

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

MAURÍCIO ARTUR COPATTI

**AVALIAÇÃO DE DESEMPENHO DE COMPUTAÇÃO EM NUVEM E NÉVOA:
ESTUDO DE CASO DE UM SISTEMA DE AUTOMAÇÃO RESIDENCIAL COM
REDES NEURAIS ARTIFICIAIS**

CURITIBA

2022

MAURÍCIO ARTUR COPATTI

**AVALIAÇÃO DE DESEMPENHO DE COMPUTAÇÃO EM NUVEM E NÉVOA:
ESTUDO DE CASO DE UM SISTEMA DE AUTOMAÇÃO RESIDENCIAL COM
REDES NEURAIIS ARTIFICIAIS**

**Cloud and fog computing performance evaluation: case study of a home
automation system with artificial neural networks**

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Tecnólogo em Sistemas em Telecomunicações do Curso Superior de Tecnologia em Sistemas de Telecomunicações da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Daniel Fernando Pigatto

CURITIBA

2022



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

MAURÍCIO ARTUR COPATTI

**AVALIAÇÃO DE DESEMPENHO DE COMPUTAÇÃO EM NUVEM E NÉVOA:
ESTUDO DE CASO DE UM SISTEMA DE AUTOMAÇÃO RESIDENCIAL COM
REDES NEURAIS ARTIFICIAIS**

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Tecnólogo em Sistemas em Telecomunicações do Curso Superior de Tecnologia em Sistemas de Telecomunicações da Universidade Tecnológica Federal do Paraná.

Data de aprovação: 12/dezembro/2022

Daniel Fernando Pigatto
Doutor
Universidade Tecnológica Federal do Paraná

Juliana de Santi
Doutora
Universidade Tecnológica Federal do Paraná

Tânia Lúcia Monteiro
Doutora
Universidade Tecnológica Federal do Paraná

**CURITIBA
2022**

Dedico este trabalho a minha família, amigos, e
todas as pessoas que por muitos anos me
apoiaram de forma direta e indireta.

AGRADECIMENTOS

Começo agradecendo ao professor Doutor Daniel Fernando Pigatto, que colaborou ativamente para a realização deste trabalho. Também agradeço a professora Doutora Myriam Regattieri de Biase da Silva Delgado e ao mestrando Lucas Vilela Sanches de Mamann pela colaboração na parte de inteligência artificial.

Gostaria de agradecer também os professores Alexandre Jorge Miziara, Décio Estevão do Nascimento, Henrique Oliveira da Silva, Joilson Alves Júnior e Simone Crocetti, pelo tempo e esforço dedicado durante os períodos de aulas com eles.

Aos meus colegas de curso, pelos bons e maus momentos que passamos juntos durante muitos anos.

RESUMO

Com o aumento do número de dispositivos de internet das coisas, começam a aparecer algumas das desvantagens de se implementar um gerenciamento centralizado utilizando computação em nuvem. Questões como alto custo para se armazenar os dados e executar os aplicativos, baixa privacidade na transmissão dos dados e alta latência podem dificultar seu uso, levando a uma má experiência por parte dos usuários. Considerando estas características da computação em nuvem, surgiu o conceito de computação em névoa. A computação em névoa está localizada mais perto da borda da rede, visando reduzir a latência e abrindo espaço para que aplicativos e serviços possam aproveitar do processamento geograficamente mais próximo. Este trabalho explora, de forma aplicada, no contexto de casas inteligentes, o impacto da latência entre a computação em névoa e a computação em nuvem utilizando uma aplicação de redes neurais artificiais para prever o comportamento do morador da residência. Os resultados mostraram que a computação em névoa pode servir como uma alternativa viável à computação em nuvem nas atuais implementações de automação residencial, reduzindo, assim, custos de implementação.

Palavras-chave: automação residencial; computação em névoa; computação em nuvem; inteligência artificial; internet das coisas.

ABSTRACT

With the increase in the number of IoT devices, some of the disadvantages of implementing central management using cloud computing are beginning to appear. Issues such as high cost to store data and run applications, low privacy in data transmission and high latency can make it difficult to use, leading to a bad experience for users. Considering these characteristics of cloud computing, the concept of fog computing emerged. Fog computing is located closer to the edge of the network to reduce latency and make room for applications and services to take advantage of geographically closer processing. This work explores, in an applied way, in the context of smart homes, the impact of latency between fog computing and cloud computing using an application of artificial neural networks to predict the behavior of a person that lives in the house. The results showed that fog computing can serve as a viable alternative to cloud computing in current home automation deployments, thus reducing implementation costs.

Keywords: artificial intelligence; cloud computing; fog computing; home automation; internet of things.

LISTA DE FIGURAS

Figura 1 – Dispositivos de internet das coisas	13
Figura 2 – Névoa, nuvem e IoT	17
Figura 3 – Representação da implementação do projeto	23
Figura 4 – Componentes propostos para o <i>framework</i>	24
Figura 5 – Configuração proposta do ambiente	24
Figura 6 – Estrutura proposta	25
Figura 7 – Raspberry Pi 4 Modelo B	29
Figura 8 – Diagrama AWS	30
Figura 9 – F-Score médio para memória alta e baixa com taxa de transferência alta	33
Figura 10 – F-Score médio para memória alta e baixa com taxa de transferência média	33
Figura 11 – F-Score médio para memória alta e baixa com taxa de transferência baixa	34
Figura 12 – Média de retreino por amostra para memória alta e baixa com taxa de transferência alta	34
Figura 13 – Média de retreino por amostra para memória alta e baixa com taxa de transferência média	35
Figura 14 – Média de retreino por amostra para memória alta e baixa com taxa de transferência baixa	35

LISTA DE TABELAS

Tabela 1 – Sumário do conjunto de dados utilizado nos experimentos	28
Tabela 2 – Especificação técnica dos processadores utilizados	29
Tabela 3 – Treinamento Online: resultados para as diferentes combinações de configurações	32

LISTA DE ABREVIATURAS E SIGLAS

Siglas

AWS	<i>Amazon Web Services</i>
BIOS	<i>Brazilian Institute of Data Science</i>
BRACIS	<i>Brazilian Conference on Intelligent Systems</i>
CoAP	<i>Constrained Application Protocol</i>
FN	Falso Negativo
FP	Falso Positivo
GCP	<i>Google Cloud Platform</i>
IA	Inteligência Artificial
IaaS	<i>Infrastructure as a Service</i>
IoT	<i>Internet of Things</i>
MQTT	<i>Message Queuing Telemetry Transport</i>
NIST	<i>National Institute of Standards and Technology</i>
PaaS	<i>Platform as a Service</i>
SaaS	<i>Software as a Service</i>
SDN	<i>Software Defined Network</i>
StaaS	<i>Storage as a Service</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Objetivos	11
1.1.1	Objetivo geral	11
1.1.2	Objetivos específicos	11
1.2	Justificativa	12
1.3	Estrutura do trabalho	12
2	REFERENCIAL TEÓRICO	13
2.1	Internet das Coisas	13
2.2	Computação em Nuvem	14
2.2.1	Características da computação em nuvem	14
2.2.2	Modelos de Serviço	15
2.2.3	Modelos de Implementação	15
2.3	Computação em Névoa	16
2.4	Desafios na computação em névoa e nuvem	17
2.5	Inteligência Artificial	18
2.5.1	Exemplos de utilização de inteligência artificial	18
2.5.2	Desafios em inteligência artificial	19
2.6	Redes neurais artificiais	20
2.6.1	Modelos de Aprendizado Offline	21
2.6.2	Modelos de Aprendizado Online	21
2.6.3	Métricas para avaliação de sistemas inteligentes	21
3	TRABALHOS RELACIONADOS	23
3.1	Uso da computação em névoa para coleta e análise de dados em cidades inteligentes	23
3.2	Uma Abordagem Orientada à Observação Temporal de Aplicações Distribuídas Baseadas em IoT e Configuração de <i>Fog Computing</i>	24
3.3	Uma Arquitetura de <i>Fog Computing</i> Virtualizada para Prover Gerenciamento de Recursos, QoS e SLA em um Ambiente Inteligente	25
3.4	Implementação de uma <i>fog computing</i> para fornecer StaaS a Dispositivos IoT utilizando sistemas embarcados	26

3.5	Considerações Finais	27
4	MATERIAIS E MÉTODOS	28
4.1	Materiais	29
4.2	Métodos	29
5	RESULTADOS	32
5.1	Discussões	36
6	CONCLUSÃO	37
	REFERÊNCIAS	38

1 INTRODUÇÃO

Uma tecnologia que vem crescendo bastante nos últimos anos é a Internet das Coisas (*Internet of Things* (IoT)), na qual dispositivos que originalmente não foram desenvolvidos com propósitos computacionais, como pequenos eletrônicos e eletrodomésticos, estão sendo conectados a redes locais e transmitindo dados a sistemas em nuvem.

