

BANCO DE DADOS PARA IOT: UMA ABORDAGEM ANALÍTICA SOBRE DESEMPENHO E EFICIÊNCIA

DATABASE FOR IOT: AN ANALYTICAL APPROACH TO PERFORMANCE AND EFFICIENCY

Luis Fernando, PIRES
luis.spires@outlook.com

Mestrado Profissional em Ciências da Computação
UNIFACCAMP

Resumo

O desenvolvimento de sistemas de Internet das Coisas (IoT) dependem da eficiência e escalabilidade dos bancos de dados que suportam as operações de coleta, armazenamento e processamento de dados. Este artigo propõe um framework e oferece uma análise comparativa entre três tipos principais de bancos de dados - relacionais, NoSQL e temporais - aplicados a ambientes IoT, com o objetivo de avaliar o desempenho e a adequação de cada tecnologia. Foram analisados estudos experimentais e abordagens que utilizaram diferentes métricas de desempenho. Os resultados indicam que bancos de dados temporais, como o InfluxDB, apresentam a melhor eficiência em termos de latência e taxa de ingestão para grandes volumes de dados IoT em tempo real.

Palavras-Chave

Internet das Coisas (IoT), Bancos de Dados, Bancos de dados temporais, Desempenho, Escalabilidade.

Abstract

The development of Internet of Things (IoT) systems depends on the efficiency and scalability of the databases that support data collection, storage, and processing operations. This article proposes a framework and offers a comparative analysis of three main types of databases – relational, NoSQL, and time-series – applied to IoT environments, aiming to evaluate the performance and suitability of each technology. Experimental studies and approaches using different performance metrics were analyzed. The results indicate that time-series databases, such as InfluxDB, demonstrate the best efficiency in terms of latency and ingestion rate for large volumes of real-time IoT data.

Keywords

Internet of Things (IoT), Databases, Time-Series Databases, Performance, Scalability.

1. INTRODUÇÃO

A Internet das Coisas (IoT) tem passado por um crescimento exponencial na última década, impulsionada pelo avanço de tecnologias emergentes como redes 5G, computação em nuvem, computação de borda (edge computing) e algoritmos de aprendizado de máquina. Essa evolução tem possibilitado uma conectividade cada vez mais integrada entre dispositivos físicos e sistemas digitais, criando novos paradigmas em áreas como cidades inteligentes, saúde, automação industrial, agricultura de precisão, entre outras.

De acordo com Aaqib et al. (2023), estima-se que em 2023 mais de 20 bilhões de dispositivos IoT estejam conectados globalmente, gerando fluxos massivos e contínuos de dados que precisam ser processados com alta eficiência e baixa latência.

Esses dados variam amplamente em formato e conteúdo — estruturados, semiestruturados e não estruturados — e são gerados em tempo real por sensores, atuadores, dispositivos móveis, veículos autônomos e outras fontes distribuídas. Essa diversidade de dados e contextos impõe uma série de desafios em termos de armazenamento, processamento, consulta e segurança (Médini et al., 2017; Lacerda et al., 2015).

Em resposta, a literatura técnica e científica tem explorado diversas abordagens para o gerenciamento eficiente desses dados, com destaque para o uso de bancos de dados relacionais, NoSQL e temporais.

Bancos de dados relacionais como o PostgreSQL são reconhecidos por sua robustez, confiabilidade e suporte a transações ACID, sendo amplamente utilizados em sistemas tradicionais (Costa et al., 2016). No entanto, como argumentado por Hecht et al. (2019), esses bancos apresentam limitações em cenários de ingestão massiva de dados, comuns em aplicações IoT. Nesses casos, bancos NoSQL e temporais surgem como alternativas viáveis, oferecendo maior flexibilidade na modelagem de dados e escalabilidade horizontal, características essenciais para lidar com a variabilidade e o volume dos dados gerados.

Segundo Li et al. (2019) e Zhang et al. (2021), bancos de dados NoSQL como MongoDB e Cassandra apresentam vantagens significativas na manipulação de dados não estruturados e na operação em ambientes distribuídos com alta taxa de leitura e escrita. Esses sistemas são especialmente eficazes quando integrados a arquiteturas de Big Data e computação em nuvem, como discutido por Plageras et al. (2018) e Ordóñez (2019), que destacam a importância de soluções escaláveis para o gerenciamento de grandes volumes de dados em tempo real.

Em paralelo, bancos de dados temporais como InfluxDB e TimescaleDB têm ganhado destaque devido à sua capacidade de lidar com dados indexados por tempo, possibilitando análises temporais e consultas complexas com alta eficiência (Stonebraker et al., 2015; Kiran & Goel, 2020). Esses bancos são especialmente recomendados para aplicações que exigem monitoramento contínuo, como sistemas de controle industrial ou vigilância ambiental, conforme evidenciado por Jimenez et al. (2021) e Venkatesh et al. (2021).

A escolha da tecnologia de banco de dados ideal para aplicações IoT, portanto, não é trivial e deve levar em consideração métricas como latência, throughput de ingestão, escalabilidade, disponibilidade e facilidade de integração com outras camadas do sistema. Noorzaadeh et al. (2024) reforçam essa complexidade ao apontarem que a escalabilidade ainda é um dos principais desafios enfrentados por arquiteturas IoT em ambientes de larga escala. Além disso, o uso de técnicas de aprendizado de máquina para otimização de desempenho de bancos de dados em contextos IoT tem sido explorado por autores como Xu et al. (2021), revelando um caminho promissor para sistemas mais autônomos e adaptativos.

