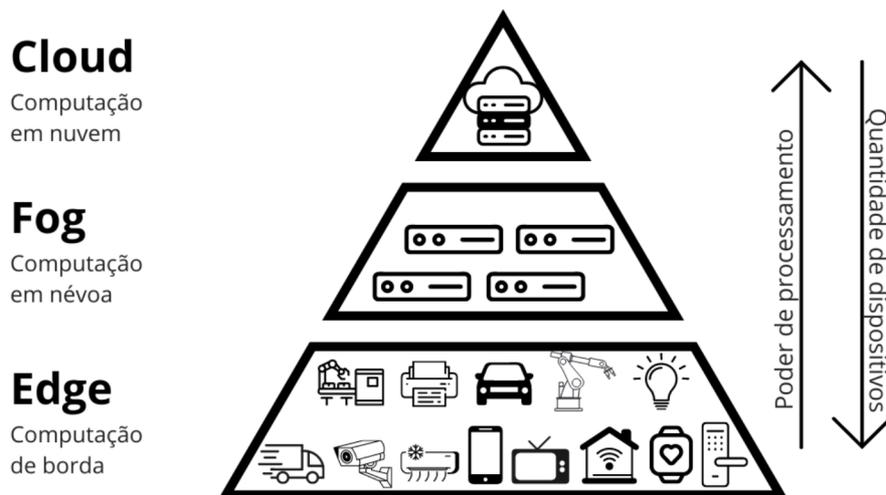
O armazenamento paralelo complementa o processamento paralelo ao oferecer soluções para o armazenamento eficiente de grandes volumes de dados, facilitando o acesso rápido e simultâneo a esses dados por múltiplos processadores. Essa abordagem é vital para ambientes de computação distribuída, onde a velocidade de acesso e a integridade dos dados são críticas para o desempenho do sistema(8).

O processamento paralelo e distribuído representam duas abordagens distintas no manuseio de tarefas computacionais. No processamento paralelo, múltiplas operações

são executadas simultaneamente dentro do mesmo nó, permitindo, por exemplo, que um servidor receba requisições e acesse o disco para operações de armazenamento ao mesmo tempo. Por outro lado, o processamento distribuído, distribui as tarefas por vários nós em uma rede, otimizando o desempenho ao permitir que diferentes máquinas colaborem na execução de uma tarefa comum. Essa abordagem é fundamental para a arquitetura *Edge-Fog-Cloud*, maximizando a eficiência e reduzindo a latência ao processar e armazenar dados mais próximos à fonte.

Como pode ser visto na Figura 5, mesmo com unidades de *Fog* de menor capacidade computacional, a multiplicidade de nós e a proximidade com as fontes de dados reduzem a latência e os custos, otimizando o processamento de dados em grande escala ao distribuir cargas de trabalho de maneira eficiente entre *Edge*, *Fog* e *Cloud*.

Figura 5 - Classificação de um ambiente *Edge-Fog-Cloud*



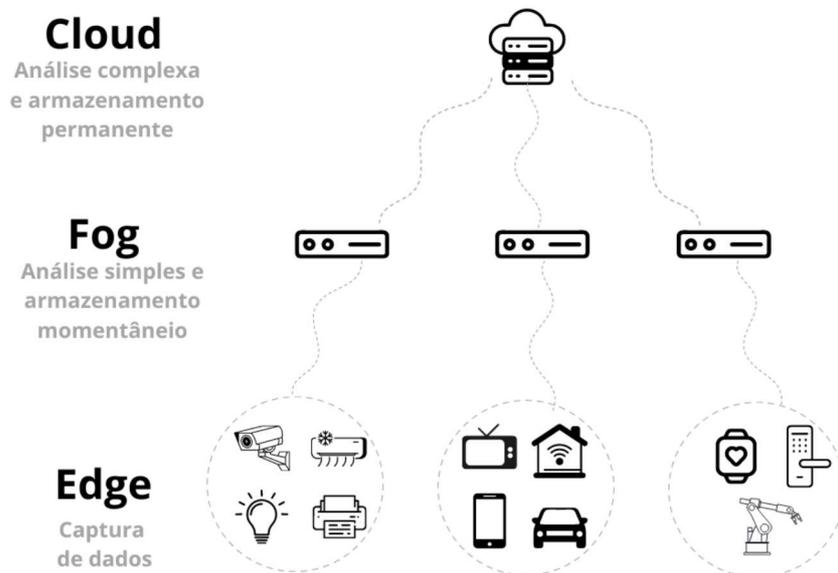
Fonte: De autoria própria (2024)

2.2 APLICAÇÃO DAS TECNOLOGIAS

Neste estudo, é empregado uma série de tecnologias para otimizar o processamento e o armazenamento de dados em ambientes distribuídos, com intuito de diminuir a latência do sistema. A Internet das Coisas (*IoT*) e a Internet Industrial das Coisas (*IIoT*) são fundamentais para a pesquisa, servindo como a base para a coleta de dados em tempo real. Dispositivos *IoT*, variando de sensores ambientais a dispositivos wearable de monitoramento de saúde, e dispositivos *IIoT*, como sensores em maquinários industriais, são os responsáveis por fornecerem um fluxo contínuo de dados.

Como pode ser visto na Figura 6, a arquitetura de *Edge-Fog-Cloud* é central para o estudo, permitindo uma análise ao distribuir o processamento e armazenamento através de diferentes camadas. No nível de *Edge*, os dispositivos *IoT* e *IIoT* realizam a captura inicial dos dados, sendo responsáveis pela transmissão de dados para a *Fog*. A camada de *Fog Computing* atua como um intermediário, oferecendo capacidade de processamento e armazenamento temporário, o que é especialmente útil para operações que requerem resposta rápida e análise de dados em tempo real. A *Cloud Computing*, por sua vez, é utilizada para tarefas de processamento mais intensivas e armazenamento de longo prazo, aproveitando sua escalabilidade e poder computacional.

Figura 6 - Arquitetura *Edge-Fog-Cloud* considerada



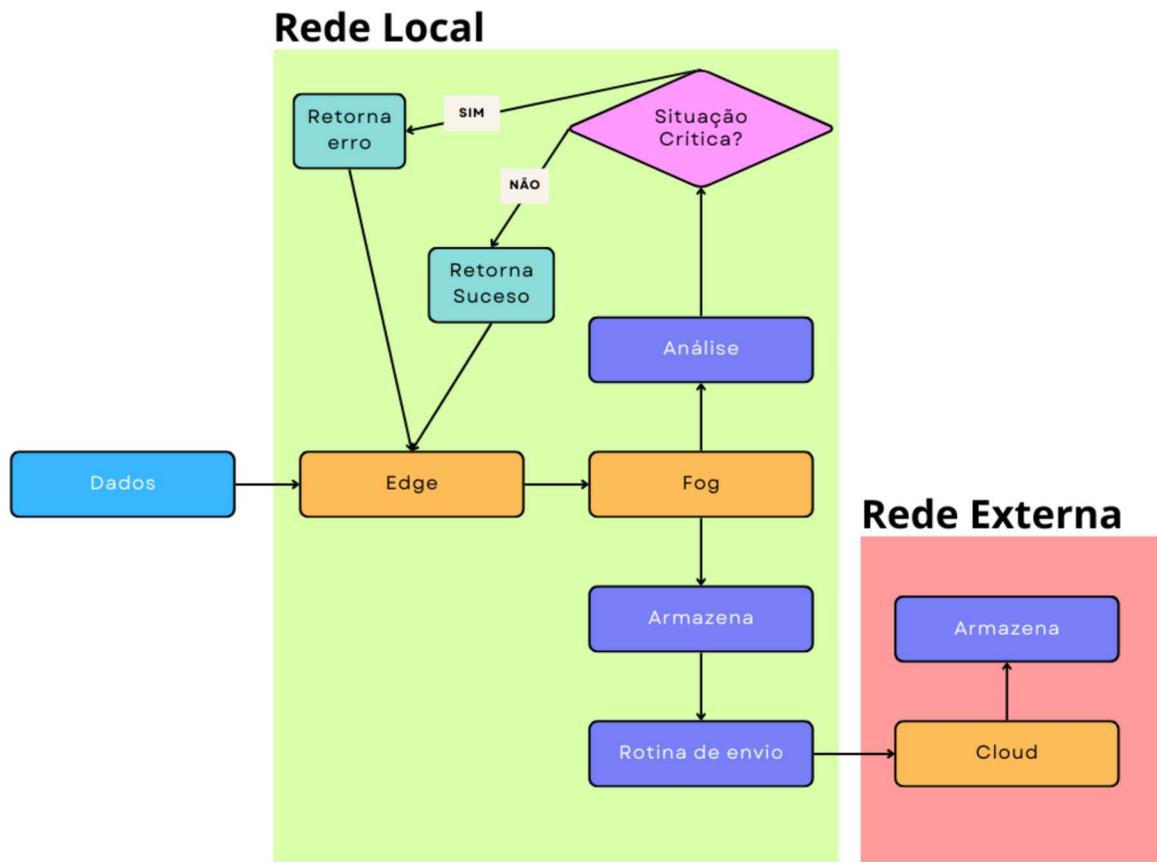
Fonte: De autoria própria (2024)

Para a construção da estrutura do HDF5, foram utilizados entendimentos e conclusões presentes em (19). Esse trabalho sobre a gestão de dados em formato HDF5 teve como destaque a eficiência, a velocidade de consultas e as operações de entrada/saída (*I/O*). Este trabalho introduziu uma ferramenta de gestão de dados leve, capaz de realizar subdefinição e agregação de dados do lado do servidor em conjuntos de dados científicos armazenados em HDF5.

A combinação dessas tecnologias no estudo não apenas aborda os desafios associados ao processamento e armazenamento de grandes conjuntos de dados em tempo real, mas também maximiza a eficiência operacional e minimiza a latência em aplicações críticas. Ao explorar a interação entre *IoT*, *IIoT*, *Edge Computing*, *Fog Computing* e *Cloud Computing*, juntamente com o uso estratégico do HDF5, nosso projeto apresenta uma solução robusta

e escalável de computação distribuída.

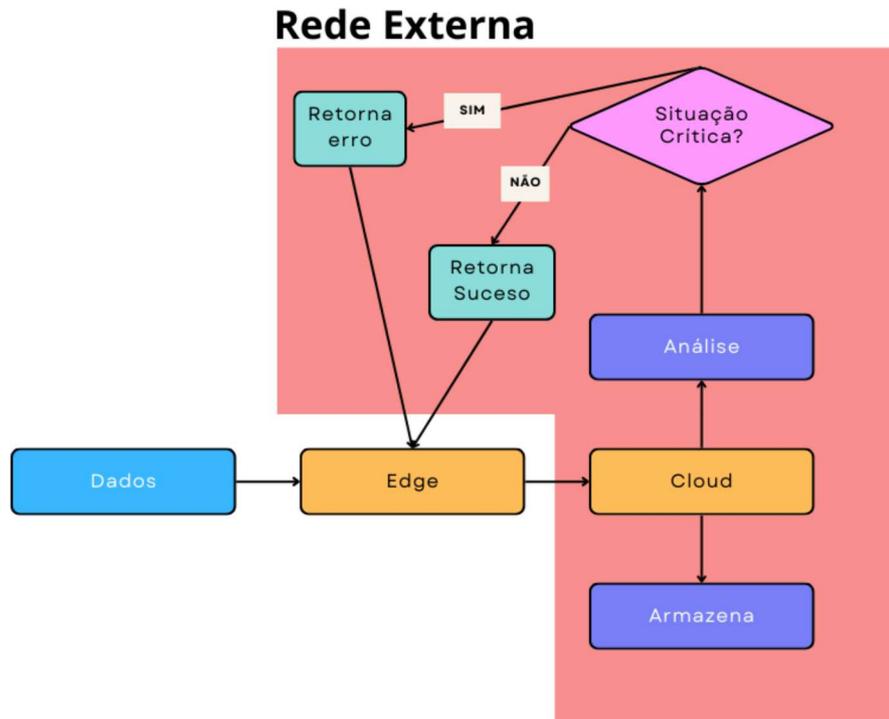
Figura 7 - Abordagem considerada para *Edge-Fog-Cloud*



Fonte: De autoria própria (2024)

Em uma comparação entre a Figura 7 e a Figura 8, ficam evidentes duas abordagens distintas para o processamento de dados em ambientes *IoT*. Na Figura 7, observa-se o fluxo numa configuração *Edge-Fog-Cloud*, onde os dados são analisados e armazenados localmente na camada de *Fog*, resultando em respostas mais rápidas para dispositivos *Edge* devido à proximidade de processamento. Em contraste, a Figura 8 demonstra a comunicação direta entre *Edge* e *Cloud*, implicando a necessidade de acesso à rede externa, o que pode introduzir latência adicional e imprevisibilidades devido à dependência de conexões de internet. Essa diferença fundamental aparenta destacar vantagens da arquitetura *Edge-Fog-Cloud* em termos de eficiência e confiabilidade para aplicações críticas que demandam respostas rápidas e confiáveis.