Com o aumento no número destes dispositivos de internet das coisas, o tráfego de dados vem crescendo proporcionalmente, fazendo com que sejam necessários maiores sistemas de transmissão de dados, processamento e infraestrutura, tornando-os mais complexos e caros (GRANJAL; MONTEIRO; SILVA, 2015). Por este motivo, surgiu o conceito de Computação em Névoa (*Fog Computing*), no qual o processamento dos dados é feito próximo aos dispositivos conectados, para que posteriormente seja transmitido para a nuvem. Seria como um processamento intermediário dos dados, com menor latência entre os dispositivos (BONOMI *et al.*, 2012). Nesse contexto, a computação em névoa é uma das tecnologias capazes de potencializar o crescimento da internet das coisas, pois aproxima os recursos dos usuários e permite análises em tempo real (DASTJERDI; BUYYA, 2016).

Considerando que as análises podem ocorrer quase em tempo real, muitos destes dispositivos podem ser utilizados para automatizar residências, fazendo com que o tempo gasto diariamente com tarefas que possam ser automatizadas diminua significativamente. Também, podem ser inseridos códigos de Inteligência Artificial (IA) para melhorar as respostas fornecidas pelos sistemas automatizados, principalmente para resolver questões que envolvam identificação de padrões de uso dos espaços físicos e tempo de utilização de equipamentos.

1.1 Objetivos

Nesta seção serão apresentados o objetivo geral e os objetivos específicos deste trabalho.

1.1.1 Objetivo geral

Implementar e analisar um ambiente de computação em névoa e nuvem no contexto de automação residencial.

1.1.2 Objetivos específicos

- Realizar uma revisão bibliográfica dos tópicos de computação em névoa e nuvem, principalmente considerando critérios de desempenho e eficiência;

- Identificar ferramentas e modelos que possam ser utilizados para medir e comparar os sistemas implementados;
- Apresentar resultados em diferentes configurações de ambientes de experimentos para auxiliar na tomada de decisão para aplicações reais;
- Sugerir melhorias que possam ser implementadas em sistemas existentes de computação em nuvem e névoa.

1.2 Justificativa

Com o crescente aumento no número de dispositivos conectados a sistemas de computação em névoa e nuvem, é necessário analisar quais dos modelos de estrutura apresentam as melhores características de desempenho e eficiência no cenário atual. Para isso, pode ser analisado se o tempo de execução, tempo de resposta, segurança e escalabilidade do sistema influenciam de forma positiva ou negativa o tema abordado.

1.3 Estrutura do trabalho

Este trabalho está dividido em seis seções, sendo elas:

- 1 - Introdução: nesta seção está localizado o objetivo geral e os objetivos específicos, a justificativa e a estrutura do trabalho.
- 2 - Referencial Teórico: nesta seção está demonstrado o estado atual das tecnologias utilizadas no trabalho conforme bibliografia. Apresenta as definições de computação em névoa, nuvem, inteligência artificial, redes neurais, métricas utilizadas e desafios apresentados em suas respectivas tecnologias.
- 3 - Trabalhos Relacionados: nesta seção estão localizados trabalhos acadêmicos relacionados as tecnologias apresentadas.
- 4 - Materiais e Métodos: nesta seção é demonstrado como o trabalho foi desenvolvido, como os dados foram selecionados, além de quais materiais, métodos e ambientes foram utilizados.
- 5 - Resultados: nesta seção são apresentados os resultados e discussões obtidos a partir dos testes realizados.
- 6 - Conclusão: nesta seção são apresentadas as conclusões geradas.

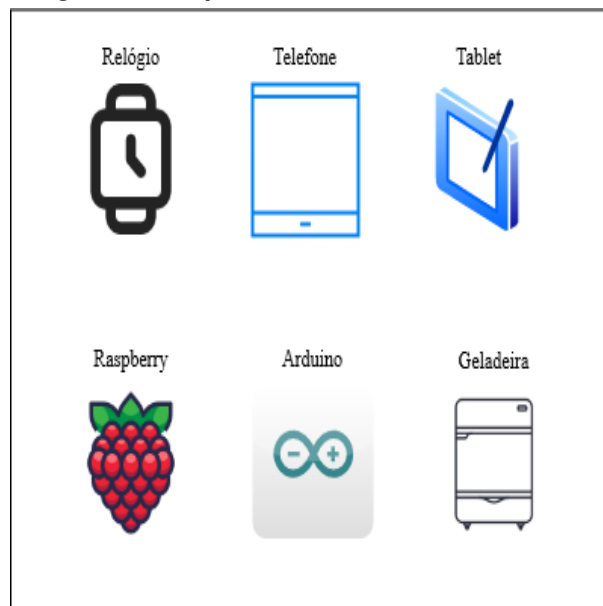
2 REFERENCIAL TEÓRICO

Este capítulo apresenta os conceitos de Internet das Coisas, Computação em Névoa e Computação em Nuvem, assim como os desafios relacionados a essas áreas. Apresenta também os conceitos de Inteligência Artificial e Redes Neurais Artificiais, ambos utilizados nos cenários de testes com automação residencial e que serão apresentados nos resultados.

2.1 Internet das Coisas

O primeiro passo para se montar um sistema de automação residencial ligado a computação em névoa utilizando internet das coisas é definir o que são estes termos, e como eles podem ser utilizados. Segundo Gillis (2022), internet das coisas é um sistema de dispositivos computacionais interconectados, equipamentos digitais ou mecânicos, objetos que possam ser identificados de forma única e que possuem a habilidade de transferir dados em uma rede sem precisar de interações entre humanos ou computadores. Por exemplo, um sensor de umidade, temperatura ou gás carbônico, que pode captar dados de um ambiente e enviar os valores para a nuvem. A Figura 1 apresenta dispositivos que podem ser considerados desta categoria.

Figura 1 – Dispositivos de internet das coisas



Fonte: Autoria própria (2022).

Além disso, conseguem emitir alertas em situações nas quais os dados estejam abaixo ou acima de um nível considerado aceitável, para que não ocorram comprometimentos dos padrões estabelecidos para o local monitorado (INDÚSTRIA... , 2018). Porém, um problema enfrentado pela internet das coisas são as quantidades de dados coletados pelos sensores, que pode ser imensa, e a identificação de quais dados são relevantes para envio aos servidores em nuvem (SHARDA, 2019).

2.2 Computação em Nuvem

Computação em nuvem é um paradigma computacional onde a computação é movida para longe de computadores pessoais ou servidores de aplicação individuais. Os consumidores precisam apenas se preocupar com suas necessidades computacionais e acesso, sem se preocupar com detalhes subjacentes. A computação em nuvem disponibiliza uma grande quantidade de recursos, de forma escalável, dinamicamente alocada, virtual e sob demanda para seus usuários. Esses serviços não estão limitados somente a aplicações de internet, pois podem oferecer também serviços de armazenamento, servidores, bases de dados, redes e aplicativos (REHMAN, 2018).

De acordo com Peter e Timothy (2015), o Instituto Nacional de Padrões do Estados Unidos (*National Institute of Standards and Technology (NIST)*) define Computação em Nuvem como um modelo que permite acesso a recursos computacionais configuráveis, de maneira ampla, conveniente, sob demanda, e que possa ser configurada com pouco esforço ou interação com o provedor. Além dessa definição, os autores detalham no documento SP 800-145 as características de computação em nuvem da seguinte forma:

2.2.1 Características da computação em nuvem

- **Acesso sob demanda:** um consumidor consegue unilateralmente provisionar recursos computacionais, como tempo de servidor e armazenamento, conforme a necessidade e de forma automática, sem precisar de interação humana com o provedor de serviço.
- **Acesso de qualquer local pela rede:** os recursos podem ser acessados por dispositivos padrão, como por exemplo telefones celulares, *tablets*, *notebooks* e computadores de mesa.
- **Agrupamento de recursos:** os recursos da nuvem são agrupados para atender a vários consumidores usando modelos multiusuários, com diferentes recursos físicos e virtuais atribuídos e reatribuídos dinamicamente de acordo com a demanda dos consumidores.
- **Rápida elasticidade:** os recursos podem ser provisionados e liberados de forma elástica, em alguns casos automaticamente, para escalar rapidamente para mais ou para menos, de acordo com a demanda. Para os consumidores, os recursos disponíveis para provisionamento geralmente parecem ilimitados e podem ser apropriados em qualquer quantidade a qualquer momento.
- **Serviço medido:** os sistemas em nuvem controlam e otimizam automaticamente o uso de recursos, aproveitando uma capacidade de medição em nível de abstração apropriado ao tipo de serviço, como por exemplo armazenamento, processamento, largura

de banda e contas de usuário ativas. O uso dos recursos pode ser monitorado, controlado e reportado, proporcionando transparência tanto para o provedor quanto para o consumidor do serviço utilizado.