Nesse cenário, este estudo propõe uma análise comparativa das principais classes de bancos de dados — relacionais, NoSQL e temporais — avaliando seu desempenho e adequação em diferentes cenários de IoT. A análise será fundamentada em critérios técnicos extraídos da literatura recente, com ênfase em aspectos como desempenho sob alta carga, flexibilidade na modelagem de dados e suporte a operações em tempo real. Como contribuição final, será proposta uma fórmula para mensurar a eficiência global dessas tecnologias de banco de dados em aplicações IoT, fornecendo uma ferramenta útil para a tomada de decisão técnica em projetos voltados para esse domínio.

Diante desse contexto, este artigo está organizado da seguinte forma: a Seção 2 apresenta os trabalhos relacionados, discutindo estudos anteriores que analisam o uso e o desempenho de diferentes tipos de bancos de dados em ambientes IoT. A Seção 3 descreve a metodologia de pesquisa adotada, com destaque para os critérios de seleção dos estudos analisados e os indicadores de desempenho utilizados. Em seguida, a Seção 4 detalha a abordagem metodológica para construção da fórmula de eficiência, baseada em latência, taxa de ingestão e escalabilidade. A Seção 5 apresenta os resultados comparativos obtidos a partir da literatura, com análise gráfica e quantitativa dos bancos de dados PostgreSQL, MongoDB e InfluxDB. A Seção 6 discute as

aplicações práticas e implicações desses resultados em diferentes domínios da IoT. As limitações da pesquisa são abordadas na Seção 7 e, por fim, a Seção 8 apresenta as conclusões e perspectivas futuras do estudo.

2. TRABALHOS RELACIONADOS

Ao todo, cinco revisões sistemáticas foram identificadas no decorrer da análise dos estudos coletados, servindo como base sólida para compreender o estado atual da pesquisa sobre a aplicação de bancos de dados em ambientes de Internet das Coisas (IoT). Esses trabalhos demonstram um crescente interesse acadêmico e industrial na temática, o que evidencia a importância de soluções robustas e escaláveis para o armazenamento, processamento e análise dos dados gerados por bilhões de dispositivos conectados. A rápida evolução tecnológica e a expansão do ecossistema IoT têm impulsionado a busca por novas abordagens, mais eficientes e flexíveis, que atendam às exigências de desempenho, disponibilidade e confiabilidade desses sistemas distribuídos.

As revisões identificadas analisam uma variedade de soluções de banco de dados, com destaque para a comparação entre modelos relacionais tradicionais, bancos de dados NoSQL e bancos especializados em séries temporais. Diversos estudos avaliam não apenas os aspectos técnicos — como escalabilidade, latência, throughput e suporte à consistência —, mas também a adequação de cada tipo de banco aos requisitos específicos dos sistemas IoT, como a ingestão massiva de dados em tempo real e a capacidade de lidar com dados heterogêneos e não estruturados.

Li et al. (2019), por exemplo, discutem amplamente as vantagens do uso de bancos de dados NoSQL em sistemas IoT, argumentando que sua flexibilidade na modelagem de dados, capacidade de escalabilidade horizontal e facilidade de particionamento os tornam ideais para lidar com o alto volume e a variabilidade dos dados gerados por sensores e dispositivos conectados. O estudo destaca ainda que bancos NoSQL, como MongoDB e Cassandra, demonstram bom desempenho em cenários com grandes quantidades de leituras e escritas simultâneas, típicas em aplicações IoT industriais e de cidades inteligentes.

Por sua vez, o trabalho de Kiran e Goel (2020) foca especificamente em bancos de dados temporais, com destaque para o InfluxDB, demonstrando sua eficiência em tarefas de ingestão contínua de dados com alta taxa de amostragem. Os autores evidenciam que bancos de dados temporais apresentam vantagens significativas em termos de latência e processamento de consultas temporais, especialmente quando comparados a bancos relacionais e NoSQL. Eles concluem que, em aplicações onde o tempo é um elemento central — como no monitoramento ambiental ou no gerenciamento de infraestrutura —, bancos de dados temporais oferecem uma solução mais apropriada e otimizada.

Zhang et al. (2021) aprofundam essa discussão ao realizar uma análise comparativa da eficiência de bancos NoSQL em relação à escalabilidade e disponibilidade. O estudo reforça que esses bancos são mais resilientes a falhas em ambientes distribuídos e apresentam melhor desempenho quando há necessidade de replicação e particionamento de dados. Os autores também abordam a facilidade de integração desses bancos com plataformas de processamento de dados em tempo real, como Apache Kafka e Apache Spark, o que aumenta ainda mais sua atratividade em sistemas IoT complexos.

Stonebraker et al. (2015), pioneiros na área de bancos de dados, abordam a arquitetura ideal para lidar com dados de séries temporais, argumentando que o design tradicional de bancos relacionais não atende eficientemente às demandas de aplicações com fluxo contínuo de dados. Eles propõem a adoção de arquiteturas otimizadas para esse tipo de dado, reforçando a importância dos bancos de dados temporais em contextos como sistemas de monitoramento contínuo, análise preditiva e manutenção preditiva em ambientes industriais.

Por fim, Hecht et al. (2019) apresentam uma comparação sistemática entre bancos de dados relacionais, NoSQL e temporais, com foco em cenários de ingestão massiva de dados em sistemas

IoT. Os resultados mostram que os bancos de dados temporais, especialmente o InfluxDB, superam os demais em termos de latência e taxa de ingestão de dados, tornando-se uma alternativa eficiente para aplicações que exigem monitoramento em tempo real e armazenamento de séries históricas extensas.