Figura 8 - Abordagem considerada para *Edge-Cloud*



Fonte: De autoria própria (2024)

2.3 RELEVÂNCIA PARA AMBIENTES APLICÁVEIS

A pesquisa proposta tem potencial de aplicação em uma gama diversificada de ambientes, cada um com suas demandas e desafios únicos. Em fábricas, por exemplo, a integração de tecnologias de *Edge-Fog-Cloud* pode otimizar processos de manufatura através do monitoramento em tempo real e da manutenção preditiva, reduzindo paradas não planejadas e aumentando a eficiência produtiva.

Nos hospitais, a aplicação dessas tecnologias pode revolucionar o monitoramento de pacientes, permitindo o acompanhamento contínuo de sinais vitais e a identificação precoce de condições adversas, contribuindo assim para a melhoria dos cuidados de saúde e a redução de custos operacionais.

Cidades inteligentes também se beneficiam significativamente, com a possibilidade de gerir de forma mais eficiente serviços urbanos como iluminação pública, tráfego e sistemas de segurança, melhorando a qualidade de vida dos cidadãos e promovendo a

sustentabilidade.

Na agricultura, o uso dessas tecnologias pode levar à agricultura de precisão, onde o monitoramento e análise de dados em tempo real podem auxiliar na otimização do uso de recursos, como água e fertilizantes, aumentando a produtividade e minimizando o impacto ambiental.

Esses exemplos ilustram apenas uma fração do potencial de aplicação das tecnologias abordadas neste estudo, sublinhando sua relevância e a importância prática do trabalho proposto.

2.4 CONSIDERAÇÕES

Este estudo destaca a seleção criteriosa das bases de dados, fundamentais para simular ambientes reais. A escolha das bases de dados foi estratégica, visando representar uma ampla gama de cenários aplicáveis a *IoT* e *IIoT*, desde monitoramento de informações de saúde de pessoas até o controle de processos industriais. Essa diversidade é crucial para testar a versatilidade e a eficácia da proposta em condições variadas, assegurando a relevância e a aplicabilidade dos resultados no mundo real.

Este estudo emprega uma série de tecnologias avançadas para otimizar o processamento e o armazenamento de dados em ambientes distribuídos. Ao adotar estratégias de otimização distribuída, busca-se minimizar a latência, essencial para a eficácia de sistemas baseados em arquiteturas *Edge-Fog-Cloud*. Este capítulo detalha as tecnologias utilizadas, incluindo *IoT*, *IIoT*, *Fog Computing*, *Cloud Computing* e métodos de armazenamento eficientes como HDF5, descrevendo como cada uma contribui para a realização dos objetivos de pesquisa propostos.

3 TRABALHOS RELACIONADOS

A revisão da literatura enfocou a inclusão de estudos que exemplificassem a implementação e os benefícios das tecnologias *Edge-Fog-Cloud* em variados contextos, desde aplicações na saúde até avanços na indústria, refletindo a interdisciplinaridade do conceito de sua arquitetura. A seleção de trabalhos visa ilustrar a ampla aplicabilidade dessas tecnologias, destacando soluções inovadoras e os desafios enfrentados. Nesse contexto, a próxima seção aborda uma análise detalhada dos trabalhos relacionados, enfatizando tanto suas realizações quanto as lacunas que o presente estudo visa preencher, realçando o contraste e a complementaridade entre as abordagens anteriores e a proposta atual no campo das tecnologias *IoT* e *IIoT*.

3.1 REVISÃO DA LITERATURA

3.1.1 Aplicações na saúde

No trabalho '*Machine Learning on Mobile: An On-device Inference App for Skin Cancer Detection*'(20), é proposto um aplicativo móvel para a detecção de câncer de pele, que se destaca pela aplicação de técnicas de aprendizado de máquina diretamente no dispositivo, evitando assim a necessidade de comunicação constante com serviços de *Cloud* para análise de dados. Utilizando um modelo avançado de Rede Neural Convolutiva (CNN) previamente treinado, o aplicativo é capaz de realizar inferências locais. Esta metodologia apresenta benefícios significativos, incluindo a diminuição da latência na entrega de resultados, a redução do consumo de largura de banda e o fortalecimento da privacidade dos usuários, sendo uma importante aplicação na área de saúde móvel (mHealth). De maneira geral, o trabalho evidencia a eficácia e aplicabilidade deste método, sugerindo um caminho promissor para aprimorar a prevenção e diagnóstico de enfermidades por meio do uso de dispositivos móveis.

Na construção do aplicativo, adotou-se a tecnologia HDF5 para o armazenamento do modelo de aprendizado de máquina, escolhida pela capacidade de gerenciar grandes volumes de dados de maneira eficiente. O emprego de Redes Neurais Convolutivas foi crucial para a precisão na classificação de imagens médicas, possibilitando a detecção acurada de variados tipos de lesões cutâneas. Embora a capacidade computacional e de armazenamento da *Cloud Computing* tenha sido explorada na fase de treinamento dos modelos, o foco do trabalho recai sobre a inferência realizada no dispositivo, visando superar desafios relacionados à latência, privacidade e custos inerentes ao processamento em *Cloud*.

Enquanto o trabalho apresentado se concentra em dispositivos móveis com capacidade suficiente para executar modelos de aprendizado de máquina complexos, como CNN, este estudo lida com dispositivos *IoT* de capacidade mais limitada em termos de

processamento e armazenamento. Isso nos leva a adotar a arquitetura *Fog Computing*, que atua como uma camada intermediária poderosa, capaz de realizar processamentos significativos e gerenciamento de dados que os dispositivos *Edge* mais simples não podem. Dessa forma, os dispositivos *IoT* deste estudo podem se concentrar na coleta eficiente de dados, enquanto a computação pesada é deslocada para a *Fog*, que é projetada para ser substancialmente mais potente do que as unidades *Edge* individuais. Essa estrutura permite uma maior rede de dispositivos *Edge* de baixo custo e baixa potência, cada um comunicando-se com nós *Fog* robustas, otimizando o processamento distribuído e o armazenamento em variadas aplicações. Adicionalmente, considerando que a tecnologia HDF5 já demonstra excelente desempenho em dispositivos *Edge* para o gerenciamento eficaz de dados, sua aplicação em ambientes de *Fog Computing* promete ser ainda mais poderosa. Isso possibilita um gerenciamento de dados avançado e análises complexas em tempo real, aproveitando a maior capacidade de processamento e armazenamento nos nós *Fog*.

3.1.2 Estratégias de otimização

Já o trabalho '*Traffic-based reinforcement learning with neural network algorithm in Fog Computing environment*' (21) explora a otimização do tráfego em sistemas de *Fog Computing* através da aplicação de um algoritmo de aprendizado por reforço, especificamente utilizando Redes Neurais de Longo Curto Prazo (LSTM). O foco principal é a otimização dinâmica da alocação de contêineres na *Cloud* para servidores *Fog*, com o objetivo de maximizar as recompensas por meio da eficiente gestão do tráfego de rede. Utilizando dados de tráfego coletados tanto de servidores *Fog* quanto de dispositivos *IoT*, o algoritmo prevê padrões de tráfego e ajusta a distribuição de recursos para estabilizar a rede, minimizando o consumo adicional de tráfego. Este método demonstrou ser eficaz na manutenção da estabilidade do tráfego e na promoção da eficiência em ambientes de *Fog Computing*.

Na implementação técnica deste sistema, a tecnologia HDF5 desempenha um papel crucial ao armazenar os pesos dos modelos de rede neural treinados, otimizando a reutilização e atualização dos modelos de forma eficiente. A infraestrutura de *Cloud Computing* fornece a base necessária para o treinamento inicial dos modelos e a implantação dos contêineres, enquanto os dispositivos *IoT* contribuem com dados de tráfego, fundamentais para o processo de aprendizado e otimização do algoritmo. A combinação entre HDF5, *Cloud Computing* e *IoT* evidencia uma estratégia integrada para a otimização de tráfego em ambientes de *Fog Computing*, enfatizando a importância da coleta e análise de dados em tempo real para a melhoria contínua do sistema.

Embora o foco central deste trabalho e do estudo em questão sejam diferentes quanto em relação no uso de nós *Fog*, a utilização conjunta das tecnologias HDF5 e algoritmos de

aprendizado apresenta pontos de interseção interessantes. A implementação da tecnologia HDF5 para o armazenamento eficiente dos modelos de aprendizado de máquina, juntamente com a aplicação de algoritmos de aprendizado por reforço, pode ser aplicável a este trabalho. Mesmo que a utilização direta de *Fog Computing* não seja idêntica, a estratégia de combinar HDF5 com aprendizado por reforço pode ser perfeitamente integrada à solução atual, proporcionando uma forma de otimizar o processamento e a análise de dados em tempo real nos nós de *Fog*. Com isso, ao adotar essas técnicas ao contexto deste trabalho, é possível aumentar a eficiência e a inteligência de nossas arquiteturas de processamento e armazenamento distribuídas.

3.1.3 Inovações em automação

O trabalho intitulado '*Processing LiDAR Data from a Virtual Logistics Space*' (22) aborda a criação de um sistema híbrido para o processamento de dados *LiDAR*, com foco na otimização da coordenação de Veículos Guiados Automaticamente (*AGVs*) dentro de um cenário de armazém virtual. Por meio da utilização de um simulador para a geração de fluxos de dados virtuais de sensores *LiDAR* e um cluster real para o processamento desses dados, a pesquisa investiga a aplicabilidade dessa abordagem híbrida em melhorar a eficiência da movimentação dos *AGVs*. Os resultados experimentais obtidos validam a eficácia do sistema proposto, demonstrando sua capacidade de fornecer uma visão compartilhada e atualizada em tempo real do ambiente logístico.

Do ponto de vista técnico, o trabalho faz uso da tecnologia HDF5 para o armazenamento dos fluxos de dados *LiDAR* simulados, simulando o funcionamento de dispositivos *IoT* em um ambiente controlado. Essa escolha permite a análise detalhada e a replicação dos dados para testes subsequentes. Além disso, emprega-se uma arquitetura de computação em *Fog* para o processamento desses dados de maneira eficiente e próxima à fonte, representando latências e maximizando a eficácia operacional do sistema. Os *AGVs*, equipados com sensores *LiDAR* e atuando como dispositivos *IoT*, são responsáveis pela geração de dados críticos para a dinâmica do sistema, exemplificando uma aplicação prática de logística inteligente que beneficia da computação distribuída para aprimorar a coordenação e movimentação veicular.

Embora o trabalho e este estudo compartilhem o uso de tecnologias avançadas como HDF5 e computação em *Fog*, suas aplicações se divergem em alguns aspectos. Enquanto a pesquisa citada explora o processamento de dados *LiDAR* para otimização logística em ambientes virtuais, este estudo abrange uma análise mais ampla das arquiteturas *Edge-Fog-Cloud* e *Edge-Cloud* em diversas aplicações, incluindo mas não limitado a, o contexto logístico. A abordagem da utilização de um ambiente simulado para testar e aperfeiçoar a coordenação de *AGVs* oferece compreensões valiosas sobre como técnicas de simulação e processamento de dados próximos à fonte podem ser aplicadas neste estudo

para melhorar a eficiência e precisão em ambientes de computação distribuída.

3.1.4 Avanços em biomedicina

Em '*Low-power portable devices for metagenomics analysis: Fog computing makes bioinformatics ready for the Internet of Things*' (23), o trabalho explora a aplicação de dispositivos portáteis para o sequenciamento genômico para a detecção precisa de bactérias em variados contextos ambientais. O desafio técnico envolve o manejo eficiente de volumosos conjuntos de dados gerados durante o sequenciamento. É proposto a utilização da computação em *Fog*, empregando arquiteturas de baixo consumo energético para processar dados brutos diretamente no local. Isso inclui etapas computacionais locais, com a subsequente transmissão de apenas resultados considerados relevantes através da internet. A adoção de serviços em servidores *Cloud* para a agregação e análise desses resultados permite a ativação de notificações e alarmes em um ecossistema integrado à Internet das Coisas (*IoT*), abrindo portas para futuras aplicações avançadas.

No fluxo proposto do trabalho, o armazenamento e gerenciamento dos dados de sequenciamento são realizados no formato FAST5, uma extensão do HDF5, o que facilita a manipulação de grandes volumes de informação. A infraestrutura de *Fog Computing* viabiliza o tratamento local dos dados, minimizando a necessidade de enviar grandes quantidades de informação para a *Cloud* e, por consequência, elevando o nível de segurança dos dados. A cooperação entre a computação em *Fog* e a *Cloud*, juntamente com a integração de dispositivos *IoT* e o emprego de técnicas de aprendizado de máquina, otimiza a identificação rápida de agentes patogênicos e a monitoração ambiental.

Comparando o trabalho com este estudo, a principal diferença reside na especificidade da aplicação e nas tecnologias empregadas. Enquanto o trabalho citado foca na detecção de bactérias utilizando sequenciamento genômico portátil e processamento de dados via *Fog Computing*, este estudo explora uma abordagem mais ampla que envolve a otimização do armazenamento e processamento de dados em múltiplas aplicações, utilizando arquiteturas *Edge-Fog-Cloud*. Entretanto, a utilização do formato FAST5 como uma extensão do HDF5 para o manejo de dados em ambos os estudos destaca uma convergência tecnológica. A abordagem inovadora do trabalho relacionado em processar dados de sequenciamento de forma localizada pode inspirar a aplicação de técnicas semelhantes neste estudo, especialmente no que tange a eficiência no processamento local de dados e a integração com a *IoT* para aprimorar a coleta e análise de dados em ambientes distribuídos, potencializando assim as capacidades das soluções propostas.