2.2.2 Modelos de Serviço

Segundo Goyal, Garg e Bhatia (2021), os sistemas de computação em nuvem podem ser implantados de três formas diferentes, dependendo da cadeia produtiva ou maturidade de serviço necessário, sendo eles:

- **Software como serviço (*Software as a Service (SaaS)*):** é fornecido ao consumidor a capacidade de se utilizar aplicativos executados diretamente na infraestrutura da nuvem. Os aplicativos são acessíveis por meio de dispositivos de interface, como navegadores Web, ou interfaces de programa. Os consumidores não gerenciam ou controlam a infraestrutura da nuvem, incluindo servidores, sistemas operacionais, armazenamento ou mesmo recursos de aplicativos individuais, com a possível exceção de configurações limitadas ao usuário dentro do programa.
- **Plataforma como serviço (*Platform as a Service (PaaS)*):** é fornecido ao consumidor a capacidade de se implantar na infraestrutura de nuvem aplicativos criados pelo consumidor ou adquiridos usando linguagem de programação, bibliotecas, serviços e ferramentas suportadas pelo provedor. O consumidor não gerencia ou controla a infraestrutura, mas possivelmente tem controle sobre as definições de configuração do ambiente de hospedagem do aplicativo.
- **Infraestrutura como serviço (*Infrastructure as a Service (IaaS)*):** é fornecido ao consumidor a capacidade de processamento, armazenamento, redes e outros recursos computacionais fundamentais, onde o consumidor pode implantar e executar programas de forma arbitrária, incluindo a capacidade de escolha do sistema operacional. O consumidor não gerencia ou controla a infraestrutura adjacente da nuvem, mas tem controle sobre as definições do hardware, e possivelmente controle limitado de dispositivos de rede, como por exemplo *firewalls*.

2.2.3 Modelos de Implementação

Também, conforme Goyal, Garg e Bhatia (2021), os modelos de implantação são baseados em localização, controle de acesso e controle de configuração, tendo como base o modelo de serviço escolhido, sendo quatro modelos de implantação definidos:

- **Nuvem Privada:** a infraestrutura da nuvem é provisionada para uso exclusivo por uma única organização, composta por vários consumidores internos, como por exemplo,

unidades de negócio dentro de uma mesma empresa. Pode ser de propriedade, gerenciada e operada pela própria organização, por terceiros, ou por alguma combinação deles, e pode existir dentro e fora das instalações da empresa.

- **Nuvem Comunitária:** a infraestrutura da nuvem é provisionada para uso exclusivo por uma comunidade específica de consumidores de organizações que compartilham requerimentos semelhantes, como por exemplo, mesmo objetivo de negócio, mesmos requisitos de segurança, mesmas políticas de conformidade. Pode ser de propriedade, administrado e operado por uma ou mais organizações da comunidade, um terceiro ou uma combinação deles, podendo existir dentro ou fora das instalações da empresa.
- **Nuvem Pública:** a infraestrutura de nuvem é provisionada para uso aberto pelo público em geral. Ela pode ser de propriedade, gerenciada e operada por uma organização empresarial, acadêmica ou governamental, ou alguma combinação delas. Ela existe dentro das instalações do provedor de nuvem. Alguns exemplos de provedor de nuvem pública são: *Amazon Web Services (AWS)*, *Google Cloud Platform (GCP)* e *Microsoft Azure*.
- **Nuvem Híbrida:** a infraestrutura de nuvem é uma composição de duas ou mais infraestruturas de nuvem distintas, privadas, comunitárias ou públicas, que permanecem entidades únicas, mas são unidas por alguma tecnologia padronizada ou proprietária, que permite a portabilidade de dados entre os aplicativos ou sistemas.

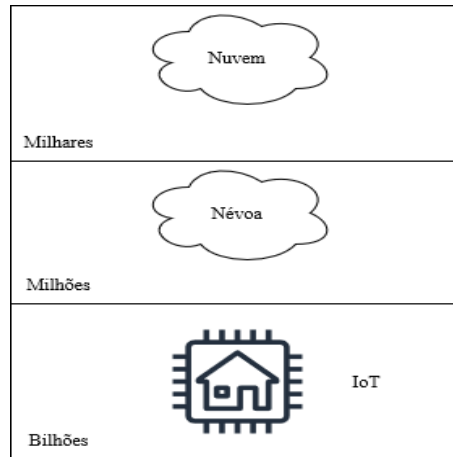
2.3 Computação em Névoa

Uma solução é descentralizar os aplicativos, gerenciamento e análise de dados dentro de uma rede local. Esse contexto foi denominado computação em névoa (S. *et al.*, 2018). Para Butler (2018), a Computação em Névoa é uma extensão do conceito de Computação em Nuvem para as bordas da rede, sendo ideal para internet das coisas e outras aplicações que exijam interações em tempo real. As principais características da névoa são:

- Baixa latência e conhecimento da localização;
- Ampla distribuição geográfica;
- Mobilidade;
- Grande número de nós;
- Acesso predominante sem fio;
- Forte presença de aplicações em tempo real e fluxo de dados;
- Heterogeneidade.

Para exemplificar a hierarquia entre névoa e nuvem, a Figura 2 demonstra as quantidades de dispositivos e sua localização em relação aos usuários.

Figura 2 – Névoa, nuvem e IoT



Fonte: Autoria própria (2022).

2.4 Desafios na computação em névoa e nuvem

Os desafios podem ser divididos em técnicos e de gestão, tendo como técnicos a parte de segurança dos dados, integração entre sistemas modernos e legados, performance do provedor do serviço ou da rede e migração dos dados. Como desafios gerenciais, pode-se citar os custos variáveis, experiência de funcionários com diferentes tecnologias, problemas legais, licenciamentos de programas e políticas de privacidade de dados (GOYAL; GARG; BHATIA, 2021). Além disso, os sistemas tradicionais de nuvem utilizados para Internet das Coisas são desafiados pela escala, heterogeneidade e latência em ecossistemas de nuvem (S. *et al.*, 2018).

Também é importante destacar os principais desafios relacionados à computação em névoa, sendo eles:

- Análises em tempo real. Em ambientes de computação em névoa, o gerenciamento de recursos tem que ser capaz de determinar, de forma dinâmica, quais funções de análise serão apresentadas para cada nuvem ou dispositivo de borda para minimizar a latência e maximizar as taxas de transferência. Estes sistemas também precisam considerar outros critérios, como as leis de dados de cada país ou região, envolvendo, por exemplo, informações médicas ou financeiras.
- Modelos de programação e arquiteturas. Muitas das estruturas de processamento e transmissão de dados não conseguem prover escalabilidade e flexibilidade para ambientes em névoa e de internet das coisas, pois são baseados em configurações estáticas. Ambientes distribuídos podem adicionar e remover recursos de forma dinâmica,

já que os nós de processamento são geralmente dispositivos móveis que se conectam e desconectam frequentemente.

- **Segurança, confiança e resistência a falhas.** Garantir a segurança em ambientes em nuvem é um desafio importante, já que existem diferentes provedores de serviços e diferentes usuários, além da distribuição dos recursos. É difícil desenhar e implementar técnicas de autenticação e autorização que trabalhem com múltiplos nós, equipados com diferentes recursos de processamento. Implementações de criptografia utilizando chaves públicas e ambientes qualificados são soluções em potencial. Usuários de computação em névoa também precisam estar preparados para acidentes na rede, plataforma de serviço e aplicações. Para resolver este problema, padrões como Protocolo de Controle de Transmissão (TCP), que lida com os pacotes e com a confiabilidade em redes de sensores sem fio, pode ser aplicada.
- **Consumo de energia.** Ambientes de computação em névoa consistem em múltiplos nós, então a base é distribuída e pode não possuir uma boa eficiência energética comparada a sistemas centralizados na nuvem. Para resolver este problema, protocolos de comunicação mais eficientes podem ser utilizados, como o CoAP (*Constrained Application Protocol*), que é um protocolo de aplicação restrita, ou o MQTT (*Message Queuing Telemetry Transport*), que é um protocolo utilizado para transporte de mensagens, além de uma abordagem conjunta sobre os recursos computacionais e de rede.

2.5 Inteligência Artificial

O conceito de inteligência artificial iniciou como uma forma de teoria na qual o comportamento humano poderia ser exibido por máquinas. Esse conceito foi evoluindo, até que nos dias atuais, com o avanço da tecnologia e com quantidades de dados extremas, a inteligência artificial se modificou de conhecimento apenas teórico para aplicações tangíveis em escala sem precedentes. Sua utilização vai desde processar grandes quantidades de dados em tempos reais, veículos autônomos, até recomendações de vídeos por plataformas na internet (HELM *et al.*, 2020).

Dentro do conceito de inteligência artificial, existe o conceito de aprendizado de máquina. No aprendizado de máquina, a inteligência humana é combinada com a capacidade dos algoritmos de aprenderem e melhorarem suas análises.

2.5.1 Exemplos de utilização de inteligência artificial

No livro publicado por Alessandro (2019), é demonstrada a utilização de inteligência artificial no contexto de cibersegurança. O foco do livro é a implementação de sistemas para

prevenir e detectar ameaças, além de anomalias em redes de computadores. Os exemplos citados no livro incluem:

- Ameaças de correio eletrônico utilizando diferentes estratégias e filtros;
- Caça de programas maliciosos e suas variações;
- Anomalias de rede;
- Autenticação e segurança de usuários;
- Prevenção de fraudes;
- Redes adversas generativas;
- Avaliação de algoritmos.