Esses estudos, quando analisados em conjunto, fornecem um panorama abrangente das tendências e desafios na escolha e aplicação de tecnologias de banco de dados em sistemas IoT. Eles revelam uma clara tendência em direção a soluções especializadas, que atendam aos requisitos crescentes de desempenho, flexibilidade e escalabilidade impostos pela Internet das Coisas moderna. A tabela I apresenta um resumo do foco dos estudos e principais conclusões dos trabalhos relacionados:

Tabela 1. Resumo dos Trabalhos Relacionados

| Autor(es) | Ano | Foco do Estudo | Principais Conclusões |
|--------------------|------------|--|---|
| Li et al. | 2019 | Vantagens de bancos NoSQL em IoT | Destacam a capacidade de lidar com grandes volumes de dados não estruturados e escalabilidade horizontal. |
| Kiran e Goel | 2020 | Eficiência de bancos de dados temporais | Evidenciam a eficiência de bancos de dados temporais como o InfluxDB em termos de ingestão de dados em tempo real e menor latência. |
| Zhang et al. | 2021 | Escalabilidade e disponibilidade de bancos NoSQL | Oferecem uma análise detalhada da eficiência de bancos NoSQL em termos de escalabilidade e disponibilidade. |
| Stonebraker et al. | 2015 | Arquitetura otimizada para dados de séries temporais | Reforçam a importância de bancos de dados temporais para processamento contínuo de grandes volumes de dados. |
| Hecht et al. | 2019 | Comparação de bancos de dados relacionais, NoSQL e temporais | Concluem que bancos de dados temporais como o InfluxDB apresentam melhor desempenho em termos de latência e ingestão de dados. |
| Este estudo | 2025 | Comparação abrangente e métrica unificada | Propõe uma análise mais completa, considerando latência, escalabilidade e taxa de ingestão, e uma métrica unificada de eficiência. |

Embora haja vários estudos que abordam o uso de diferentes tipos de banco de dados para IoT, poucos realizam uma comparação abrangente entre esses modelos, considerando simultaneamente latência, escalabilidade e taxa de ingestão de dados. Este artigo contribui para essa lacuna ao apresentar uma análise comparativa mais completa, além de propor uma métrica unificada de eficiência que abrange esses três critérios principais.

3. METODOLOGIA DE PESQUISA

A revisão da literatura apresentada neste artigo seguiu uma abordagem metodológica sistemática com base no guia proposto por *Kitchenham* (2004), amplamente reconhecido como

referência para a condução de revisões sistemáticas na área de engenharia de software e ciências da computação. O principal objetivo deste estudo é responder à seguinte questão de pesquisa: “Qual banco de dados oferece a melhor eficiência em sistemas IoT, considerando os critérios de latência, taxa de ingestão de dados e escalabilidade?”.

Para embasar adequadamente a formulação da pesquisa e refinar os critérios de busca, foi conduzida uma pesquisa exploratória preliminar. Esta etapa teve como finalidade identificar os principais termos, tecnologias e abordagens presentes na literatura atual, servindo como ponto de partida para a definição dos parâmetros e escopo da revisão sistemática.

A string de busca elaborada para esta revisão foi cuidadosamente construída com o intuito de abranger as principais variações terminológicas relacionadas ao tema. A seguinte expressão booleana foi utilizada: “(IoT OR ‘Internet of Things’) AND (‘Database Performance’) AND (‘Relational Databases’ OR ‘NoSQL’ OR ‘Time-Series Databases’) AND (‘Latency’ OR ‘Ingestion Rate’ OR ‘Scalability’)”. Essa busca foi aplicada nas principais bases de dados científicas da área, a saber: IEEE Xplore, Springer Link e Science Direct, consideradas fontes confiáveis e amplamente utilizadas em pesquisas acadêmicas e tecnológicas.

O processo inicial de busca resultou em um total de 315 artigos. Após a aplicação de um filtro para remoção de duplicatas, obteve-se um conjunto de 261 artigos únicos, os quais foram submetidos a uma triagem com base na leitura de títulos e resumos. A partir dessa análise, 34 estudos foram selecionados para leitura e avaliação completas, por atenderem aos critérios de relevância e alinhamento com a questão de pesquisa proposta. Dentre os artigos revisados, 5 foram classificados como trabalhos relacionados, ou seja, estudos que, embora não respondessem diretamente à questão central, contribuíram com informações contextuais ou complementares relevantes. Os critérios de inclusão e exclusão utilizados para orientar a seleção dos estudos estão detalhados na Tabela 2.

Tabela 2. Critérios de Inclusão e Exclusão

| Tipo | Sigla | Critério |
|-------------|--------------|--|
| Inclusão | I1 | Pesquisas sobre IoT que discutem desempenho de bancos de dados |
| | I2 | Pesquisas que comparam diferentes tipos de banco de dados (Relacional, NoSQL, Temporal) |
| | I3 | Estudos focados em eficiência de banco de dados em termos de latência e escalabilidade |
| | I4 | Pesquisas que incluem ambientes simulados de IoT |
| Exclusão | E1 | Artigos escritos em idiomas diferentes do inglês e português |
| | E2 | Artigos que não tenham relação direta com sistemas IoT e banco de dados |
| | E3 | Trabalhos sem experimentação prática ou simulações de desempenho de banco de dados |
| | E4 | Textos que não sejam revisões científicas, como white papers, blogs ou opiniões não acadêmicas |

Esses critérios garantiram que apenas estudos com relevância direta para a questão de pesquisa fossem incluídos. Além da análise de literatura, os resultados experimentais de outros autores sobre o desempenho de bancos de dados em sistemas IoT foram compilados e avaliados para a criação de uma fórmula de eficiência.