3.2 APLICAÇÕES E LACUNAS NAS PESQUISAS EXISTENTES

Os trabalhos relacionados ilustram a aplicabilidade e o impacto das tecnologias de *Fog Computing*, *Cloud Computing*, *IoT* e aprendizado de máquina em uma variedade de

ambientes. Essa análise não somente contextualiza estudo atual no âmbito mais amplo da tecnologia e inovação, mas também sublinha onde a contribuição atual pode se destacar.

No trabalho (20), apesar da aplicação de aprendizado de máquina em dispositivos móveis para detecção de câncer de pele, uma exploração das arquiteturas distribuídas poderia potencializar ainda mais a eficiência e a escalabilidade dessas soluções de saúde móvel. O estudo atual visa preencher essa lacuna, integrando *Fog Computing* para aprimorar a capacidade de processamento e a segurança dos dados em uma ampla gama de aplicações de saúde.

O trabalho (21), concentrado na otimização do tráfego em ambientes de *Fog Computing*, limita-se ao gerenciamento de tráfego, sem abordar como essas estratégias podem ser aplicadas ou adaptadas para otimizar outras operações críticas em sistemas industriais e logísticos. O estudo atual expande essa visão, explorando como algoritmos avançados e *Fog Computing* podem ser utilizados para melhorar a coordenação e a eficiência em diversos cenários operacionais.

Em (22), o trabalho ilustra a aplicação de processamento de dados LiDAR em logística, mas não abrange a integração de diferentes tecnologias de computação distribuída que poderiam otimizar ainda mais esses ambientes. O estudo atual propõe combinar *Edge*, *Fog* e *Cloud Computing*, proporcionando uma solução mais abrangente e que pode ser adaptada para melhorar a eficiência em uma variedade de contextos industriais e comerciais.

Por fim, o trabalho (23) discute o uso de sequenciamento genômico para identificação rápida de patógenos, nota-se uma concentração na análise de dados biomédicos sem considerar a aplicabilidade dessa abordagem em outras áreas que também se beneficiariam de processamento de dados local e em tempo real. Nosso estudo busca abranger essa aplicabilidade, demonstrando o potencial de *Fog Computing* além do contexto biomédico, em áreas como monitoramento ambiental e industrial.

Assim, enquanto cada um desses trabalhos contribui significativamente para seu campo, nosso estudo propõe uma abordagem mais integrada e versátil, explorando a sinergia entre diferentes tecnologias de computação distribuída para enfrentar desafios em uma gama mais ampla de aplicações, como pode ser visto na Tabela 1.

3.3 CONSIDERAÇÕES

Os estudos analisados fornecem uma base sólida para entender o estado atual da tecnologia em ambientes *Edge-Fog-Cloud* e suas diversas aplicações práticas. É evidente que a integração de técnicas avançadas, como aprendizado de máquina em dispositivos móveis e otimização de tráfego em *Fog Computing*, oferece soluções inovadoras para desafios como latência e gerenciamento de dados. No entanto, ao se observar a Tabela 1, notou-se uma lacuna na aplicação destas tecnologias num contexto ampliado que abrange

Tabela 1 – Comparação das tecnologias utilizadas e propostas entre os trabalhos relacionados e o trabalho atual

Trabalho Relacionado	Área	Tecnologias Utilizadas					Aprendizado de máquina
		Edge	Fog	Cloud	HDF5		
Machine Learning on Mobile: An On-device Inference App for Skin Cancer Detection	mHealth	X	-	X	X		Rede Neural Convolutacional
Traffic-based reinforcement learning with neural network algorithm in fog computing environment	Otimização de ambientes fog	X	X	-	X		Redes Neurais de Longo Curto Prazo
Processing LiDAR Data from a Virtual Logistics Space	Veículos Autônomos	X	X	-	X		-
Low-power portable devices for metagenomics analysis: Fog computing makes bioinformatics ready for the Internet of Things	Bioinformática	X	X	X	X		-
Estudo atual	Contexto amplo	X	X	X	X		Direcionamentos futuros

Fonte: De autoria própria (2024).

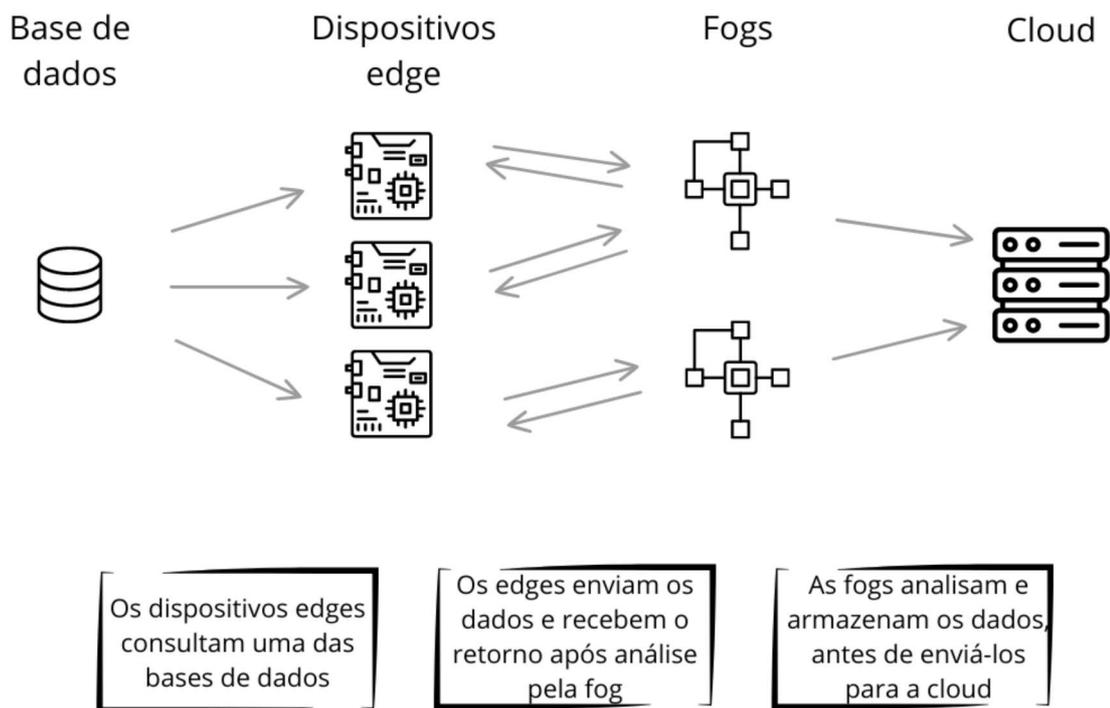
tanto *IoT* quanto *IIoT*, com um foco especial na interoperabilidade entre dispositivos de diferentes capacidades computacionais. Este estudo busca, portanto, preencher essa lacuna, aproveitando os conhecimentos derivados dos trabalhos relacionados para aplicar a especificidade de cada abordagem num espectro mais amplo. Com isso, busca-se a combinar os melhores atributos e características de cada estudo anterior, visando uma arquitetura *Edge-Fog-Cloud* que seja não só eficiente e adaptável, mas também amplamente aplicável em diversos contextos de *IoT* e *IIoT*, promovendo assim uma inovação significativa na área.

4 AMBIENTE E RESULTADOS EXPERIMENTAIS

4.1 ARQUITETURA PROPOSTA

A arquitetura proposta neste estudo integra dispositivos *Edge*, que simulam dispositivos *IoT*, coletando dados de bases específicas para enviar à *Fog*. Na camada de *Fog*, esses dados são recebidos, analisados e armazenados, atuando como um ponto intermediário crítico que agiliza o processamento de informações. Periodicamente, a *Fog* é responsável por enviar os dados armazenados localmente para a *Cloud*, onde podem ser acessados para análises mais profundas e armazenamento de longo prazo, completando assim o ciclo de fluxo de dados na arquitetura *Edge-Fog-Cloud*. A representação dessa proposta é representada pela Figura 9.

Figura 9 - Arquitetura proposta para *Edge-Cloud*



Fonte: De autoria própria (2024)

4.2 ESPECIFICAÇÕES DOS COMPONENTES NO AMBIENTE DE TESTE

Com o intuito de adequar o estudo às exigências de processamento e análise de dados de *IoT* e *IIoT* em tempo real, a arquitetura é composta por ambientes *Cloud*, *Fog* e

Edge. A especificidade dos códigos e as configurações detalhadas dos dispositivos foram desenvolvidos para maximizar a eficiência e a escalabilidade da solução.

A primeira fase dos testes experimentais deste estudo foi conduzida em um ambiente ordinário, onde se enfrentaram desafios significativos relacionados à conexão dos dispositivos sem fio utilizados. Tais problemas geraram diversas inconsistências e falhas que distorciam a representação fiel do ambiente de teste proposto. Diante dessas adversidades, optou-se pela transição para um ambiente especializado, equipado para superar as limitações observadas e garantir a integridade e a precisão dos testes realizados.

4.2.1 Base de dados

As bases de dados escolhidas para este estudo são cruciais para a exploração de aplicações *IoT*, *IIoT* e saúde, refletindo as possíveis aplicações já citadas. Cada base de dados é de licença livre, proporcionando uma riqueza de informações em grandes volumes, com campos de data e hora que permitem simulações temporais precisas e a possibilidade de representar múltiplos dispositivos. Esta característica é importante para testar a eficácia de diferentes configurações de *Fog Computing*, onde dados de diversos dispositivos *IoT* e *IIoT* podem ser processados e analisados para otimizar o desempenho do sistema.

A primeira base de dados, '*IIOT Data of Wind Turbine*', é uma fonte rica de dados operacionais de turbinas eólicas. Esta base inclui uma variedade de parâmetros, com uma prévia através da Figura 10, como velocidade do vento (média, máxima e mínima), rotação da turbina, potência gerada (média, máxima e mínima), horas operacionais, produção em kWh, minutos de produção, etc. Esses dados são fundamentais para a análise de desempenho e manutenção preditiva em ambientes *IIoT*, permitindo a otimização da geração de energia e a minimização de paradas não planejadas (14).

Figura 10 - Trecho da base de dados '*IIOT Data of Wind Turbine*'

DateTime	Time	Error	WEC: ava. windspeed	WEC: max. windspeed	WEC: min. windspeed
5/1/2014 0:00	1398920448	0	6.900000095	9.399999619	2.900000095
5/1/2014 0:09	1398920960	0	5.300000191	8.899999619	1.600000024
5/1/2014 0:20	1398921600	0	5	9.5	1.399999976
5/1/2014 0:30	1398922240	0	4.400000095	8.300000191	1.299999952
5/1/2014 0:39	1398922752	0	5.699999809	9.699999809	1.200000048
5/1/2014 0:49	1398923392	0	8.399999619	9.899999619	5.400000095
5/1/2014 1:00	1398924032	0	6.699999809	10.5	1.899999976
5/1/2014 1:09	1398924544	0	3.700000048	9.100000381	1.100000024
5/1/2014 1:19	1398925184	0	3.400000095	8.899999619	0.699999988
5/1/2014 1:30	1398925824	0	4.5	8.699999809	1.100000024
5/1/2014 1:38	1398926336	0	7.599999905	9.300000191	2.400000095
5/1/2014 1:49	1398926976	0	8.100000381	9.699999809	3.5
5/1/2014 2:00	1398927616	0	6.699999809	9.300000191	2.299999952
5/1/2014 2:10	1398928256	0	7.300000191	9.199999809	3.400000095

Fonte: De autoria própria (2024)

Já a segunda base, 'An Open Dataset for Human Activity Analysis', fornece dados capturados por *smartphones* e *smartwatches*, além de dados de sensores de *smartglasses*. Os *smartphones*, neste contexto, são empregados para capturar dados contextuais, enquanto os *smartwatches* focam na coleta da frequência cardíaca do usuário e dados de movimento, como pode ser visto na Figura 11. Por outro lado, os *smartglasses* são equipados com sensores como acelerômetro, giroscópio e sensor oculográfico, capturando passos, movimentos da cabeça, piscadas e orientação dos olhos. Esta base é intrigante pela sua aplicabilidade em estudos de comportamento humano e saúde, permitindo análises detalhadas sobre atividades diárias e suas implicações para o bem-estar (15).