2.5.2 Desafios em inteligência artificial

Sistemas de inteligência artificial possuem alguns desafios que precisam ser superados. No artigo de Mohammad *et al.* (2022) são descritos 28 desafios encontrados na literatura, cobrindo um número alto de questões abordadas, sendo elas:

- Identificação do problema e formulação;
- Consumo de energia;
- Problemas com os dados;
- Confiabilidade e robustez;
- Trapaças e enganoso;
- Segurança em termos gerais;
- Privacidade;
- Justiça;
- Explicabilidade;
- Responsabilidade;
- Controlabilidade;
- Previsibilidade;
- Aprendizado contínuo;

- Espaço de armazenamento;
- Comunicação e semântica;
- Moralidade e ética;
- Racionalidade;
- Mente e cognição;
- Contabilidade;
- Transparência;
- Reprodutibilidade;
- Evolução;
- Benefícios;
- Exploração;
- Verificabilidade;
- Segurança no contexto de trabalho;
- Complexidade;
- Credibilidade.

Segundo o artigo, muitos pesquisadores focam em resolver um problema específico com um conjunto fixo de hipóteses como contexto, e geralmente em um ambiente estacionário. Isso pode levar a situações problemáticas, pois muitos destes sistemas podem ser utilizados em produtos e indústrias em situações variadas.

2.6 Redes neurais artificiais

As redes neurais artificiais têm sido amplamente utilizadas em dispositivos móveis e aplicações inteligentes, como casas e cidades inteligentes, e vêm alcançando resultados promissores em várias tarefas. Exemplos atuais incluem reconhecimento de objetos, reconhecimento de fala, e aplicações de automação residencial. Estas estruturas de rede são compostas por camadas conectadas, nas quais os dados de entrada são processados por cada camada até que a última produza o resultado calculado. À medida que mais camadas são utilizadas, mais recursos computacionais são utilizados. Por isso, são necessários modelos neurais, sendo que os online e offline têm suas próprias vantagens e desvantagens (MAMANN *et al.*, 2022).

Existem vários estudos sobre redes neurais artificiais utilizando aprendizagem online ou offline, porém discutir cada um deles está fora do escopo deste trabalho. No contexto de casas inteligentes e computação em névoa ou nuvem, é um campo pouco explorado.

2.6.1 Modelos de Aprendizado Offline

Um método de aprendizagem offline recebe todos os dados do problema desde o início e produz uma resposta que resolva o problema em questão. Estes modelos podem lidar com grandes quantidades de dados, pois o tempo de computação não é crítico para sua estrutura. Eles são robustos para pequenas variações, mas não se adaptam a mudanças maiores no sistema.

2.6.2 Modelos de Aprendizado Online

Um método de aprendizado online é aquele capaz de processar dados de fluxo, peça por peça, de forma serial, sem ter todos os dados de entrada disponíveis desde o início. Modelos online podem se adaptar rapidamente a variações não lineares de comportamento das entradas, mas podem ser menos precisos por causa de pequenos conjuntos de dados fornecidos para treinamento nos lotes. Além disso, devido a sua baixa capacidade de memória, frequentemente grandes quantidades de dados são esquecidas com o tempo.

2.6.3 Métricas para avaliação de sistemas inteligentes

A partir do momento que os dados são processados pelos sistemas de inteligência artificial ou aprendizado de máquina, é necessário a utilização de métricas para classificar os resultados. A métrica geralmente depende do problema analisado (DIEGO, 2021). Os dados classificados podem ser apresentados de forma visual utilizando o conceito de matriz de confusão.

A classificação dos dados em sistemas que trabalham com verdadeiros e falsos pode gerar quatro saídas possíveis:

- Verdadeiro Positivo (VP): Quando o dado analisado é positivo e o sistema classificou como positivo;
- Verdadeiro Negativo (VN): Quando o dado analisado é negativo e o sistema classificou como negativo;
- Falso Positivo (FP): Quando o dado analisado é negativo e o sistema classificou como positivo;

- Falso Negativo (FN): Quando o dado analisado é positivo e o sistema classificou como negativo.

Para o cálculo dos acertos do método utilizado, são somados os valores de verdadeiros positivos e verdadeiros negativos:

$$\text{acertos} = VP + VN \quad (1)$$

Para o cálculo do erro, são somados os valores de falsos positivos e falsos negativos:

$$\text{erros} = FP + FN \quad (2)$$

A acurácia do sistema demonstra uma performance geral do modelo e pode ser obtida dividindo o total de acertos pelo total de dados analisados:

$$\text{acurácia} = \frac{\text{Total de acertos}}{\text{Total de itens}} \quad (3)$$

A métrica de sensibilidade é a capacidade do sistema de detectar com sucesso os resultados positivos:

$$\text{sensibilidade} = \frac{VP}{VP + FN} \quad (4)$$

A especificidade é a métrica utilizada para se detectar com sucesso os resultados negativos:

$$\text{especificidade} = \frac{VN}{VN + FP} \quad (5)$$

A precisão é o grau de variação dos resultados dentro de uma medição. Ela é a métrica utilizada para avaliar a quantidade de verdadeiros positivos sobre todos os valores positivos detectados:

$$\text{precisão} = \frac{VP}{VP + FP} \quad (6)$$

O F-Score é calculado conforme a precisão e sensibilidade do sistema. Funciona como um método de se observar apenas uma métrica, que está mais próxima dos menores valores do que uma média aritmética simples:

$$\text{F-Score} = 2 * \frac{\text{precisão} * \text{sensibilidade}}{\text{precisão} + \text{sensibilidade}} \quad (7)$$

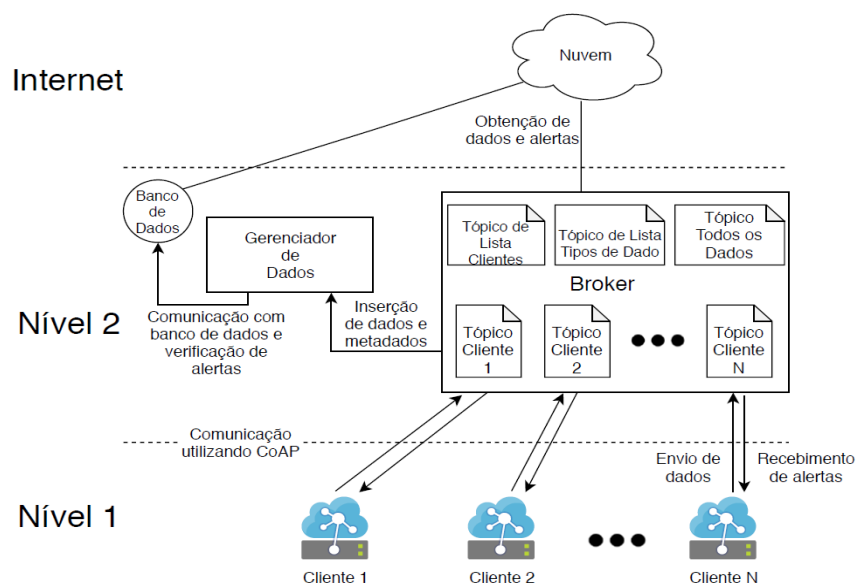
3 TRABALHOS RELACIONADOS

Existem diversos trabalhos acadêmicos relacionados a este em relação a computação em névoa e nuvem, e diversos trabalhos relacionados nos quesitos de inteligência artificial e aprendizado de máquina. Porém, com os dois temas sendo utilizados ao mesmo tempo a bibliografia é mais escassa.

3.1 Uso da computação em névoa para coleta e análise de dados em cidades inteligentes

No trabalho de Ross (2019), é apresentada uma arquitetura de dois níveis com base em computação em névoa, a fim de facilitar o processo de coleta e análise de dados provenientes de sensores posicionados em reservatórios de água. Neste cenário, buscou-se um protocolo de comunicação que otimize o uso de processamento e consumo energético dos sensores, além do uso de largura de banda e a eficiência perante a perda de dados na rede. Para escolha do protocolo mais adequado para o cenário em questão, é analisado o desempenho dos dois protocolos mais populares para IoT, *Message Queuing Telemetry Transport* (MQTT) e *Constrained Application Protocol* (CoAP). As métricas de latência, consumo de largura de banda, eficiência perante a perda de dados e eficiência energética são consideradas. Como resultado, foi determinado que o protocolo CoAP mais se adequou aos objetivos propostos, utilizando as métricas de latência, largura de banda, eficiência em situações com perda de dados e consumo energético. A Figura 3 apresenta a arquitetura do projeto.