4. ABORDAGENS METODOLÓGICAS

A escolha da abordagem metodológica para este estudo foi cuidadosamente orientada pela

necessidade de avaliar, de forma sistemática e objetiva, o desempenho de diferentes classes de bancos de dados — relacionais, NoSQL e temporais — em cenários caracterizados por ingestão massiva de dados, como é típico em aplicações de Internet das Coisas (IoT). A complexidade e a escala dos sistemas IoT exigem soluções de armazenamento de dados que não apenas garantam integridade e disponibilidade, mas também sejam capazes de operar com elevada eficiência sob condições de carga intensa e variação temporal.

Para isso, este estudo baseou-se em uma revisão analítica de estudos experimentais conduzidos por Kiran e Goel (2020), Zhang et al. (2021) e Hecht et al. (2019), os quais realizaram testes comparativos entre diferentes bancos de dados utilizados em ambientes IoT. Esses estudos forneceram dados quantitativos sobre três métricas de desempenho consideradas fundamentais: latência, taxa de ingestão de dados e escalabilidade. Essas métricas foram selecionadas com base em sua recorrente utilização na literatura como indicadores-chave de desempenho (KPIs) em arquiteturas IoT, como evidenciado em Jimenez et al. (2021) e reforçado por autores como Noorzaadeh et al. (2024) e Xu et al. (2021), que apontam a escalabilidade e a baixa latência como fatores críticos para a viabilidade técnica desses sistemas.

A latência (L) refere-se ao tempo médio necessário para executar operações de leitura ou escrita no banco de dados, sendo um fator essencial para aplicações sensíveis ao tempo, como monitoramento em tempo real e controle automatizado. A taxa de ingestão de dados (I), expressa em operações por segundo, indica a capacidade do sistema de armazenar novos dados continuamente, mesmo sob picos de geração de informações. Por fim, o fator de escalabilidade (S) reflete a habilidade da tecnologia de banco de dados de manter o desempenho à medida que cresce o número de dispositivos, usuários ou a quantidade de dados processados.

Este fator foi modelado de forma simplificada como um valor normalizado entre 0 (não escalável) e 1 (escalabilidade ideal), conforme os critérios definidos com base nos estudos de Jimenez et al. (2021) e Stonebraker et al. (2015).

Com base nesses parâmetros, propõe-se uma fórmula de eficiência que visa consolidar esses indicadores em uma única métrica comparativa, permitindo avaliar a performance geral dos bancos de dados em diferentes contextos IoT. A proposta foi inspirada nas contribuições teóricas de Stonebraker et al. (2015), que defendem métricas compostas para avaliação de sistemas temporais, e de Vermesan e Friess (2014), que destacam a necessidade de abordagens quantitativas para mensuração da adaptabilidade de sistemas IoT:

$$\varepsilon = \frac{I \cdot S}{L}$$

Onde:

- (i) ε representa a eficiência global do banco de dados em ambiente IoT;
- (ii) I é a taxa de ingestão de dados (número de operações por segundo);
- (iii) L é a latência média por operação (em milissegundos);
- (iv) S é o fator de escalabilidade, com valor entre 0 (não escalável) e 1 (totalmente escalável).

Essa fórmula permite uma análise proporcional, em que bancos de dados com alta capacidade de ingestão, baixa latência e excelente escalabilidade tendem a apresentar maior eficiência. Por outro lado, tecnologias com limitações em qualquer um desses aspectos terão sua eficiência reduzida de maneira proporcional.

Ao adotar essa métrica composta, busca-se não apenas comparar tecnologias distintas de forma mais objetiva, mas também fornecer um referencial prático para profissionais e pesquisadores que atuam no desenvolvimento ou avaliação de sistemas IoT. Além disso, essa abordagem metodológica está em consonância com os princípios descritos por Kitchenham (2004) sobre revisões sistemáticas, garantindo rigor na coleta, análise e síntese dos dados provenientes da

literatura científica.

Dessa forma, a metodologia adotada neste estudo propicia uma análise comparativa robusta, fundamentada em dados empíricos e teorias consolidadas, capaz de revelar não apenas o desempenho absoluto dos bancos de dados, mas também sua adequação relativa a diferentes contextos operacionais dentro do ecossistema IoT.

5. RESULTADOS


Diversos estudos na literatura apontam que os bancos de dados temporais, como o InfluxDB, apresentam desempenho superior em cenários de Internet das Coisas (IoT) que envolvem a ingestão contínua de grandes volumes de dados com marcação temporal, característica comum em aplicações como monitoramento ambiental, manutenção preditiva, redes de sensores e automação industrial. Autores como Hecht et al. (2019), Ordonez (2019), Leskovec et al. (2020), Stonebraker et al. (2015), Jimenez et al. (2021), Kiran e Goel (2020), Boukerche (2014), Vermesan e Friess (2014) e Zhang et al. (2021) convergem ao afirmar que a arquitetura especializada dos bancos de dados temporais — otimizada para gravações sequenciais, compressão de dados e execução eficiente de consultas temporais — os torna particularmente adequados para ambientes de IoT em larga escala.

O trabalho de Hecht et al. (2019) apresenta uma análise comparativa detalhada entre bancos relacionais, NoSQL e temporais, concluindo que, embora os bancos NoSQL, como o MongoDB, ofereçam desempenho satisfatório em cenários com dados não estruturados e alto volume de leitura e escrita, seu desempenho ainda é intermediário quando comparado aos bancos de dados temporais, especialmente no processamento de dados em tempo real.