Figura 11 - Trecho da base de dados 'An Open Dataset for Human Activity Analysis'

index	source	timestamp	values
164349	battery	2017-06-29 07:45:56.262	['98']
164350	accelerometer	2017-06-29 07:46:01.263	['-0.3440857', '0.68330383', '9.967361']
164351	gravity	2017-06-29 07:46:01.324	['-0.34131828', '0.6573288', '9.778641']
164352	linear_acceleration	2017-06-29 07:46:01.329	['-0.018068999', '0.034808993', '-0.033065796']
164353	gyroscope	2017-06-29 07:46:01.402	['0.0041656494', '-0.0132751465', '0.006164551']
164354	pressure	2017-06-29 07:46:01.464	['969.3651']
164355	orientation	2017-06-29 07:46:01.509	['31.284260813896044', '-3.3376453624603086',
164356	magnetometer	2017-06-29 07:46:01.661	['-15.32135', '24.88861', '-44.90509']
164357	rotation_vector	2017-06-29 07:46:01.719	['0.036942374', '0.007465202', '-0.25660786',
164358	heart_rate	2017-06-29 07:46:05.590	['173.0', '0']
164359	accelerometer	2017-06-29 07:46:06.270	['-0.4410553', '0.7886505', '9.872787']
164360	linear_acceleration	2017-06-29 07:46:06.351	['0.011193424', '-0.0062996745', '0.004644394']
164361	gravity	2017-06-29 07:46:06.354	['-0.49383318', '0.6960046', '9.769447']
164362	pressure	2017-06-29 07:46:06.498	['969.0265']

Fonte: De autoria própria (2024)

A terceira base, 'Longitudinal indoor personal comfort preferences', oferece um *feedback* longitudinal sobre preferências de conforto pessoal em ambientes internos, capturadas por *smartwatches*, como pode ser visto na Figura 12. Utilizando micro avaliações ecológicas momentâneas em uma plataforma de *smartwatch*, esta base de dados coleta *feedback* subjetivo dos ocupantes sobre suas preferências em relação ao conforto térmico, ruído e acústica. Durante um experimento que envolveu 30 ocupantes ao longo de duas semanas. Este conjunto de dados é valioso para o desenvolvimento de sistemas inteligentes de gerenciamento ambiental, visando a personalização do conforto e a eficiência energética em edifícios inteligentes (16).

Por fim, a quarta base, 'Pulse Time Series Under Different Conditions', apresenta dados de pulsação sob diversas condições de exercício, como pode ser visto na Figura 13, capturados por um *smartwatch*. A particularidade desta base é devido a metodologia de coleta de dados, onde a frequência cardíaca é monitorada durante corridas de três minutos a velocidades variadas — iniciando a 6 km/h, aumentando para 9 km/h e reduzindo para 3 km/h. Esses dados permitem investigar a resposta fisiológica ao exercício, abrindo caminhos para aplicações em saúde e fitness, especialmente na monitoração e no aprimoramento de

Figura 12 - Trecho da base de dados '*Longitudinal indoor personal comfort preferences*'

Unnamed: 0	index	time	clothing	comfort_cozie
0	0	2019-09-28 09:07:28.561000+00:00		
1	1	2019-09-29 09:07:30.131000+00:00		
2	2	2019-09-30 00:55:46.387000+00:00	10.0	9.0
3	3	2019-09-30 01:04:23.821000+00:00	10.0	9.0
4	4	2019-09-30 03:07:36.976000+00:00	10.0	
5	5	2019-09-30 03:07:42.184000+00:00	10.0	10.0
6	6	2019-09-30 03:30:56.306000+00:00	10.0	10.0
7	7	2019-09-30 04:00:57.716000+00:00	10.0	9.0
8	8	2019-09-30 04:08:23.750000+00:00	9.0	10.0
9	9	2019-09-30 04:37:53.719000+00:00	9.0	10.0
10	10	2019-09-30 04:48:46.900000+00:00	9.0	9.0
11	11	2019-09-30 04:53:00.125000+00:00	9.0	9.0
12	12	2019-09-30 05:02:37.388000+00:00	9.0	10.0
13	13	2019-09-30 05:20:17.130000+00:00	10.0	
14	14	2019-09-30 05:38:46.872000+00:00	9.0	
15	15	2019-09-30 07:07:37.348000+00:00	10.0	

Fonte: De autoria própria (2024)

treinamentos personalizados(17).

Figura 13 - Trecho da base de dados '*Pulse Time Series Under Different Conditions*'

Time start	Total time (seconds)	Workout type	Time	Puls
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:23:44	0
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:23:54	0
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:24:04	107
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:24:14	120
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:24:24	109
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:24:34	120
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:24:44	117
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:24:54	122
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:25:04	132
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:25:14	139
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:25:24	143
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:25:34	148
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:25:44	146
2024-02-07 16:23:44	180	Koşmak	2024-02-07 16:25:54	139

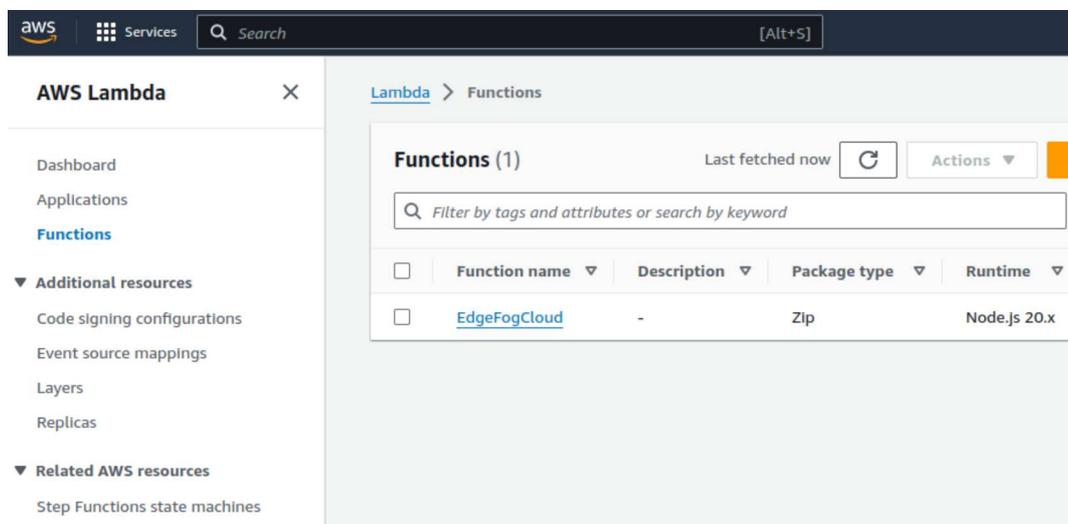
Fonte: De autoria própria (2024)

A importância dessas bases de dados no contexto do nosso trabalho é devido a possibilidade de testar e validar as hipóteses e soluções tecnológicas. Elas não apenas suportam a análise de aplicações específicas em *IoT*, *IIoT* e saúde, mas também facilitam a simulação de cenários complexos que envolvem a interação entre múltiplos dispositivos e sistemas de *Fog Computing*. Através destas bases, é possível explorar a eficácia da arquitetura proposta.

4.2.2 Cloud

O ambiente *Cloud* é executado pelos servidores da *Amazon Web Services (AWS)*, como pode ser visto na Figura 14. Foram utilizadas funções *Lambda* programadas em Node.js, configuradas para operar de forma escalonável e com 5GB de armazenamento, este obtido através da conexão com o *Amazon Simple Storage Service*, também conhecido como *Amazon S3* (24)(25). O uso do HDF5 na *Cloud* é fundamental para lidar com a complexidade dos dados recebidos, permitindo um armazenamento eficiente e acessível para análises futuras.

Figura 14 - Ambiente *AWS Lambda*



Fonte: De autoria própria (2024)

Os códigos desenvolvidos em Node.js para as funções Lambda são específicos para o processamento e análise dos dados enviados pelos dispositivos *Edge* e pelas nós *Fog*, além de organizar e armazenar esses dados de forma otimizada no *Amazon S3* utilizando o formato HDF5. Essa abordagem permite aproveitar as capacidades do HDF5 para gerenciar dados complexos e multidimensionais, combinadas com a escalabilidade, durabilidade e acessibilidade que são oferecidas por serviços de armazenamento na web. Após a análise, os códigos na *Cloud* comunicam o sucesso ou a falha da análise de volta aos dispositivos *Edge* ou nós *Fog*.

4.2.3 Fog

De forma complementar, o ambiente *Fog* é composto por um cluster de Raspberry Pis, com sua imagem real na Figura 15, configurado para suportar tarefas de processamento e armazenamento de dados.

Figura 15 - Cluster



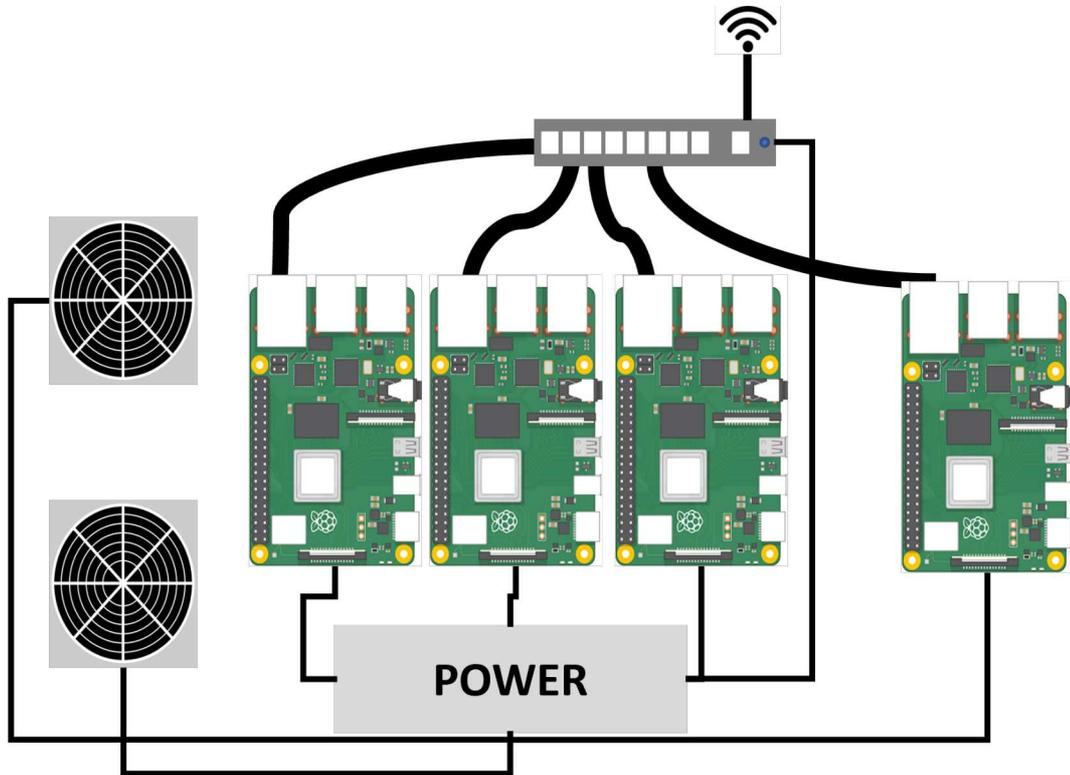
Fonte: De autoria própria (2024)

Este cluster inclui dois modelos Raspberry Pi 4 B+, identificados como pi01 e pi02, ambos equipados com 4 CPUs Broadcom BCM2711, Quad core Cortex-A72 operando a 1.5GHz, e 4GB de RAM. O modelo pi01 dispõe de 64GB de armazenamento, enquanto o pi02 tem 32GB, e ambos operam sob o sistema operacional Raspbian GNU/Linux 11 em sua versão de 64 bits. Adicionalmente, o cluster conta com um Raspberry Pi 3 B+ (pi03), que possui 4 CPUs Broadcom BCM2837B0 a 1.4GHz, 1GB de RAM e 32GB de armazenamento, também rodando Raspbian GNU/Linux 11, mas em sua variante de 64 bits. Por fim, o Raspberry Pi 2 B (pi04) completa o conjunto, trazendo 4 CPUs a 900MHz quad-core ARM Cortex-A7, 1GB de RAM e 32GB de armazenamento, este rodando uma versão de 32 bits do Raspbian GNU/Linux 11. Essa configuração diversificada permite que o cluster de nós *Fog* opere de maneira eficiente, lidando com as demandas de processamento e armazenamento dos dados coletados dos dispositivos *Edge*, enquanto prepara as informações para serem enviadas ao ambiente de *Cloud*. A arquitetura do cluster está representada pela Figura 16.

Nos nós *Fog*, os códigos são escritos em Python e desempenham o papel do processamento intermediário dos dados recebidos dos dispositivos *Edge*. Esses scripts são responsáveis por executar a análise dos dados, armazená-los temporariamente em formato HDF5, e comunicar o status da análise (sucesso ou erro) de volta aos dispositivos *Edge*.

Além disso, os códigos na *Fog* gerenciam o envio periódico desses dados para a *Cloud*, assegurando a distribuição uniforme das cargas de rede e a minimização da latência.