Figura 3 – Representação da implementação do projeto

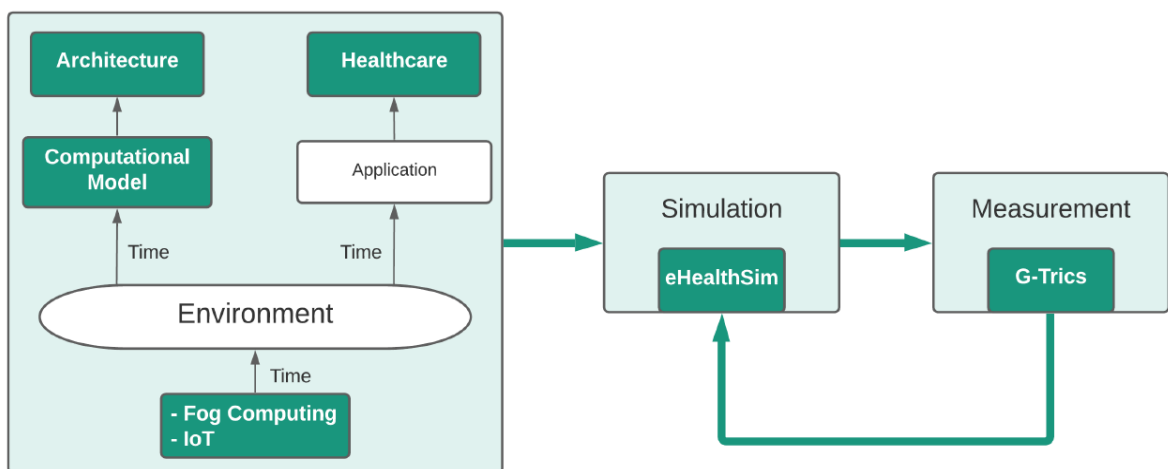


Fonte: Ross (2019).

3.2 Uma Abordagem Orientada à Observação Temporal de Aplicações Distribuídas Baseadas em IoT e Configuração de *Fog Computing*

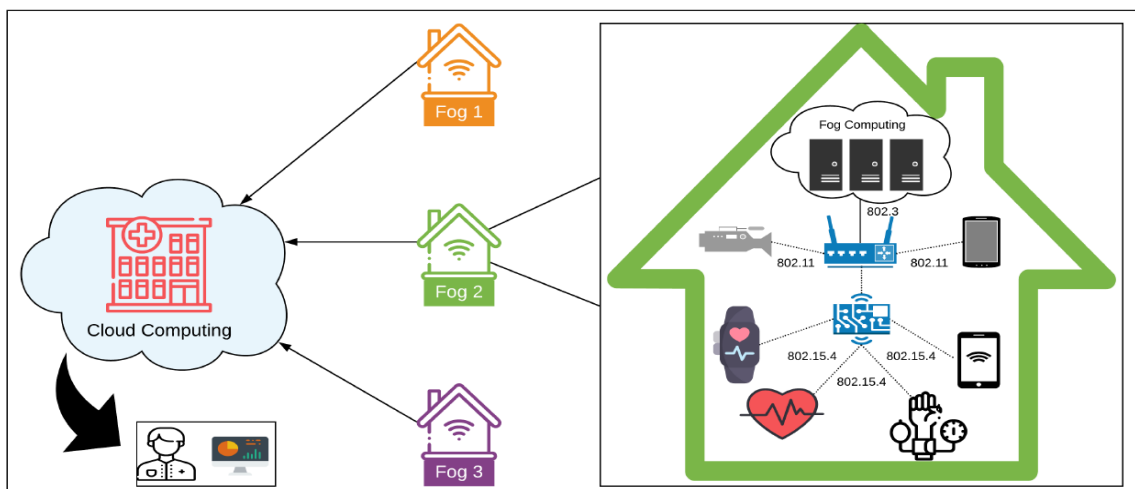
Na tese de Gomes (2021), foram investigadas diversas abordagens relacionadas aos conceitos de execução de aplicações em tempo real, com configurações baseadas em computação em névoa. Também, foi proposto um *framework*, conforme visualizado na Figura 4, com o objetivo de estruturar e medir o desempenho de um ambiente distribuído. O caso de estudo apresentado foi relacionado a saúde, conforme Figura 5.

Figura 4 – Componentes propostos para o *framework*



Fonte: Gomes (2021).

Figura 5 – Configuração proposta do ambiente



Fonte: Gomes (2021).

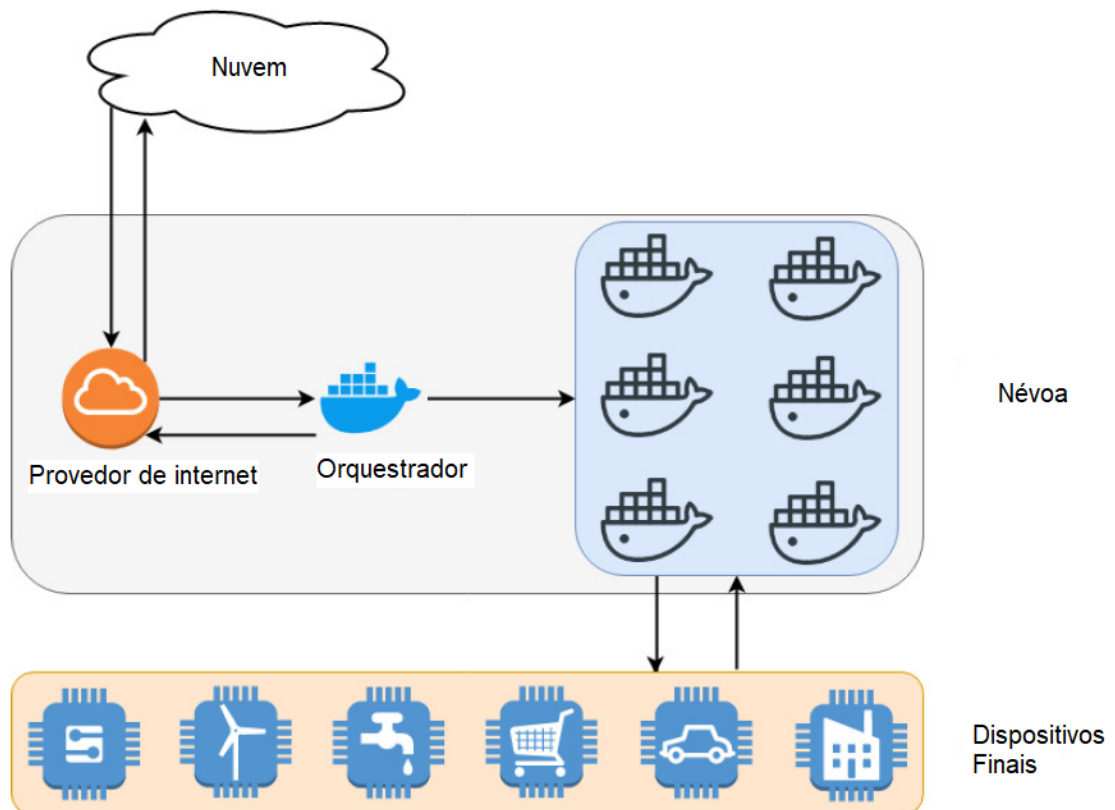
Foi demonstrado que o ambiente de IoT possui características que se aproximam ao tempo real, no qual os dados são executados imediatamente após a sua chegada, sem garantir o tempo de execução.

3.3 Uma Arquitetura de *Fog Computing* Virtualizada para Prover Gerenciamento de Recursos, QoS e SLA em um Ambiente Inteligente

No artigo de Ribeiro, Sa e Barreto (2019), foi apresentada uma arquitetura de computação em névoa para segurança e qualidade de serviço. Foram apresentados seis critérios considerados importantes para a arquitetura proposta, sendo eles: heterogeneidade, qualidade de serviço, escalabilidade, mobilidade, federação e interoperabilidade. Além destas características, também foram abordados aspectos de segurança, com o objetivo de facilitar uma possível comercialização de serviços utilizando a arquitetura implementada.

A estrutura apresentada na Figura 6 foi definida conforme referencial teórico deste trabalho, sendo dividida em névoa, nuvem, além de dispositivos de internet das coisas. A comunicação entre as camadas apresentadas utilizou *Software Defined Network* (SDN).

Figura 6 – Estrutura proposta



Fonte: Adaptado de Ribeiro, Sa e Barreto (2019).

Para o ambiente de névoa, foi utilizado virtualização de contêineres utilizando o aplicativo Docker. A escolha do Docker foi devido a sua capacidade de tolerância a falhas, gerenciamento dos serviços e escalabilidade.

No ambiente de nuvem AWS, foi implementado um algoritmo de inteligência artificial de forma distribuída, capaz de aprender sobre situações e comportamentos anormais, principalmente ataques de negação de serviço. Neste ambiente foi feito o treinamento e a validação das amostras, que foram tiradas de bases de dados abertas.

Como resultado, foi apresentada uma arquitetura capaz de prover, de forma consistente, gerenciável, segura, com características que são importantes para ambientes de dispositivos de internet das coisas. Para os autores, os resultados foram possíveis devido ao ambiente utilizado, configurado de maneira orquestrada e virtualizada, com inteligência artificial, promovendo uma estrutura que pode facilitar a entrega dos serviços entre as diferentes camadas.

3.4 Implementação de uma *fog computing* para fornecer StaaS a Dispositivos IoT utilizando sistemas embarcados

Na dissertação de Machado (2018), foi utilizado um ambiente de névoa para implementar um espaço de armazenamento de dados do tipo *Storage as a Service* (StaaS) para dispositivo de internet das coisas utilizando sistemas embarcados, além de comparar o sistema com servidores de alto desempenho.