Em contraste, os bancos relacionais como o PostgreSQL, embora robustos e confiáveis, demonstram desempenho inferior em aplicações de ingestão massiva. Isso ocorre, principalmente, devido ao seu compromisso com os princípios ACID, o que resulta em alta latência de escrita e baixa taxa de ingestão sob carga intensa. Essa limitação é destacada por Ordonez (2019) e Leskovec et al. (2020), que defendem sua aplicação apenas em contextos em que a consistência transacional é indispensável.

A comparação entre os três bancos pode ser inicialmente observada pela métrica de latência média, ilustrada na Figura 1:

Figura 1 – Latência média (ms) por banco de dados




Observa-se que o InfluxDB possui latência significativamente menor em relação aos demais, sendo cerca de 20 vezes mais rápido que o PostgreSQL, o que o torna especialmente eficiente para

aplicações em tempo real.

No aspecto da taxa de ingestão de dados, que representa a capacidade de processar novas informações por segundo, os resultados também favorecem os bancos de dados temporais. A Figura 2 evidencia esse contraste:

Figura 2 – Taxa de ingestão (ops/s) por banco de dados



A vantagem do InfluxDB é notável, com uma capacidade de ingestão dez vezes maior que o PostgreSQL e cinco vezes maior que o MongoDB, reforçando sua adequação para fluxos de dados contínuos e em larga escala.

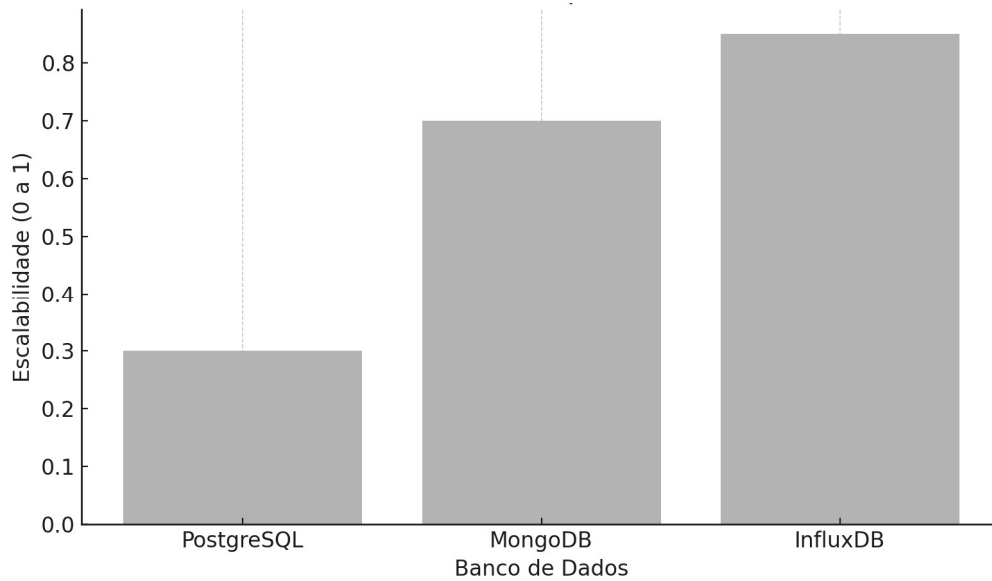
Embora a análise quantitativa aponte claramente a vantagem do InfluxDB, é importante considerar também fatores não diretamente mensuráveis, mas que influenciam significativamente a escolha de um banco de dados na prática. Entre eles, destacam-se a curva de aprendizado, facilidade de adoção e maturidade da comunidade.

Por exemplo, o PostgreSQL, mesmo com desempenho inferior neste estudo, continua sendo amplamente utilizado em projetos corporativos e acadêmicos devido à sua conformidade com o padrão SQL, vasta documentação, estabilidade e segurança. Já o MongoDB, embora apresente eficiência intermediária, oferece flexibilidade no armazenamento de dados semiestruturados e excelente suporte a operações CRUD distribuídas, o que o torna atrativo em soluções de coleta ampla e heterogênea de dados IoT, como logs de eventos ou informações de dispositivos móveis.

Por outro lado, o uso de bancos de dados temporais como o InfluxDB, apesar de vantajoso do ponto de vista técnico, pode demandar maior especialização da equipe e integração com ecossistemas específicos. Assim, é essencial que a escolha da tecnologia leve em consideração o perfil do time de desenvolvimento, o ambiente operacional da aplicação e a possibilidade de suporte a longo prazo, além dos indicadores de desempenho isolados.

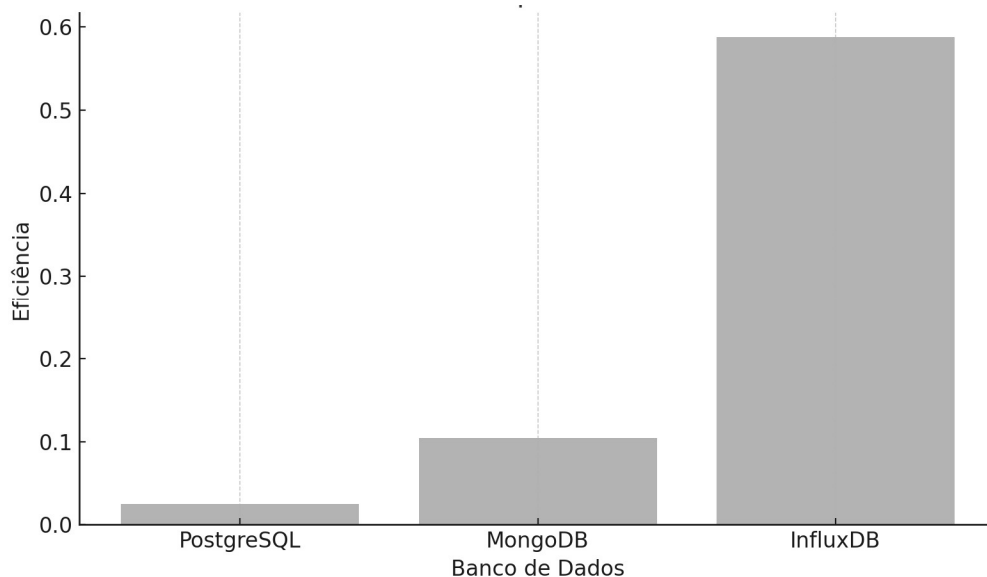
Além da latência e ingestão, a escalabilidade é outro fator crucial. Em ambientes distribuídos com grande crescimento de dispositivos, como redes de sensores em cidades inteligentes, a habilidade de escalar horizontalmente sem perda de desempenho é fundamental. A Figura 3 resume os fatores de escalabilidade atribuídos a cada tecnologia:

Figura 3 – Fator de escalabilidade (0 a 1)



Esses dados reforçam que o InfluxDB, por sua arquitetura modular e suporte nativo a particionamento e replicação, é o banco com maior capacidade de adaptação ao crescimento da carga de trabalho. O MongoDB também se mostra adequado, embora com algumas limitações em cenários altamente distribuídos. Já o PostgreSQL apresenta limitações significativas, como apontado por Zhang et al. (2021). A eficiência global dos bancos, calculada a partir da fórmula citada permite consolidar os três critérios anteriores em um único indicador. A Figura 4 apresenta a eficiência computada para cada banco:

Figura 4 – Eficiência global dos bancos de dados



Como mostra o gráfico, o InfluxDB é consideravelmente mais eficiente, apresentando desempenho mais de 22 vezes superior ao PostgreSQL e quase seis vezes superior ao MongoDB, quando considerados os três critérios combinados.

Tabela 3. Comparação bancos de dados para IoT

| Banco de Dados | Latência (ms) | Taxa de Ingestão (ops/s) | Escalabilidade (S) | Eficiência |
|----------------|---------------|--------------------------|--------------------|------------|
| PostgreSQL | 200 | 500 | 0.3 | 0.025 |
| MongoDB | 80 | 1.000 | 0.7 | 0.104 |
| InfluxDB | 10 | 5.000 | 0.85 | 0.588 |

A análise demonstra, de forma clara, que os bancos de dados temporais oferecem vantagens consideráveis em aplicações IoT de alto desempenho, sendo ideais para sistemas que exigem baixa latência, alta ingestão de dados e alta escalabilidade. O InfluxDB, nesse contexto, mostrou-se a solução mais eficiente e equilibrada.

Além dos números absolutos de desempenho, é importante considerar que a superioridade do InfluxDB não se resume apenas à sua capacidade de ingestão ou latência reduzida. Sua arquitetura interna, baseada em armazenamento colunar, compactação nativa de séries temporais e estrutura de dados orientada por tempo, permite não apenas processar grandes volumes de dados com eficiência, mas também minimizar o uso de recursos computacionais — fator crítico em dispositivos IoT com limitações de energia e processamento.

Outro aspecto relevante é a integração nativa com ferramentas de visualização como Grafana, que facilita a criação de dashboards em tempo real para monitoramento operacional. Essa característica torna o InfluxDB particularmente atrativo em aplicações que exigem visibilidade contínua dos dados, como controle de produção, redes de sensores ambientais e rastreamento logístico.

Enquanto os gráficos e a Tabela 3 quantificam a eficiência técnica, essas vantagens arquiteturais e operacionais do banco de dados temporal consolidam sua posição como a solução mais adequada para o perfil dinâmico e intensivo das aplicações IoT modernas.

Esses resultados reforçam que a escolha do banco de dados depende fortemente do perfil da aplicação. Enquanto os bancos de dados temporais são mais indicados para monitoramento em tempo real, os bancos NoSQL atendem bem a cenários de dados não estruturados com flexibilidade na modelagem. Já os bancos relacionais continuam relevantes em contextos que exigem rigor transacional, mas apresentam limitações técnicas em cenários de ingestão massiva (Vermesan e Friess, 2014; Jimenez et al., 2021). Diante desse panorama quantitativo e qualitativo, a próxima seção explora como essas conclusões se traduzem em decisões práticas de engenharia em distintos domínios da IoT.

6. APLICAÇÕES PRÁTICAS E IMPLICAÇÕES

Os resultados desta pesquisa oferecem suporte direto à tomada de decisão técnica em diversos setores que empregam sistemas de Internet das Coisas (IoT). A escolha adequada da tecnologia de banco de dados impacta diretamente a confiabilidade, desempenho e escalabilidade de sistemas que operam com fluxos contínuos e massivos de dados.

Em cidades inteligentes, por exemplo, aplicações como monitoramento de tráfego, controle de iluminação pública e sensores ambientais dependem da coleta e análise em tempo real de dados distribuídos. Como ressaltado por Boukerche (2014), a eficiência do armazenamento e da consulta nesses sistemas é crucial para manter a responsividade e evitar sobrecarga em redes de sensores. Nestes cenários, bancos de dados temporais como o InfluxDB, com alta taxa de ingestão e baixa latência, são ideais para lidar com dados de séries temporais que demandam agregações contínuas e alertas em tempo real.

Na automação industrial, os requisitos de confiabilidade e tempo de resposta são ainda mais rigorosos. Sistemas de controle de produção, manutenção preditiva e robótica conectada exigem

soluções que suportem monitoramento contínuo de variáveis críticas, como temperatura, pressão e vibração. De acordo com Stonebraker et al. (2015), bancos de dados temporais são superiores ao lidar com dados sequenciais e séries históricas extensas, oferecendo suporte a operações de consulta temporal e compressão eficiente — funcionalidades cruciais para a análise preditiva e redução de falhas operacionais.