Figura 16 - Disposição dos elementos do cluster



Fonte: De autoria própria (2024)

4.2.4 Edge

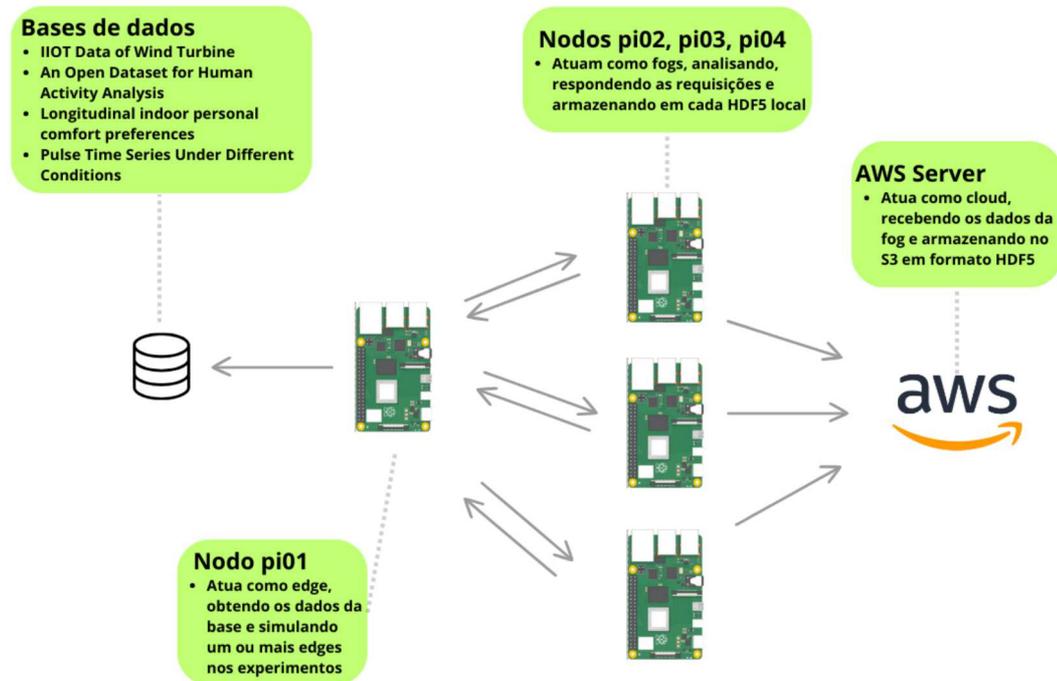
No ambiente *Edge*, especificamente no dispositivo Raspberry Pi 4 B+ (pi01), os códigos em Python são projetados para simular a coleta de dados de dispositivos *IoT* e *IIoT*, utilizando para isso as bases de dados já citadas anteriormente. Esses scripts têm a função de enviar dados diretamente para a *Cloud* e para os nós *Fog* alternativamente, permitindo assim testar diferentes arquiteturas de processamento de dados em tempo real. Em sua execução, os códigos seguem os intervalos de tempo médios definidos em cada uma das bases de dados e, quando esses se esgotam, iniciam novamente a sequência de dados, assegurando a continuidade dos testes sem interrupções.

4.3 AMBIENTES DE TESTE

No ambiente de teste *Edge-Fog-Cloud*, representado pela Figura 17, o nodo pi01 atua como dispositivo *Edge*, enquanto pi02, pi03 e pi04 funcionam como camada *Fog*, encarregados pela análise e armazenamento dos dados. Esta configuração permite uma

análise local, reduzindo latência e aproveitando a proximidade dos dados. Em contraste, como pode ser visto na Figura 18, no ambiente *Edge-Cloud* a ausência da camada *Fog* faz com que todos os dados coletados pelo *Edge* (pi01) sejam enviados diretamente para a *Cloud* (AWS) para análise e armazenamento.

Figura 17 - Ambiente de teste *Edge-Fog-Cloud*

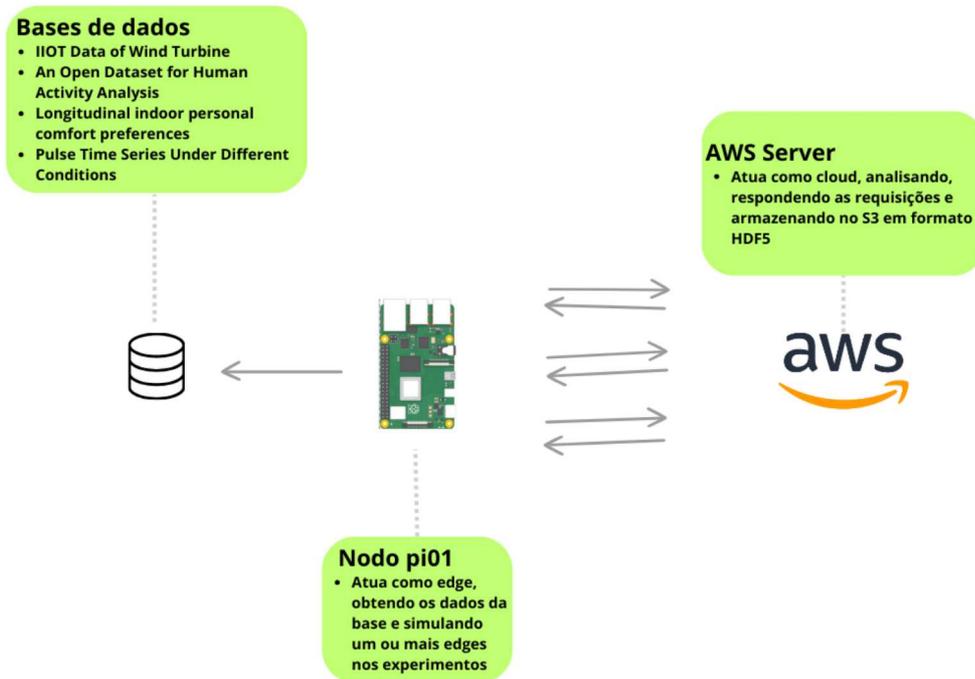


Fonte: De autoria própria (2024)

4.4 EXECUÇÃO

Para avaliar as arquiteturas, foram conduzidos testes planejados, utilizando as bases de dados disponíveis. Cada execução dos testes foi desenvolvida para abranger o uso de todas as bases, sem ordem predefinida, garantindo a diversidade dos cenários de teste. Para cada base de dados, os respectivos dados foram enviados durante um período de 2 horas.

De forma a manter a consistência e evitar variações de rede, cada execução alternou entre o envio de dados diretamente da *Edge* para a *Cloud* e da *Edge* para a *Fog*. Essa metodologia assegura que os dados de cada base de dados sejam enviados duas vezes por execução, uma simulando a configuração *Edge-Cloud* e outra a configuração *Edge-Fog-Cloud*, totalizando um tempo de execução de 8 horas para cada ciclo completo de testes. A Figura 19 representa o código fonte da *Edge* em execução no nó pi01, onde requisições são feitas de forma alternada entre *Fog* e *Cloud*. Já na Figura 20 o código da *Fog* é exibido durante seu funcionamento, onde o mesmo recebe os dados enviados da *Edge*.

Figura 18 - Ambiente de teste *Edge-Cloud*

Fonte: De autoria própria (2024)

Figura 19 - Código em execução no nodo01, simulando um *Edge*

```
fogcomp@pi01: ~
Request succeeded in 0.01670551300048828 seconds
Request succeeded in 0.010578393936157227 seconds
Request succeeded in 0.015493154525756836 seconds
Request succeeded in 0.01563405990600586 seconds
Request succeeded in 0.010536909103393555 seconds
Request succeeded in 0.010482549667358398 seconds
Request succeeded in 0.016034841537475586 seconds
Request succeeded in 0.016277790069580078 seconds
Request succeeded in 0.016021251678466797 seconds
Request succeeded in 0.016020536422729492 seconds
Request succeeded in 0.016035079956054688 seconds
Request succeeded in 0.01576685905456543 seconds
Request succeeded in 0.01644754409790039 seconds
Request succeeded in 0.015746593475341797 seconds
Request succeeded in 0.01584482192993164 seconds
Request succeeded in 0.01601386070251465 seconds
Request succeeded in 0.015446901321411133 seconds
Request succeeded in 0.015444040298461914 seconds
Request succeeded in 0.015468597412109375 seconds
Request succeeded in 0.015372753143310547 seconds
Request succeeded in 0.015243768692016602 seconds
Request succeeded in 0.01546478271484375 seconds
Request succeeded in 0.015460014343261719 seconds
Request succeeded in 0.015891075134277344 seconds
Request succeeded in 0.015743017196655273 seconds
Request succeeded in 0.015850305557250977 seconds
Request succeeded in 0.01568150520324707 seconds
Request succeeded in 0.01563239097595215 seconds
```

Fonte: De autoria própria (2024)

Figura 20 - Código em execução no nodo02, simulando uma *Fog*

```

fogcomp@pi02: ~
* Serving Flask app "fog" (lazy loading)
* Environment: production
  WARNING: This is a development server. Do not use it in a production deployment.
  Use a production WSGI server instead.
* Debug mode: off
* Running on http://0.0.0.0:5000/ (Press CTRL+C to quit)
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done
HDF5 write operation successful
192.168.0.11 - - "POST / HTTP/1.1" 200 -
Analysis done

```

Fonte: De autoria própria (2024)

Durante o estudo, foram conduzidos diferentes ciclos de testes para avaliar e eficácia das diferentes configurações *Edge-Fog-Cloud* e *Edge-Cloud* da solução em ambientes distribuídos, utilizando configurações de 1, 5, 10, 15, 20 e 25 dispositivos *Edge* momentâneos, enquanto a quantidade de nós *Fog* foram constantes, com sempre 3 em operação. A quantidade de servidores *Cloud* se manteve regular, com somente 1 em funcionamento durante todos os testes. Esta metodologia permitiu uma avaliação detalhada da capacidade do sistema de manejar escalas variadas de demanda de processamento e comunicação.

Em adição à estrutura dos testes, é importante notar que cada requisição enviada dos dispositivos *Edge* para a *Fog* ou para a *Cloud* é composta por um conjunto variado de parâmetros, refletindo a diversidade dos tipos de dados manipulados. Por exemplo, no caso dos dados '*IIOT Data of Wind Turbine*', cada requisição inclui 7 parâmetros distintos, como vento mínimo e máximo, rotação e potência mínima gerada, entre outros. Para o '*An Open Dataset for Human Activity Analysis*', as requisições abrangem 10 parâmetros, incluindo dados em três eixos do acelerômetro e giroscópio. Os dados de '*Longitudinal indoor personal comfort preferences*' compreendem 4 parâmetros, como batimento, temperatura e umidade, enquanto '*Pulse Time Series Under Different Conditions*' envia apenas um parâmetro, a frequência cardíaca. Independentemente da quantidade de parâmetros, descritos na Tabela 2, cada valor enviado é submetido a uma operação de comparação com uma constante, caracterizando uma análise de operação de tempo constante $O(1)$ para

cada parâmetro. Assim, a complexidade temporal total da função de processamento para cada requisição é de $O(n)$, onde n representa o número de parâmetros a serem analisados. Essa abordagem assegura que, seja na *Fog* ou na *Cloud*, a análise dos dados enviados pode ser realizada de maneira eficiente, mantendo a capacidade de resposta do sistema frente a variadas demandas de processamento e comunicação.

Tabela 2 – Quantidade de parâmetros analisados de acordo com as bases de dados

Base de dados	Quantidade de parâmetros analisados
IIoT Data of Wind Turbine	7
An Open Dataset for Human Activity Analysis	10
Longitudinal indoor personal comfort preferences	4
Pulse Time Series Under Different Conditions	1

Fonte: De autoria própria (2024).

Além das especificidades dos dados anteriormente, é importante ressaltar que cada base de dados possui um intervalo de tempo distinto entre as entradas de dados, o que influencia na frequência de envio dos dados de dispositivos *Edge* para a *Fog* ou para a *Cloud*. Essa característica garante que os dados sejam enviados respeitando os intervalos naturais da base, refletindo com precisão a variabilidade real dos cenários simulados. Como resultado, cada base de dados contribui com uma quantidade diferente de dados durante o período de 2 horas que define cada ciclo de teste. A quantidade exata de dados enviados varia não apenas em função do intervalo de tempo específico de cada base, mas também da quantidade de dispositivos *Edge* ativos em um dado momento. A Tabela 3 contém um resumo detalhado das quantidades de envio para cada base de dados em um ciclo de teste de 2 horas, além de ilustrar como essas quantidades se ajustam com a variação na quantidade de dispositivos *Edge* momentâneos. Essas informações fornecem uma compreensão da densidade e do volume de dados manipulados pelo sistema.

4.5 RESULTADOS

Os resultados obtidos nesta pesquisa, juntamente com as bases de dados utilizadas, estão disponíveis para acesso e análise através do repositório no *GitHub* no seguinte endereço: <https://github.com/thiagogoldoni/UFJF-PPGCC-Dissertacao>. As bases de dados também estão disponíveis nas referências diretas das citações do documento.

Os resultados obtidos a partir dos testes detalhados são apresentados nas Tabelas 4, 5, 6 e 7, destacando uma comparação detalhada dos tempos médios de resposta e desvios

Tabela 3 – Quantidade de requisições enviadas no período de 2 horas para cada base de dados e para as diferentes quantidades de dispositivos *Edge* momentâneos

Base de dados	Quantidade de dados enviados no período de 2 horas para a quantidade de edges simultâneas					
	1 edge	5 edges	10 edges	15 edges	20 edges	25 edges
IIoT Data of Wind Turbine	673	3365	6730	10095	13460	16825
An Open Dataset for Human Activity Analysis	19440	97200	194400	291600	388800	486000
Longitudinal indoor personal comfort preferences	40	200	400	600	800	1000
Pulse Time Series Under Different Conditions	7200	36000	72000	108000	144000	180000

Fonte: De autoria própria (2024).

padrões para cada uma das bases de dados utilizadas no estudo. Essas tabelas apresentam o comportamento das configurações *Edge-Fog-Cloud* e *Edge-Cloud* sob diversas condições operacionais, oferecendo algumas visões sobre a eficiência das arquiteturas em questão.