A justificativa apresentada pelo autor foi de que como os dispositivos de internet das coisas possuem poucos recursos de processamento e memória, poderiam ser utilizados dispositivos como Raspberry Pi e Banana Pi como plataforma de computação em névoa para suprir as limitações existentes. O Quadro 1 detalha as diferentes implementações de sistemas operacionais e dispositivos utilizados.

Quadro 1 – Diferentes implementações de sistemas operacionais

Equipamentos utilizados na avaliação				
EQUIPAMENTO	S.O	VIRTUALIZAÇÃO	RAM	REDE
Banana PI M3	Ubuntu Server 16.04	Não suporta	2 Gb	1000 Mb/s
Raspberry PI 3	Raspbian Stretch Lite 9	Sem virtualização	1 Gb	100 Mb/s
Raspberry PI 3	Raspbian Stretch Lite 9	Docker	1 Gb	100 Mb/s
Raspberry PI 3	Ubuntu MATE 16.04	Docker	1 Gb	100 Mb/s
Servidor Dell T410	Ubuntu Server 16.04	VMware ESXi + Docker	16 Gb	1000 Mb/s
Desktop Dell OptiPlex 5050	Windows 10	Docker	16 Gb	1000 Mb/s

Fonte: Machado (2018).

Os resultados apresentados pelo autor conseguiram satisfazer as expectativas apresentadas para aplicações que funcionam em tempo quase real, porém não foram adequadas para aplicações em tempo real, pois o desvio padrão apresentado nos dispositivos de sistemas embarcados estava muito elevado, fazendo com que o sistema não obtivesse uma boa precisão.

3.5 Considerações Finais

Nesta seção foram apresentados diversos trabalhos referentes à utilização de sistemas de computação em névoa e nuvem em ambientes de cidades inteligentes, aplicações distribuídas baseadas em internet das coisas, gerenciamento de recursos, qualidade de serviço e armazenamento de dados.

Os resultados obtidos pelos autores demonstram que sistemas de computação em névoa podem ser utilizados de forma eficiente em diversos ambientes, podendo alcançar resultados próximos aos sistemas em nuvem, com suas vantagens e desvantagens dependendo da forma e modelo de implementação.

Considerando que os trabalhos apresentados neste capítulo não contemplam a associação de técnicas de redes neurais e computação em névoa e nuvem, foi desenvolvida a proposta deste trabalho conforme os próximos capítulos.

4 MATERIAIS E MÉTODOS

Como este trabalho aborda um ambiente de redes de computadores, automação residencial, computação em névoa e nuvem, além de inteligência artificial, é necessário definir quais materiais e métodos foram utilizados para construir o ambiente de testes para obtenção dos resultados.

Os testes e o código implementado foram elaborados em parceria com o mestrando Lucas Vilela Sanches de Mamann, utilizados em sua dissertação e também no artigo (MAMANN *et al.*, 2022) apresentado no *Brazilian Conference on Intelligent Systems* (BRACIS), organizado pelo *Brazilian Institute of Data Science* (BIOS), sendo considerado um dos eventos mais importantes no Brasil para pesquisadores interessados em publicar estudos significativos ou inéditos relacionados a inteligência artificial e computação inteligente.

A proposta apresenta quatro visões diferentes e compara sua performance para resolução de oito distintos problemas de classificação. O ambiente do projeto funciona para comparação entre redes neurais artificiais no contexto de residências inteligentes, utilizando modelos de treinamento *offline* e um modelo de névoa como alternativa para o modelo em nuvem.

O conjunto de dados utilizados foi separado por cômodo da residência inteligente. A distribuição foi feita conforme o número de sensores, número de atividades ou classes, número total de amostras e porcentagem de amostras que representam um valor de atividade. A Tabela 1 apresenta o conjunto inicial dos dados.

Tabela 1 – Sumário do conjunto de dados utilizado nos experimentos

Cômodo	Número de sensores	Número de atividades ou classes	Total de amostras	Atividade
Entrada	55	2	30216	2.34%
Escadaria	51	2	33629	2.83%
Banheiro	68	4	36860	18.82%
Sala de estar	80	4	120598	18.83%
Toalete	47	1	28947	0.33%
Escritório	62	3	104290	84.24%
Cozinha	94	4	69417	10.46%
Quarto	76	4	45405	19.46%

Fonte: Adaptado de Mamann *et al.* (2022).

Deste conjunto de dados, foi escolhido o ambiente da cozinha para análise, devido ao maior número de sensores e atividades ou classes disponíveis. Foram utilizadas 4000 amostras por teste, sendo que quaisquer um dos ambientes listados na tabela apresenta um volume maior de dados que poderia ser utilizado.

O escopo deste trabalho consiste na implementação dos ambientes de testes em névoa e nuvem, os quais foram utilizados para execução dos testes de acordo com as configurações apresentadas nesta seção.

4.1 Materiais

O principal componente eletrônico utilizado neste trabalho foi um microprocessador, pois nele são realizados os cálculos dos dados pela rede neural do tipo online. Foram utilizados dois dispositivos, conforme a Tabela 2.


Tabela 2 – Especificação técnica dos processadores utilizados

Marca	Intel®	ARM®
Modelo	I7-8565U	Cortex®-A72
Número de núcleos	8	4
Frequência	1.80 GHZ	1.50 GHZ
Litografia	14 nm	16 nm

Fonte: Autoria própria (2022).

O processador da marca Intel® é referente a um computador portátil. O processador da marca ARM® é referente a um Raspberry Pi 4 Modelo B. A Figura 7 apresenta uma foto do microcontrolador.

Figura 7 – Raspberry Pi 4 Modelo B



Fonte: Adaptado de Raspberry (2022).

4.2 Métodos

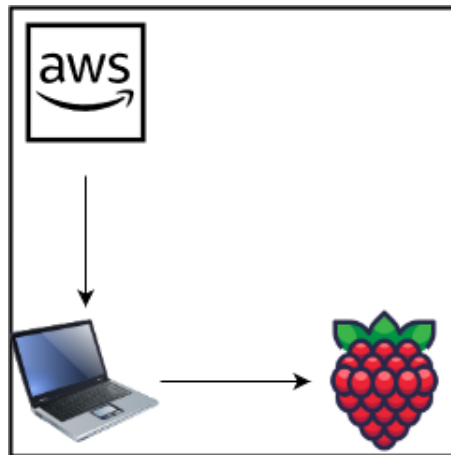
Para a realização dos experimentos de aprendizado online, foi utilizado um ambiente real, com configurações padronizadas para simular diferentes configurações de quantidade de memória e taxa de amostras enviadas, sendo distribuídos da seguinte forma:

- Um com maior capacidade de processamento, para simular uma plataforma em nuvem.

- Um com menor capacidade de processamento, para simular um sistema de névoa.

Para o cenário de nuvem, os dados foram enviados da região leste dos Estados Unidos, Norte da Virgínia, para um computador local no Brasil na cidade de Curitiba. Esses dados foram utilizados no notebook pela rede neural com o processador da marca Intel® conforme Tabela 2. No cenário de névoa os dados foram trocados entre dois dispositivos dentro de uma rede local e utilizados pela rede neural no microcontrolador Raspberry com processador da marca ARM®. A Figura 8 demonstra o sentido do envio dos dados entre os dispositivos.

Figura 8 – Diagrama AWS



Fonte: Autoria própria (2022).

Neste trabalho foram utilizados dois parâmetros para controle, a taxa T na qual os dados são enviados de sensores para sistemas de névoa e nuvem, e quantidade de memória M considerada para cada componente, que pode ser menos restritiva na nuvem comparado a névoa. Além destes dois parâmetros de controle, existem dois fatores adicionais que afetam o desempenho do sistema que não são possíveis de se controlar. Primeiro, há um atraso que ocorre na comunicação entre os sistemas, principalmente para a nuvem, onde a comunicação ocorre principalmente pela internet. Em segundo lugar, a capacidade real do processador. Embora não seja diretamente controlado pelo usuário, geralmente o processador do servidor em nuvem é considerado superior ao disponível para computação em névoa.

No caso da aprendizagem online, o tempo de treinamento é um critério importante, pois o sistema é executado em pequenos valores de tempo de amostragem. Assim, diferentemente do treinamento offline, ao adaptar os pesos na forma online, as propostas utilizam cada amostra assim que chega e a experiência passada pode ser completamente perdida, pois o fluxo de dados pode fornecer novos dados quando não há memória suficiente para armazenar todos os padrões.

Visando comparar ambos os sistemas sob diferentes condições de sensores e componentes de redes neurais, foram consideradas seis combinações de tamanhos de *buffer* de memória, com os valores $M = 1000, 100$ e 10 e taxas de transmissão $T = 2,5, 1,25, 0,83$ amos-

tras por segundo. Foram utilizadas 4000 mil amostras de dados por teste, sendo que o teste foi executado 3 vezes para cada cenário, e o valor apresentado é o da média das tentativas.

O código para envio e recebimento dos dados foi escrito em linguagem de programação *Python*. O sistema operacional utilizado foi o Linux.