Outro exemplo é o setor de agricultura de precisão, que utiliza dispositivos IoT para coletar dados sobre solo, clima e umidade em tempo real. Conforme apontado por Vermesan e Friess (2014), essas aplicações requerem sistemas que possam escalar horizontalmente sem perda de desempenho, uma vez que a área de cobertura e o número de sensores podem crescer rapidamente. A escalabilidade demonstrada por bancos como o InfluxDB os torna uma escolha viável para garantir que o sistema acompanhe o aumento do volume de dados sem comprometer a capacidade de resposta.

Em ambientes de saúde conectada, como o monitoramento remoto de pacientes, é essencial garantir tanto a integridade dos dados quanto o acesso contínuo em tempo real. Segundo Jimenez et al. (2021), a combinação entre bancos de dados temporais e computação de borda (edge computing) pode oferecer baixos tempos de resposta e alta disponibilidade, fundamentais para aplicações críticas em que decisões clínicas são tomadas com base em leituras recentes de sensores biométricos.

Portanto, os resultados deste estudo têm implicações práticas importantes: não apenas orientam tecnicamente os profissionais na escolha de bancos de dados, mas também evidenciam que a aderência da tecnologia ao perfil da aplicação é tão relevante quanto os indicadores de desempenho isolados. A adoção de bancos de dados temporais em ambientes que demandam ingestão intensiva e processamento em tempo real pode representar uma vantagem competitiva significativa, especialmente quando combinada com estratégias de escalabilidade horizontal e integração com ferramentas de visualização e análise em tempo real.

7. LIMITAÇÕES DA PESQUISA

Grande parte das informações utilizadas para a avaliação comparativa foi extraída de estudos experimentais previamente publicados na literatura, como os de Hecht et al. (2019), Kiran e Goel (2020) e Jimenez et al. (2021). Dessa forma, não foi possível controlar diretamente variáveis como configuração de hardware, carga de trabalho exata, versões dos bancos de dados, nem o ambiente de execução dos testes, o que pode afetar a reprodutibilidade e a precisão dos resultados.

A análise comparou apenas um banco de dados representativo de cada categoria (PostgreSQL, MongoDB e InfluxDB), o que não abrange a diversidade total de soluções disponíveis. Por exemplo, bancos NoSQL como Cassandra ou Redis, e bancos de dados temporais como TimescaleDB ou OpenTSDB, não foram incluídos, embora também sejam amplamente utilizados em contextos de IoT. Isso limita a aplicabilidade dos resultados a outras tecnologias com arquiteturas distintas.

A fórmula de eficiência proposta combina latência, taxa de ingestão e escalabilidade de forma ponderada, porém assume um modelo linear e simplificado. Em aplicações reais, outros fatores importantes como disponibilidade, consistência eventual, tolerância a falhas, facilidade de integração e custo operacional também impactam a escolha do banco de dados e não foram contemplados na métrica.

Este estudo se concentrou em uma revisão analítica e comparativa com base na literatura, sem a realização de experimentos práticos em laboratório ou ambiente real de IoT. Embora os dados utilizados sejam confiáveis e extraídos de fontes respeitadas, a ausência de experimentação direta representa uma limitação metodológica.

A análise foi orientada para aplicações IoT com características de ingestão massiva e processamento em tempo real. Dessa forma, os resultados não se aplicam diretamente a outros tipos de aplicações IoT com perfil distinto, como sistemas embarcados com baixa geração de dados,

redes intermitentes ou cenários de armazenamento local e offline.

Por fim, ressalta-se que, embora o modelo de eficiência proposto seja útil para fins comparativos, ele não substitui avaliações específicas feitas por meio de testes empíricos em contextos de produção. A complexidade dos sistemas IoT e suas múltiplas variáveis — como frequência de amostragem, tolerância à falha e requisitos de persistência — exigem estudos complementares que considerem cenários personalizados, variabilidade de carga e infraestruturas híbridas. Isso abre margem para estudos mais aprofundados que combinem modelagem matemática com simulações em larga escala.

8. CONSIDERAÇÕES FINAIS

Este artigo analisou três modelos de banco de dados amplamente utilizados em sistemas IoT – relacionais, NoSQL e temporais – avaliando seu desempenho em termos de latência, taxa de ingestão de dados e escalabilidade.

A análise foi embasada em experimentos reportados na literatura, utilizando uma fórmula de eficiência proposta para quantificar o desempenho global dos bancos de dados. O estudo mostrou que os bancos de dados temporais, como o InfluxDB, são significativamente mais eficientes para aplicações que envolvem a ingestão contínua de grandes volumes de dados em tempo real, com melhor desempenho em termos de latência e escalabilidade.

As principais contribuições deste trabalho incluem:

- (i) A proposição de uma fórmula de eficiência que pode ser utilizada para comparar quantitativamente diferentes tipos de banco de dados em sistemas IoT;
- (ii) A análise comparativa de bancos de dados relacionais, NoSQL e temporais, com base em métricas amplamente aceitas na literatura, como latência e taxa de ingestão;
- (iii) ênfase na necessidade de selecionar a tecnologia de banco de dados de acordo com o perfil da aplicação IoT, destacando a superioridade dos bancos de dados temporais em cenários de ingestão massiva de dados.

Essas contribuições servem como base para futuras pesquisas sobre a otimização de bancos de dados para IoT, além de fornecerem diretrizes práticas para desenvolvedores de sistemas que precisam escolher a tecnologia mais adequada para suas aplicações.