Na Tabela 4, analisando o tempo médio em segundos para a resposta no ambiente *Fog* com diferentes quantidades de dispositivos *Edge*, observa-se que para a base '*An Open Dataset for Human Activity Analysis*', o tempo aumenta de 0,01917 segundos com 1 *Edge* para 0,02341 segundos com 25 dispositivos *Edge*, indicando um possível aumento de carga conforme o número de dispositivos *Edge* cresce. Em contraste, a base '*IIoT Data of Wind Turbine*' mostra um aumento de tempo mais moderado, de 0,01784s para 0,01786s no mesmo intervalo, sugerindo uma menor sensibilidade ao aumento de carga.

Tabela 4 – Tempo médio da duração da requisição até a resposta no ambiente *Fog*

Base de dados	Tempo médio em segundos da duração até resposta no ambiente <i>Fog</i>					
	Por 1 edge	Por 5 edges	Por 10 edges	Por 15 edges	Por 20 edges	Por 25 edges
IIoT Data of Wind Turbine	0,0178431448	0,0178616676	0,0178623732	0,0178631059	0,0178638665	0,0178646557
An Open Dataset for Human Activity Analysis	0,0191713375	0,0192277906	0,0193375745	0,0196608523	0,0206128003	0,0234159961
Longitudinal indoor personal comfort preferences	0,0146498704	0,0146645538	0,0146645869	0,0146646164	0,0146646513	0,0146646840
Pulse Time Series Under Different Conditions	0,0151244740	0,0151470368	0,0151581342	0,0151746891	0,0151993856	0,0152362299

Fonte: De autoria própria (2024).

De forma complementar, a Tabela 5 apresenta o desvio padrão em segundos da duração até resposta no ambiente *Fog*, retratando que o desvio padrão para '*Pulse Time Series Under Different Conditions*' permanece relativamente baixo, variando apenas de 0.000942s para 0.000949s de 1 a 25 dispositivos *Edge*. Isso contrasta com a base '*An Open Dataset for Human Activity Analysis*', onde o desvio padrão aumenta de 0.001692 segundos para 0.002066 segundos, indicando uma variabilidade maior nos tempos de resposta à medida que o número de dispositivos *Edge* aumenta.

Já na Tabela 6, que analisa o tempo médio em segundos até a resposta no ambiente *Cloud* também com diferentes quantidades de dispositivos *Edge*, destaca-se que para a base

Tabela 5 – Desvio padrão da duração da requisição até a resposta no ambiente *Fog*

Base de dados	Desvio padrão em segundos da duração até resposta no ambiente <i>Fog</i>					
	Por 1 edge	Por 5 edges	Por 10 edges	Por 15 edges	Por 20 edges	Por 25 edges
IOT Data of Wind Turbine	0,0014922335	0,0014937822	0,0014938415	0,0014939026	0,0014939660	0,0014940325
An Open Dataset for Human Activity Analysis	0,0016918579	0,0016968397	0,0017065266	0,0017350533	0,0018190617	0,0020664499
Longitudinal indoor personal comfort preferences	0,0031648688	0,0031680412	0,0031680489	0,0031680530	0,0031680625	0,0031680706
Pulse Time Series Under Different Conditions	0,0009424070	0,0009438123	0,0009445047	0,0009455365	0,0009470742	0,0009493715

Fonte: De autoria própria (2024).

'An Open Dataset for Human Activity Analysis', o tempo de resposta aumenta de 0,62388 segundos com 1 *Edge* para 0,66531 segundos com 25 dispositivos *Edge*. Este aumento é proporcionalmente maior quando comparado ao da base 'IOT Data of Wind Turbine', que apresenta um aumento mais suave, de 0,62841s para 0,62864 segundos no mesmo intervalo de dispositivos *Edge*, indicando uma melhor estabilidade nesta base em ambiente *Cloud*.

Tabela 6 – Tempo médio da duração da requisição até a resposta no ambiente *Cloud*

Base de dados	Tempo médio em segundos da duração até resposta no ambiente <i>Cloud</i>					
	Por 1 edge	Por 5 edges	Por 10 edges	Por 15 edges	Por 20 edges	Por 25 edges
IOT Data of Wind Turbine	0,6284128106	0,628608545	0,6286160483	0,6286237414	0,6286318441	0,6286402235
An Open Dataset for Human Activity Analysis	0,6238768960	0,6244279743	0,6254997860	0,6286556651	0,6379492250	0,6653156602
Longitudinal indoor personal comfort preferences	0,6367104054	0,6369014707	0,6369020492	0,6369024499	0,6369031366	0,6369031798
Pulse Time Series Under Different Conditions	0,6203948582	0,6206725237	0,6208090699	0,6210127389	0,6213167726	0,6217701388

Fonte: De autoria própria (2024).

Adicionalmente, a Tabela 7 apresenta o desvio padrão em segundos da duração até resposta no ambiente *Cloud*, onde revela uma variação simples na base 'Longitudinal indoor personal comfort preferences', onde o desvio padrão cresce de 0,049051s para 0,049065 de 1 a 25 dispositivos *Edge*. Este aumento sutil contrasta com a base 'An Open Dataset for Human Activity Analysis', que vê um aumento no desvio padrão de 0,016480 segundos para 0,017581 segundos, sugerindo uma maior dispersão nos tempos de resposta à medida que o número de dispositivos *Edge* aumenta, especialmente em comparação com as outras bases.

Por fim, os quartis são medidas estatísticas que dividem os dados em quatro partes iguais, essenciais para entender a distribuição e identificar *outliers*, que são pontos significativamente distintos dos demais dados. A quantidade somada de *outliers* para cada configuração de ambiente está presente na Tabela 8. Na configuração *Edge-Fog-Cloud*, detectamos 846 *outliers*, enquanto a *Edge-Cloud* apresentou 7668, refletindo diferenças significativas na dispersão de dados entre os ambientes, o que ressalta a importância de

Tabela 7 – Desvio padrão da duração da requisição até a resposta no ambiente *Cloud*

Base de dados	Desvio padrão em segundos da duração até resposta no ambiente <i>Cloud</i>					
	Por 1 edge	Por 5 edges	Por 10 edges	Por 15 edges	Por 20 edges	Por 25 edges
IIoT Data of Wind Turbine	0,0141474753	0,0141519861	0,0141521236	0,0141523893	0,0141523536	0,0141524648
An Open Dataset for Human Activity Analysis	0,0164798768	0,0164944341	0,0165225872	0,0166064395	0,0168516166	0,0175814906
Longitudinal indoor personal comfort preferences	0,0490506458	0,0490658770	0,0490649666	0,0490657082	0,0490661678	0,0490655095
Pulse Time Series Under Different Conditions	0,0180061333	0,0180141971	0,0180181115	0,0180241813	0,0180329386	0,0180464217

Fonte: De autoria própria (2024).

analisar tais medidas para avaliar a estabilidade e a consistência dos sistemas propostos.

Tabela 8 – Quantidade de *outliers* por configuração de ambiente

Configuração	Outliers
Edge-Fog-Cloud	846
Edge-Cloud	7668

Fonte: De autoria própria (2024).

4.6 DISCUSSÃO

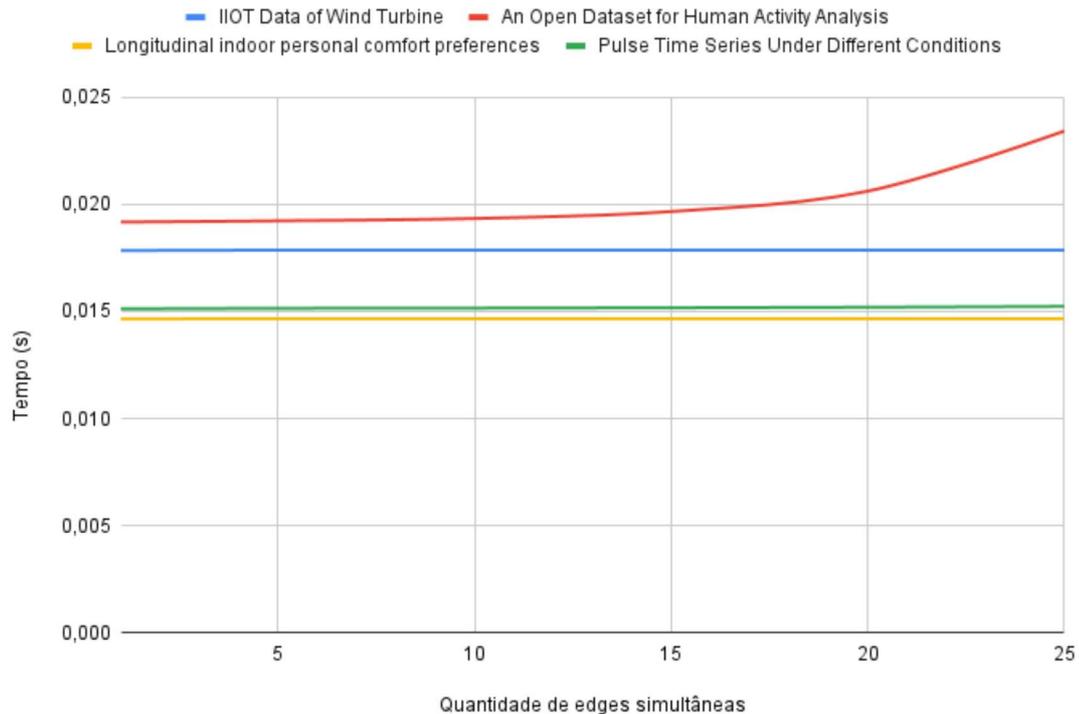
A análise dos resultados obtidos nas diferentes configurações *Edge-Fog-Cloud* e *Edge-Cloud* revela uma dinâmica quanto ao desempenho do sistema em resposta à escalabilidade e à complexidade dos dados processados. Observa-se um desempenho superior da computação em *Fog* que se justifica pela sua proximidade aos dispositivos *Edge*, reduzindo a latência na comunicação e permitindo um processamento mais ágil dos dados. Essa eficiência é notada em todas as bases de dados, mas principalmente em bases com menor quantidade de parâmetros e um volume de dados reduzido, onde a simplicidade das requisições permite um tratamento mais rápido e eficaz pelo sistema.

Contudo, à medida que o número de dispositivos *Edge* aumenta, a capacidade de processamento da *Fog* começa a ser desafiada, especialmente em bases de dados com uma maior complexidade e volume de requisições, como é o caso de '*An Open Dataset for Human Activity Analysis*' e que pode ser visto na Figura 21. Essa base, em comparação com as outras, é a que possui o maior número de requisições enviadas e a que mais necessita operações de análise. Por isso, esse fenômeno pode ser explicado pela limitação dos recursos computacionais disponíveis na *Fog*, que, apesar de serem otimizados para processamento de dados em tempo real, não escalam linearmente com o aumento significativo no volume de dados. Portanto, a degradação no desempenho observada nas etapas finais dos testes

sugere um ponto de saturação da *Fog*, onde a capacidade de processamento pode se tornar um gargalo.

Figura 21 - Tempo médio (s) da resposta da requisição em cada base pela quantidade de dispositivos *Edge* no ambiente *Fog*

Tempo médio em segundos da duração até resposta no ambiente Fog



Fonte: De autoria própria (2024)

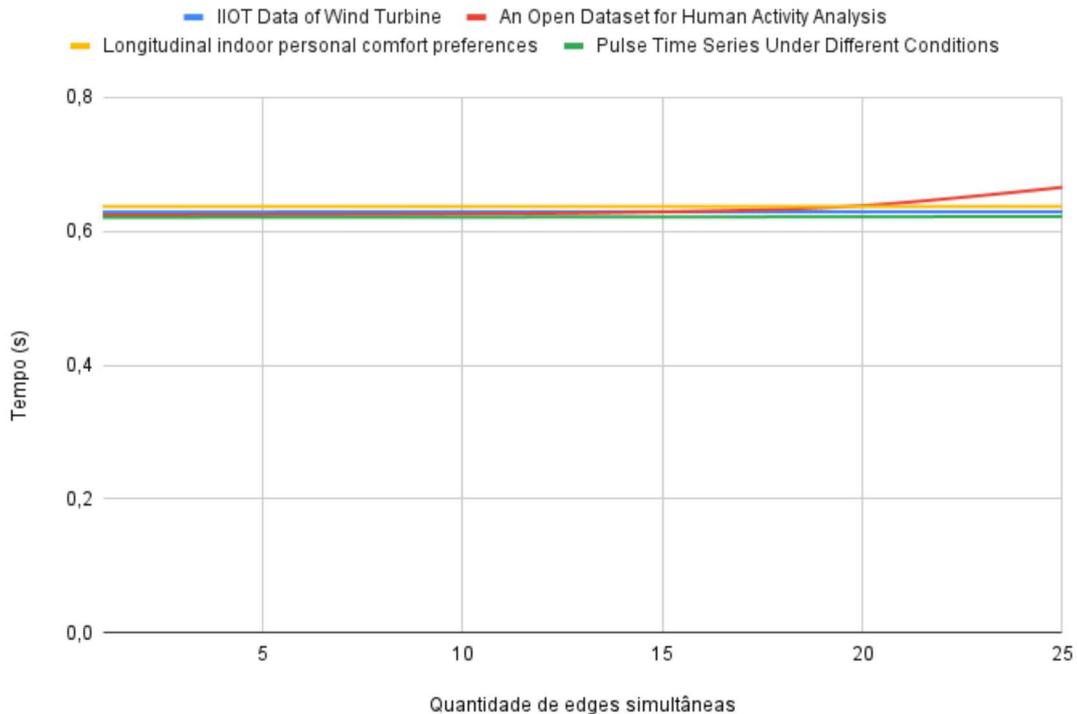
É importante notar que essa saturação da capacidade de processamento na *Fog* não afeta todas as bases de dados igualmente. Bases com menos parâmetros e requisitos menos complexos de processamento, como '*Pulse Time Series Under Different Conditions*', conseguem manter um nível de desempenho aceitável mesmo com o aumento no número de dispositivos *Edge*.