5 RESULTADOS

Para a obtenção dos resultados deste trabalho, foram definidos seis cenários comparativos entre névoa e nuvem, com variações em quantidades de amostras enviadas por segundo e memória, com o objetivo de avaliar se estes fatores, somados ao tempo que os dados levam para trafegar pela rede, poderiam influenciar de forma significativa a implementação de um sistema de automação residencial conectado a névoa ou nuvem.

Como dispositivos de computação em névoa geralmente possuem menos memória do que servidores utilizados para computação em nuvem, foi estabelecida uma relação de dez vezes a quantidade de memória entre névoa e nuvem. Estes valores foram limitados manualmente, para que fosse possível comparar os dados. Se fosse utilizada toda a memória do dispositivo de internet das coisas e do servidor em nuvem, a relação de quantidade de memória seria diferente do valor atribuído.

A taxa de envio dos dados foi padronizada com três valores diferentes de amostras por segundo, para se ter uma base de comparação. Se fosse utilizada toda a capacidade de envio de dados dos dispositivos, os resultados obtidos seriam diferentes devido às variações de processamento e rede durante os testes.

Para o cálculo da performance do sistema de inteligência artificial, foi utilizado o F-Score, que é uma média calculada utilizando os dados de precisão e sensibilidade da rede neural. Esta métrica é utilizada para determinar se os valores de acerto ou erro da rede são confiáveis.

A Tabela 3 mostra os tempos médios em segundos gastos por diferentes configurações de topologia para processar cada amostra de teste. Como esperado, o tempo médio para processar cada amostra no sistema de névoa é maior, quase duas vezes, do que na nuvem. O tempo parece ser afetado principalmente pela capacidade de processamento, que é significativamente menor. No entanto, o sistema de névoa parece ser mais robusto a mudanças em M e T do que na nuvem. Enquanto na nuvem, quando a memória aumenta 10 vezes, os ganhos relativos de tempo são de aproximadamente 20%, 10% e 6% para as três taxas de T, em névoa os ganhos relativos correspondentes são menores e quase constantes, de 4%, 4%, e 1% para todo o T.


Tabela 3 – Treinamento Online: resultados para as diferentes combinações de configurações

Combinações	T (amostras/s)	Memória Nuvem(M)	Tempo Nuvem(s)	Memória Névoa(M)	Tempo Névoa(s)
Alto T com baixo M	2.5	100	1.43	10	2.43
Alto T com alto M	2.5	1000	1.14	100	2.34
Médio T com médio baixo M	1.25	100	1.22	10	2.36
Médio T com alto M	1.25	1000	1.1	100	2.27
Baixo T com baixo M	0.83	100	1.2	10	2.31
Baixo T com alto M	0.83	1000	1.31	100	2.28

Fonte: Adaptado de Mamann *et al.* (2022).

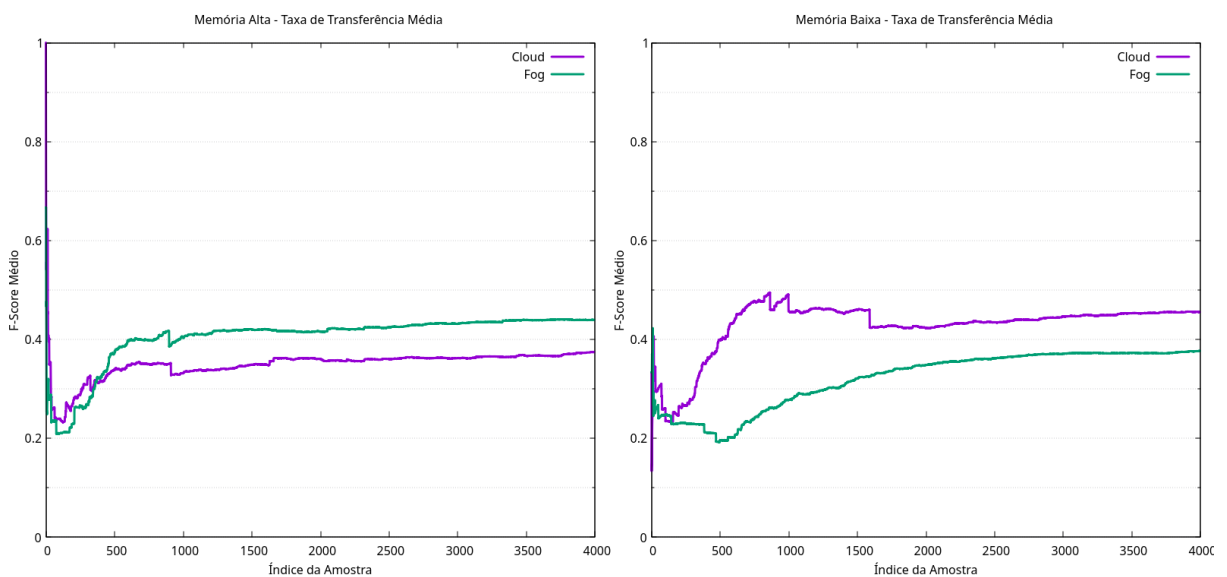
A performance do sistema testado é determinada pelo F-Score médio pelo total de amostras, conforme Figuras 9, 10 e 11.

Figura 9 – F-Score médio para memória alta e baixa com taxa de transferência alta



Fonte: Adaptado de Mamann *et al.* (2022).


Figura 10 – F-Score médio para memória alta e baixa com taxa de transferência média



Fonte: Adaptado de Mamann *et al.* (2022).

Nas Figuras 12, 13 e 14, escritas em escala logarítmica para permitir a comparação entre névoa e nuvem, está apresentado o número médio de vezes que cada amostra é treinada novamente. É importante destacar que cada amostra de *streaming* é primeiro testada e depois treinada e retreinada quantas vezes for possível, até que o *buffer* de memória M fique cheio e as


Figura 11 – F-Score médio para memória alta e baixa com taxa de transferência baixa



Fonte: Adaptado de Mamann *et al.* (2022).

amostras mais antigas comecem a ser descartadas. Quanto maior a quantidade de memória, maior o tempo para que seja preenchido o *buffer* de memória, e após o processo de descarte ser iniciado o número de retreinamento por amostra pode ser calculado.

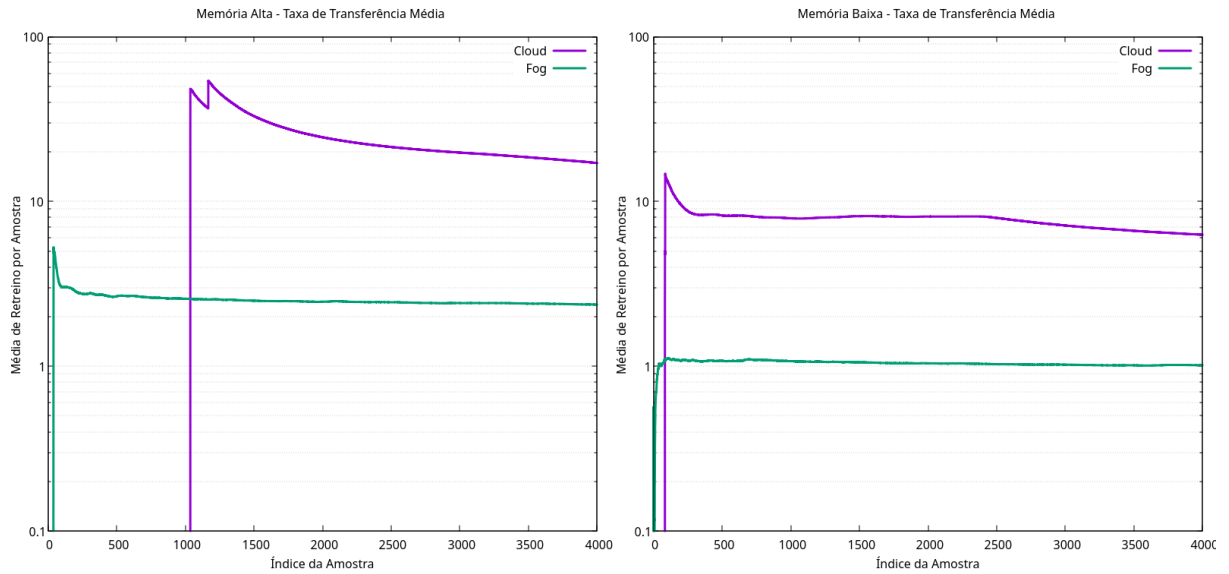
Figura 12 – Média de retreino por amostra para memória alta e baixa com taxa de transferência alta



Fonte: Adaptado de Mamann *et al.* (2022).


O pico inicial nos gráficos, indicando um número maior de repetições, ocorre porque as primeiras rodadas de treinamento levam menos tempo para serem concluídas, pois possuem menos exemplos para serem executados. Após este período, as curvas tendem a se tornar está-

Figura 13 – Média de retreino por amostra para memória alta e baixa com taxa de transferência média



Fonte: Adaptado de Mamann *et al.* (2022).

Figura 14 – Média de retreino por amostra para memória alta e baixa com taxa de transferência baixa



Fonte: Adaptado de Mamann *et al.* (2022).

veis, e o valor de F-Score de estabilização representa o gargalo da capacidade do processador para esse equipamento. Como esperado, em todos os cenários o ambiente de nuvem foi capaz de treinar cada amostra mais vezes, variando de 4 a 10 vezes, devido ao seu processador mais potente e maior quantidade de memória.