Embora a computação em *Cloud* também apresente um aumento no tempo de resposta conforme o número de dispositivos *Edge* é escalonado, é notável que esse incremento não se dá de forma tão imponente quanto observado na computação em *Fog*, como visto na Figura 22. Esse comportamento pode ser atribuído ao poder computacional disponível na *Cloud*, que, diferentemente da *Fog*, possui uma capacidade de processamento significativamente mais ampla. Essa robustez permite que a *Cloud* absorva aumentos na demanda de processamento sem atingir um ponto de saturação tão rapidamente quanto

aos nós *Fog*, mantendo o desempenho em um nível aceitável mesmo sob cargas de trabalho intensificadas.

Figura 22 - Tempo médio (s) da resposta da requisição em cada base pela quantidade de dispositivos *Edge* no ambiente *Cloud*

Tempo médio em segundos da duração até resposta no ambiente Cloud

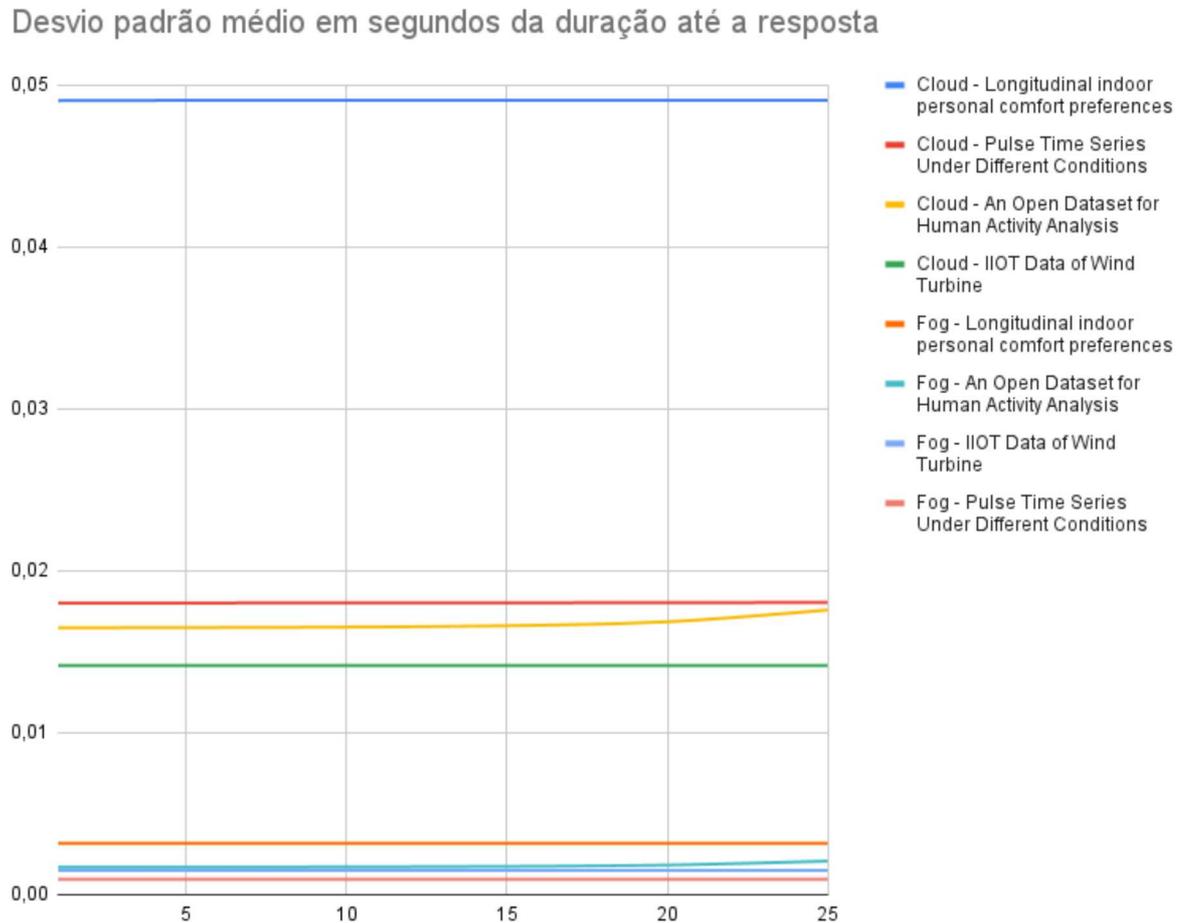


Fonte: De autoria própria (2024)

A figura 23 exibe o gráfico responsável por exibir a comparação entre os desvios padrões médios da duração até a resposta, e revela uma diferença notável entre ambientes *Fog* e *Cloud*. As linhas representando as bases em ambiente *Fog* são mais agrupadas, com desvios na escala dos milésimos de segundo, indicando uma resposta mais rápida e consistente. Em contraste, a configuração *Cloud* mostra desvios nos centésimos de segundo, refletindo a influência da necessidade de conexão com redes externas, que pode aumentar a latência e depende diretamente da qualidade da conexão à internet.

O desvio padrão, ao refletir variações ao invés de tempos de resposta, destaca a consistência predominante no ambiente *Fog*, apontando para uma estabilidade que alinha com os requisitos de aplicações críticas que valorizam a confiabilidade e a capacidade de previsão nas respostas. Essa característica se torna ainda mais evidente ao considerarmos a distribuição de *outliers*, conforme demonstrado na Figura 24, onde é possível comparar a presença de tais dados anômalos nas configurações *Fog* e *Cloud* dos ambientes. Por isso,

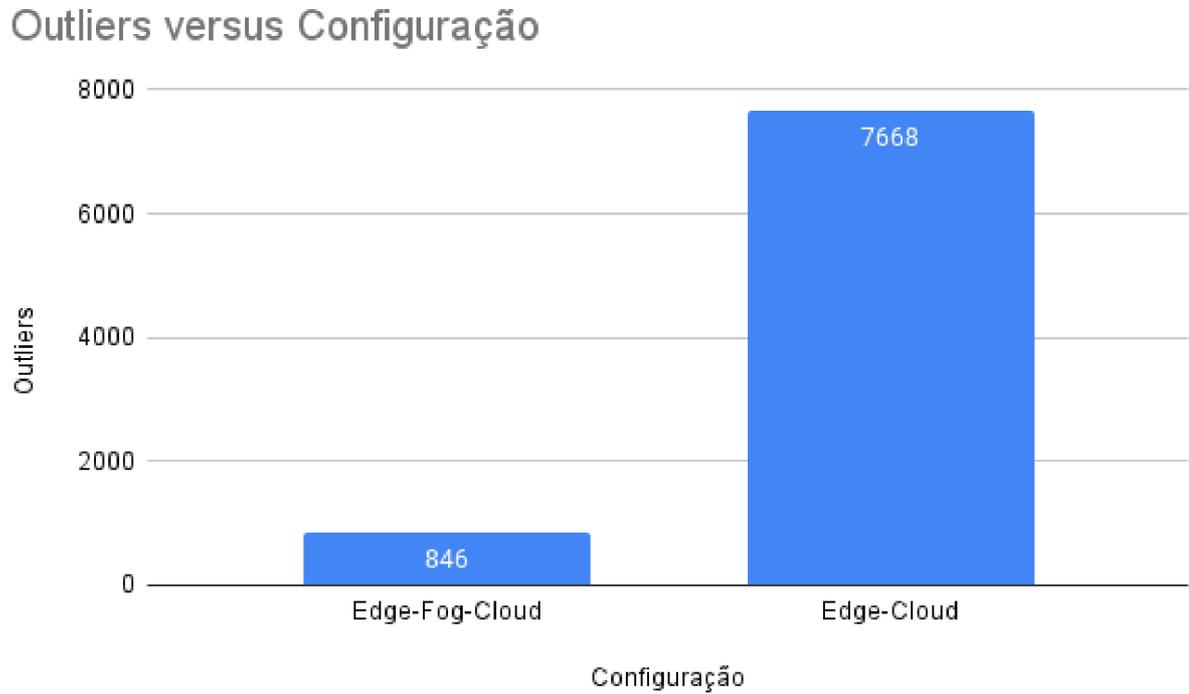
Figura 23 - Tempo médio (s) da resposta da requisição em cada base pela quantidade de dispositivos *Edge* no ambiente *Cloud*



Fonte: De autoria própria (2024)

a importância de analisar conjuntamente desvio padrão e *outliers* é válida durante uma análise de dados. A análise cuidadosa destes elementos fornece indicações contundentes sobre o equilíbrio entre consistência nas respostas e as variações extremas pontuais, salientando a capacidade do ambiente *Fog* para suportar operações críticas, mesmo frente a desafios inerentes a variações de dados.

Ao comparar os aumentos percentuais entre ambientes com 1 e 25 dispositivos *Edge* nas configurações *Edge-Fog-Cloud*, na Tabela 9, e *Edge-Cloud*, na Tabela 10, é possível notar um aumento muito mais expressivo na *Fog*, com valores de aumento percentual variando entre 0,121% e 22,141% nas diferentes bases de dados, contrastando significativamente com os aumentos mais modestos na *Cloud*, que variam de 0,036% a 6,642%. Esse padrão sugere que, apesar das vantagens de latência na *Fog*, ela apresenta uma maior variabilidade de

Figura 24 - Quantidade de *outliers* por cada uma das configurações

Fonte: De autoria própria (2024)

desempenho em comparação à *Cloud*, cujo poder de processamento mais robusto resulta em aumentos menos expressivos, evidenciando as características distintas de processamento e desempenho entre as duas configurações.

Tabela 9 – Diferença no tempo médio e porcentagem de aumento no ambiente *Fog*

Base de dados	Fog - Tempo médio (s)		Diferença	
	1 edge	25 edges	Final - Inicial (s)	Aumento em %
IIOT Data of Wind Turbine	0,0178431448	0,0178646557	0,0000215109	0,121
An Open Dataset for Human Activity Analysis	0,0191713375	0,0234159961	0,0042446586	22,141
Longitudinal indoor personal comfort preferences	0,0146498704	0,0146646840	0,0000148136	0,101
Pulse Time Series Under Different Conditions	0,0151244740	0,0152362299	0,0001117559	0,739

Fonte: De autoria própria (2024).

Tabela 10 – Diferença no tempo médio e porcentagem de aumento no ambiente *Cloud*

Base de dados	Cloud - Tempo médio (s)		Diferença	
	1 edge	25 edges	Final - Inicial (s)	Aumento em %
IIOT Data of Wind Turbine	0,6284128106	0,6286402235	0,0002274129	0,036
An Open Dataset for Human Activity Analysis	0,6238768960	0,6653156602	0,0414387642	6,642
Longitudinal indoor personal comfort preferences	0,6367104054	0,6369031798	0,0001927744	0,030
Pulse Time Series Under Different Conditions	0,6203948582	0,6217701388	0,0013752806	0,222

Fonte: De autoria própria (2024).

4.7 CONSIDERAÇÕES

Os resultados demonstraram que a configuração *Edge-Fog-Cloud* oferece uma vantagem significativa em termos de menor variação nas respostas e latência reduzida quando comparada à configuração *Edge-Cloud*. Enquanto a *Cloud* mostrou um aumento percentual no tempo total menor em comparação com a *Fog*, essa diferença ressalta a eficiência da distribuição de carga e processamento em ambientes mais próximos aos dispositivos de borda.

A configuração do ambiente experimental, mantendo constante a proporção de três nós *Fog* para uma *Cloud*, reforça a importância de adaptar a escala de nós *Fog* em resposta às necessidades específicas dos dispositivos *Edge*. Ao calibrar o número de nós *Fog* para acompanhar a complexidade das análises e o volume de dados gerados pelos dispositivos *Edge*, é possível alcançar uma escalabilidade mais linear, divergindo dos resultados obtidos em momentos de gargalo dos nós *Fog*. Isso não apenas otimiza o desempenho e reduz a latência, mas também pode oferecer uma vantagem de custo significativa, especialmente quando consideramos as estruturas de preços baseadas no uso de recursos e transferência de dados nas soluções de *Cloud Computing*.

Mesmo valores de milésimos de segundo podendo parecer insignificantes à primeira vista, em muitas aplicações, essas diferenças são críticas e podem ter impactos significativos, como evitar acidentes de trânsito, salvar vidas em contextos médicos ou prevenir prejuízos em grandes operações industriais. A aplicação de arquiteturas *Edge-Fog-Cloud*, quando adaptada às necessidades específicas de cada ambiente, promete resultados notáveis. Além de minimizar dependências de conectividade à internet, potencializa a capacidade de resposta imediata e a tomada de decisões em tempo real, elementos essenciais para a segurança e eficiência operacional.

5 CONCLUSÕES

Este trabalho desenvolveu uma arquitetura *Edge-Fog-Cloud* para otimizar o processamento e armazenamento de dados em ambientes *IoT* e *IIoT*, reduzindo a latência e melhorando a eficiência. A proposta incluiu a implementação de soluções que aproveitam as capacidades das camadas *Edge*, *Fog* e *Cloud*, demonstrando como a distribuição de processamento e armazenamento pode melhorar a resposta em aplicações críticas. O estudo focou na integração eficaz dessas tecnologias, visando uma abordagem que suporte aplicações em tempo real em diversos contextos.

5.1 CONTRIBUIÇÃO

O experimento realizado demonstra a importância de uma infraestrutura computacional eficaz em ambientes onde a agilidade no processamento de dados é crucial, como em cidades inteligentes, fábricas e hospitais. Nesses contextos, a capacidade de obter respostas rápidas a partir de dados em tempo real pode ter implicações significativas, desde a prevenção de falhas em máquinas de fábricas até a preservação da vida humana através da monitorização contínua de sinais vitais. A vantagem de sistemas que operam independentemente de conexões de internet, como em ambientes *Fog*, ressalta a relevância dessa abordagem em situações onde a estabilidade da conexão não pode ser garantida. Assim, a implementação de soluções *Edge-Fog-Cloud* não apenas apoia a otimização operacional e a eficiência financeira, mas também eleva os padrões de segurança e bem-estar em diversos setores.

Conclui-se que a utilização de ambientes *Edge-Fog-Cloud* se prova não apenas eficiente, mas de importância comprovada para garantir respostas ágeis em situações críticas. A eficácia desse modelo depende intrinsecamente de um planejamento cuidadoso que considere a quantidade e a frequência dos dados transmitidos, bem como a estruturação adequada da rede de nós *Fog* para suportar as demandas de processamento. A adoção de arquiteturas que promovem o processamento e armazenamento distribuídos é valiosa para maximizar a eficiência da solução, permitindo uma escalabilidade flexível em face de variadas cargas de trabalho. Esse estudo destaca a importância de adaptar a infraestrutura computacional às necessidades específicas de cada aplicação, assegurando que ambientes altamente dinâmicos possam se beneficiar plenamente da agilidade oferecida pela integração eficiente das camadas *Edge*, *Fog* e *Cloud*.

5.2 DIRECIONAMENTOS FUTUROS

Na evolução dos ambientes de *Fog Computing*, uma direção de pesquisa promissora envolve a integração avançada de modelos de aprendizado de máquina, que são inicialmente desenvolvidos e treinados na *Cloud*, aproveitando seu poder de processamento e capacidade

de armazenamento. Essa abordagem permite a criação de modelos complexos, como redes neurais, árvores de decisão e modelos de regressão, que são capazes de aprender com grandes volumes de dados para identificar padrões, fazer previsões ou classificações com alta precisão. Após o treinamento, esses modelos são otimizados e adaptados para se tornarem versões mais leves, a fim de serem implementados nos nós *Fog*. Essa transferência tira proveito da capacidade computacional local da *Fog* para realizar inferências em tempo real com dados provenientes dos dispositivos *Edge*, permitindo decisões rápidas e ações baseadas em análises profundas, mesmo com as limitações de processamento dos ambientes de *Fog*.

Explorar o potencial de modelos de aprendizado de máquina leves na *Fog* abre novas oportunidades para pesquisa e desenvolvimento. Por exemplo, em um cenário prático, um modelo na *Fog* que monitora as condições de temperatura de equipamentos industriais pode prever falhas antes que elas ocorram, promovendo manutenção preventiva e evitando paradas não planejadas. A atualização contínua desses modelos, com novas versões treinadas na *Cloud*, garante que o sistema se mantenha adaptável e eficiente frente às mudanças nos padrões de dados.

REFERÊNCIAS

- 1 Khujamatov, H., Reypnazarov, E., Khasanov, D., Akhmedov, N. **IoT, IIoT, and Cyber-Physical Systems Integration**. Advances in Science, Technology and Innovation. Springer, Cham. doi: 10.1007/978-3-030-66222-63
- 2 Aagaard, A., Presser, M., Andersen, T. **Applying Iot as a leverage for business model innovation and digital transformation**. Global IoT Summit (GIoTS), Aarhus, Denmark, 2019, pp. 1-5. doi: 10.1109/GIOTS.2019.8766397.
- 3 Aazam, M., Zeadally, S., Harras, K.A. **Fog Computing Architecture, Evaluation, and Future Research Directions**. IEEE Communications Magazine, vol. 56, no. 5, pp. 46-52, May 2018. doi: 10.1109/MCOM.2018.1700707
- 4 Alam, T. **Cloud-Based IoT Applications and Their Roles in Smart Cities**. Smart Cities. 2021; 4(3):1196-1219. doi: 10.3390/smartcities4030064
- 5 Shi, W., Cao, J., Zhang, Q., Li, Y., Xu, L. **Edge Computing: Vision and Challenges**. IEEE Internet of Things Journal, vol. 3, no. 5, pp. 637-646, Oct. 2016. doi: 10.1109/JIOT.2016.2579198.
- 6 Sabireen, H., Neelanarayanan, V. **A Review on Fog Computing: Architecture, Fog with IoT, Algorithms and Research Challenges**. ICT Express, Volume 7, Issue 2, 2021, Pages 162-176, ISSN 2405-9595. doi: 10.1016/j.ict.2021.05.004.
- 7 Habibi, P., Farhoudi, M., Kazemian, S., Khorsandi, S., Leon-Garcia, A. **Fog Computing: A Comprehensive Architectural Survey**. IEEE Access, vol. 8, pp. 69105-69133, 2020, doi: 10.1109/ACCESS.2020.2983253.
- 8 Sunyaev, A. **Cloud Computing**. Internet Computing. Springer, Cham. doi: 10.1007/978-3-030-34957-87
- 9 Bouakouk, M.R., Abdelli, A., Mokdad, L. **Survey on the Cloud-IoT paradigms: Taxonomy and architectures** IEEE Symposium on Computers and Communications (ISCC), Rennes, France, 2020, pp. 1-6. doi: 10.1109/ISCC50000.2020.9219638
- 10 Byers., C.C. **Architectural Imperatives for Fog Computing: Use Cases, Requirements, and Architectural Techniques for Fog-Enabled IoT Networks**. IEEE Communications Magazine, vol. 55, no. 8, pp. 14-20, Aug. 2017. doi: 10.1109/MCOM.2017.1600885
- 11 Folk, M., Heber, G., Koziol, Q., Pourmal, E., Robinson, D. **An overview of the HDF5 technology suite and its applications**. In Proceedings of the EDBT/ICDT 2011 Workshop on Array Databases (AD '11). Association for Computing Machinery, New York, NY, USA, 36–47. doi: 10.1145/1966895.1966900
- 12 Firouzi, F., Farahani, B., Marinšek, A. **The convergence and interplay of edge, fog, and cloud in the AI-driven Internet of Things (IoT)**. Information Systems, Volume 107, 2022, 101840, ISSN 0306-4379. doi: 10.1016/j.is.2021.101840.
- 13 Ashton, K. **That ‘internet of things’ thing**. RFID Journal, 22 (7), 97-114

- 14 **IIOT Data of Wind Turbine.** Data from Microsoft Azure Predictive Maintenance Template, 2014. Disponível em:
<https://www.kaggle.com/datasets/wasuratme96/iiot-data-of-wind-turbine>. Acesso em: set 2023.
- 15 **An Open Dataset for Human Activity Analysis.** Data collected using Smartphone, Smartwatch and Smartglasses, 2017. Disponível em:
<https://www.kaggle.com/datasets/sasanj/human-activity-smart-devices>. Acesso em: set 2023.
- 16 **Longitudinal indoor personal comfort preferences.** Thermal/light/noise data captured from building occupants using smartwatches, 2021. Disponível em:
<https://www.kaggle.com/datasets/claytonmiller/longitudinal-personal-thermal-comfort-preferences>. Acesso em: set 2023.
- 17 **Pulse Time Series Under Different Conditions.** Smartwatch pulse monitoring with three-minute runs before and after fitness, 2024. Disponível em:
<https://www.kaggle.com/datasets/fatihfurkankurt/pulse-time-series-under-different-conditions>. Acesso em: jan 2024.
- 18 Ghobaei-Arani, M., Souri, A., Rahmanian, A.A. **Resource Management Approaches in Fog Computing: a Comprehensive Review.** J Grid Computing 18, 1–42 (2020). doi: 10.1007/s10723-019-09491-1
- 19 Wang, Y., Su, Y., Agrawal, G. **Supporting a Light-Weight Data Management Layer over HDF5.** 13th IEEE/ACM International Symposium on Cluster, Cloud, and Grid Computing, Delft, Netherlands, 2013, pp. 335-342. doi: 10.1109/CCGrid.2013.9.
- 20 Dai, X., Spasić, I., Meyer, B., Chapman, S., Andres, F. **Machine Learning on Mobile: An On-device Inference App for Skin Cancer Detection.** Fourth International Conference on Fog and Mobile Edge Computing (FMEC), Rome, Italy, 2019, pp. 301-305. doi: 10.1109/FMEC.2019.8795362
- 21 Jung, T.-W., Lee, J.-Y., Jung, K.-D. **Traffic-based reinforcement learning with neural network algorithm in fog computing environment.** International Journal of Internet, Broadcasting and Communication, 12(1), 144–150. doi: 10.7236/IJIBC.2020.12.1.144
- 22 Harjuhahto, J., Debner, A., Hirvisalo, V. **Processing LiDAR Data from a Virtual Logistics Space.** In 2nd Workshop on Fog Computing and the IoT (Fog-IoT 2020). Open Access Series in Informatics (OASICs), Volume 80, pp. 4:1-4:12, Schloss Dagstuhl - Leibniz-Zentrum für Informatik (2020). doi: 10.4230/OASICs.Fog-IoT.2020.4
- 23 Merelli, I., Morganti, L., Corni, E., Pellegrino, C., Cesini, D., Roverelli, L., Zereik, G., D’Agostino, D. **Low-power portable devices for metagenomics analysis: Fog computing makes bioinformatics ready for the Internet of Things.** Future Generation Computer Systems, Volume 88, 2018, Pages 467-478, ISSN 0167-739X. doi: 10.1016/j.future.2018.05.010.
- 24 **Amazon Web Services.** Cloud Computing Services. Disponível em:
<https://aws.amazon.com/>. Acesso em: out 2023.

25 **Amazon S3.** Amazon Simple Storage Service. Disponível em:
<https://aws.amazon.com/s3/>. Acesso em: out 2023.

APÊNDICE A – PUBLICAÇÕES

Thomé, T.G., Ströele, V., Pinheiro, H., Dantas, M.A.R. (2021). **A Fog Computing Simulation Approach Adopting the Implementation Science and IoT Wearable Devices to Support Predictions in Healthcare Environments**. In: Barolli, L., Woungang, I., Enokido, T. (eds) *Advanced Information Networking and Applications. AINA 2021. Lecture Notes in Networks and Systems*, vol 226. Springer, Cham. https://doi.org/10.1007/978-3-030-75075-6_24

Abstract: The world is facing a grand challenge with the unexpected pandemic caused by the Sars-CoV-2 virus. Several researches are underway to understand more about the virus, its way of spreading in environments and prevention methods. Even in a short period, it was possible to obtain recommendations to assist in the control of contamination, and some parameters of those are the use of masks and social distancing. In this study, we considered the implementation science concept in a simulation effort based on changes in habits and behaviors related based on prevention methods. In addition, in our work we also considered the utilization of wearable IoT devices for monitoring people who live in environments where social isolation is complex. We conceived four scenarios with different prevention approaches and isolation, where the health data of the simulated agents were collected for monitoring and providing predictions. The implementation science approach, together with wearable IoT devices, provided a differentiated view from all environments. Agents that have more preventive habits got contamination rates of 12.11% against the worst scenario, with 77.00%.

Qualis: A3

Pioli, L., Thomé, T.G., Nunes, J.X.M., de Macedo, D.D.J., Junior, P.C.R.d.L., Dantas, M.A.R. (2022). **A Scientific Model to Support Industrial Data Management Process Using Virtualized Environments**. In: Barolli, L. (eds) *Advances on P2P, Parallel, Grid, Cloud and Internet Computing. 3PGCIC 2021. Lecture Notes in Networks and Systems*, vol 343. Springer, Cham. https://doi.org/10.1007/978-3-030-89899-1_15

Abstract: Nowadays, scientific and industrial fields produce data at rates never seen before. They usually produce an extensive amount of raw data that should be transformed and manipulated to be stored correctly considering different storage perspectives. In many cases, due to the heterogeneity of the temporal data, these storage methods should be configured to make consistent data available for client consumption. Considering raw data management of a natural industrial environment to support specific local tasks, in this paper, an industrial effort model in the context of virtual environment data access was constructed. In this solution, the data were captured, processed, and available in almost real-time for in loco staff through VR technologies. The usage of these virtualized

technologies in industrial areas is challenging and promissory due to the wide variety of applications to support locale tasks. The results presented are promising to support tasks and operational demands in complex industrial contexts.

Qualis: B1