5.1 Discussões

Levando em consideração todos os resultados, podemos notar que, embora as redes neurais executadas em névoa levam um tempo maior para processar amostras e convergir, elas estabilizam em um nível de desempenho semelhante. Isso significa que a quantidade de retreinamento dos dados tem baixo impacto no resultado final ao longo do tempo, ou seja, um sistema de névoa mais barato pode ser usado como substituto ou suporte para uma solução em nuvem, conseguindo alcançar um desempenho comparável.

Também, é importante saber quais são os padrões de uso de uma residência inteligente, para que seja possível prover uma experiência mais adequada ao usuário. Diferentes padrões de comportamento podem levar a resultados mais ou menos precisos. Um dos fatores que são analisados quando se insere um sistema de inteligência artificial para melhorar as respostas é de que o resultado final seja mais preciso que um sistema configurado de forma estática, que funciona sem variações conforme o tempo.

Outro fator a ser analisado é que sistemas em nuvem podem trazer custos mais altos e dificultar tomadas de decisão em tempo real, então é necessário definir qual o objetivo dos sistemas em névoa e nuvem neste contexto, para que seja dimensionado conforme a real necessidade do ambiente. Se o tamanho final do sistema e a quantidade de processamento utilizado for maior do que é possível se implementar em um ambiente local, pode-se avaliar a utilização de nuvem.

6 CONCLUSÃO

Este trabalho comparou o desempenho entre névoa e nuvem utilizando dados coletados de uma situação real de automação residencial. O tempo médio de processamento por amostra no sistema em névoa foi quase duas vezes maior do que na nuvem, sendo afetado principalmente pela menor capacidade de processamento. A quantidade de memória e taxa de envio das amostras interferiu de forma menos significativa em névoa do que em nuvem. No sistema em nuvem, quando a quantidade de memória aumentava 10 vezes, os ganhos de tempo variavam entre 6% a 20%; já em névoa, os ganhos relativos são menores e quase constantes, variando de 1% a 4%.

Considerando as características de treinamento e execução das redes neurais artificiais para se determinar a melhor configuração de uso de computação em névoa e nuvem, no modelo de aprendizagem online, a topologia proposta em névoa foi capaz de obter um desempenho comparável com a computação em nuvem, mesmo utilizando muito menos amostras retreinadas. Esse resultado demonstra que podem ser reduzidos os custos de infraestrutura em computação em nuvem.

Em ambientes locais, pode ser analisada a viabilidade do uso da computação em névoa, reduzindo a dependência da internet e sua latência, com isso possibilitando a criação de novas aplicações com alta demanda de respostas em tempo real.

Como referência para trabalhos futuros, pode-se implementar a atual proposta utilizando somente ambientes reais, com a quantidade de memória e número de amostras enviadas sendo limitada pela capacidade real dos dispositivos, não por valores configurados.

Outra implementação possível seria utilizar um sistema que faça o ordenamento, validação e retransmissão dos dados perdidos durante o tráfego na rede, para garantir que todas as amostras sejam de fato utilizadas pelo sistema.

Caso os dados utilizados sejam considerados sensíveis, é necessário a implementação de medidas de segurança para o armazenamento, transmissão e uso das informações, utilizando tecnologias como criptografia de dados e autenticação dos usuários.

REFERÊNCIAS

- ALESSANDRO, P. **Hands-On Artificial Intelligence for Cybersecurity : Implement Smart AI Systems for Preventing Cyber Attacks and Detecting Threats and Network Anomalies**. Packt Publishing, 2019. ISBN 9781789804027. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=e000xww&AN=2225815&lang=pt-br&site=eds-live&scope=site>.
- BONOMI, F. *et al.* Fog computing and its role in the internet of things. 2012. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsair&AN=edsair.doi.....0627ceb165f184e168004081dbb57aba&lang=pt-br&site=eds-live&scope=site>.
- BUTLER, B. What is fog computing? connecting the cloud to things. **Network World**, 2018. ISSN 0887-7661. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsgao&AN=edsgcl.561589708&lang=pt-br&site=eds-live&scope=site>.
- DASTJERDI, A.; BUYYA, R. Fog computing: Helping the internet of things realize its potential. **Computer**, v. 49, n. 8, p. 112 – 116, 2016. ISSN 0018-9162. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsee&AN=edsee.7543455&lang=pt-br&site=eds-live&scope=site>.
- DIEGO, M. Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e f-score. 2021. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsair&AN=edsair.doi.....14e71b491149af27ecae171ec0ce6f14&lang=pt-br&site=eds-live&scope=site>.
- GILLIS, A. S. **What is the internet of things (IoT)?** 2022. Disponível em: <https://www.techtarget.com/iotagenda/definition/Internet-of-Things-IoT>. Acesso em: 21 ago. 2022.
- GOMES, E. H. A. **Uma Abordagem Orientada à Observação Temporal de Aplicações Distribuídas Baseadas em IoT e Configuração de Fog Computing**. dez. 2021. 109 p. Tese (Doutorado) — Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de Santa Catarina, Florianópolis, dez. 2021.
- GOYAL, A.; GARG, R.; BHATIA, K. K. Models and challenges categorization in cloud computing. **2021 International Conference on Computing Sciences (ICCS), Computing Sciences (ICCS), 2021 International Conference on, ICCS**, p. 34 – 37, 2021. ISSN 978-1-6654-9445-8. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsee&AN=edsee.9784682&lang=pt-br&site=eds-live&scope=site>.
- GRANJAL, J.; MONTEIRO, E.; SILVA, J. S. Security for the internet of things: A survey of existing protocols and open research issues. **IEEE Communications Surveys I& Tutorials, Communications Surveys I& Tutorials, IEEE, IEEE Commun. Surv. Tutorials**, v. 17, n. 3, p. 1294 – 1312, 2015. ISSN 1553-877X. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsee&AN=edsee.7005393&lang=pt-br&site=eds-live&scope=site>.
- HELM, J. M. *et al.* Machine learning and artificial intelligence: Definitions, applications, and future directions. **Current Reviews in Musculoskeletal Medicine**, v. 13, n. 1, p. 69, 2020. ISSN 1935-9748. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsgao&AN=edsgcl.628349271&lang=pt-br&site=eds-live&scope=site>.

- INDÚSTRIA 4.0 : conceitos e fundamentos. Blucher, 2018. ISBN 9788521213703. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsmib&AN=edsmib.000016245&lang=pt-br&site=eds-live&scope=site>.
- MACHADO, J. d. S. Implementação de uma fog computing para fornecer staas a dispositivos iot utilizando sistemas embarcados. 2018. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsair&AN=edsair.od.....3056..8d8fa28bed4b86375f49c8c4b664d16a&lang=pt-br&site=eds-live&scope=site>.
- MAMANN, L. V. S. D. *et al.* Offline and online neural network learning in the context of smart homes and fog computing. **11th Brazilian Conference on Intelligent Systems (BRACIS)**, 2022.
- MOHAMMAD, S. A. *et al.* A survey of artificial intelligence challenges: Analyzing the definitions, relationships, and evolutions. **Applied Sciences**, v. 12, n. 4054, p. 4054, 2022. ISSN 2076-3417. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsdoj&AN=edsdoj.9de44e4b3a8f431eb1e7d8e7c49646f7&lang=pt-br&site=eds-live&scope=site>.
- PETER, M.; TIMOTHY, G. The nist definition of cloud computing. 2015. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsair&AN=edsair.doi.....57ce1ed7ce3f964ada9a9f49dc32df54&lang=pt-br&site=eds-live&scope=site>.
- RASPBERRY, F. **Raspberry Pi 4**. 2022. Site Raspberry Pi ORG. Disponível em: <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/>. Acesso em: 31 oct. 2022.
- REHMAN, T. B. **Cloud Computing Basics**. Mercury Learning & Information, 2018. ISBN 9781683923503. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=e000xww&AN=1991380&lang=pt-br&site=eds-live&scope=site>.
- RIBEIRO, A. de R. L.; SA, A. R. de; BARRETO, B. N. A fog computing architecture for security and quality of service. **Position Papers of the 2019 Federated Conference on Computer Science and Information Systems**, 2019. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsair&AN=edsair.doi.....c4ba8d88bb49cda7087f93001bc2d129&lang=pt-br&site=eds-live&scope=site>.
- ROSS, A. B. **USO DA COMPUTAÇÃO EM NÉVOA PARA COLETA E ANÁLISE DE DADOS EM CIDADES INTELIGENTES**. dez. 2019. 81 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Curitiba, dez. 2019.
- S., G. N. *et al.* Fog computing conceptual model. 2018. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsair&AN=edsair.doi.....720747c116517779ae9a91aed5f36f25&lang=pt-br&site=eds-live&scope=site>.
- SHARDA, R. **Business intelligence e análise de dados para gestão do negócio**. Bookman, 2019. ISBN 9788582605196. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=edsmib&AN=edsmib.000016336&lang=pt-br&site=eds-live&scope=site>.