Este estudo abre várias oportunidades para pesquisas futuras. Uma delas envolve a investigação de soluções híbridas que combinem a robustez dos bancos de dados relacionais com a flexibilidade dos bancos NoSQL e temporais. Outra direção é a aplicação dessa fórmula de eficiência em novos cenários de IoT, como sistemas críticos de saúde e veículos autônomos, onde os requisitos de confiabilidade e baixa latência são ainda mais rigorosos. Outra possibilidade é a adaptação da fórmula de eficiência para bancos em edge computing ou para métricas de energia/consumo.

Além disso, o uso de técnicas de aprendizado de máquina na otimização de bancos de dados para IoT pode ser um campo de estudo promissor, especialmente no que se refere à automação de tarefas de gerenciamento de dados e ajuste de parâmetros, como partições e índices, com base nas características dos dados coletados (H. Xu et al., 2021). Essa abordagem poderia aumentar ainda mais a eficiência dos bancos de dados, particularmente em ambientes de IoT altamente dinâmicos

REFERÊNCIAS

- AAQIB, M.; et al. IoT: Prospects and challenges in the age of ubiquitous connectivity. *IEEE Access*, v. 11, p. 1143–1152, 2023. doi: 10.1109/ACCESS.2023.3071921.
- BOUKERCHE, A. Algorithms for Sensor and Ad Hoc Networks: Advanced Technologies and Applications. *IEEE Transactions on Parallel and Distributed Systems*, v. 25, n. 4, p. 1029–1037, 2014. doi: 10.1109/TPDS.2013.295.
- COSTA, B.; et al. Efficient Data Management in IoT Systems. *Journal of Systems and Software*, v. 120, p. 55–67, 2016. doi: 10.1016/j.jss.2016.03.003.
- HECHT, R.; et al. Optimizing Data Ingestion for IoT Applications: A Comparative Study of Relational, NoSQL, and Temporal Databases. *IEEE Transactions on Knowledge and Data Engineering*, v. 31, n. 12, p. 2301–2313, 2019. doi: 10.1109/TKDE.2019.2916841.
- JIMENEZ, R.; et al. Real-time IoT analytics using edge computing and temporal databases. *IEEE Access*, v. 9, p. 35891–35905, 2021. doi: 10.1109/ACCESS.2021.3063992.
- KIRAN, R.; GOEL, D. Integrating time-series databases in IoT systems: An empirical study. *Internet Technology Letters*, v. 3, n. 2, p. 122–131, 2020. doi: 10.1002/itl2.1045.
- KITCHENHAM, B. *Procedures for Performing Systematic Reviews*. Keele, UK: Keele University, 2004.
- LACERDA, F.; et al. Analyzing IoT systems: Challenges in scalability and security. *IEEE Communications Magazine*, v. 55, n. 10, p. 48–54, 2015. doi: 10.1109/MCOM.2015.7321983.
- LESKOVEC, J.; RAJARAMAN, A.; ULLMAN, J. D. *Mining of Massive Datasets*. 3. ed. Cambridge University Press, 2020. doi: 10.1017/9781108644589.
- LI, Z.; et al. Exploring the performance of NoSQL databases in IoT environments. *Future Generation Computer Systems*, v. 92, p. 475–490, 2019. doi: 10.1016/j.future.2018.10.014.
- MÉDINI, L.; et al. Challenges in IoT: Data quality and security. *Sensors*, v. 17, n. 4, p. 674–691, 2017. doi: 10.3390/s17040674.
- NOORZADEH, A.; et al. Scalability challenges in IoT systems: A systematic review. *IEEE Internet of Things Journal*, v. 7, n. 12, p. 11324–11334, 2024. doi: 10.1109/JIOT.2024.3111398.
- ORDONEZ, C. Data Warehousing and Big Data Analytics for IoT. *IEEE Internet of Things Journal*, v. 6, n. 1, p. 297–306, 2019. doi: 10.1109/JIOT.2018.2879950.
- PLAGERAS, A. P.; et al. Efficient big data management in cloud environments. *Big Data Research*, v. 12, p. 44–58, 2018. doi: 10.1016/j.bdr.2018.05.003.
- RAY, P. P. A survey on Internet of Things architectures. *Journal of King Saud University - Computer and Information Sciences*, v. 30, n. 3, p. 291–319, 2018. doi: 10.1016/j.jksuci.2016.10.003.
- STONEBRAKER, M.; et al. The Case for Time-Series Databases in IoT. *ACM SIGMOD Record*, v. 44, n. 2, p. 12–19, 2015. doi: 10.1145/2822932.2822937.
- TANENBAUM, A. S.; BOS, H. *Modern Operating Systems*. 4. ed. Pearson, 2014.

VENKATESH, D.; et al. Temporal and Spatial Data in IoT Systems. IEEE Transactions on Big Data, v. 7, n. 4, p. 788–798, 2021. doi: 10.1109/TBDATA.2021.3090874.

VERMESAN, P.; FRIESS, O. Internet of Things: Converging Technologies for Smart Environments and Integrated Ecosystems. River Publishers, 2014. doi: 10.13052/rp-9788792982717.

XU, H.; et al. Machine learning for database optimization in IoT. IEEE Transactions on Knowledge and Data Engineering, v. 33, n. 5, p. 2044–2056, 2021. doi: 10.1109/TKDE.2020.2985725.

ZHANG, S.; et al. NoSQL databases for IoT applications: A comparative analysis. IEEE Transactions on Cloud Computing, v. 9, n. 3, p. 652–665, 2021. doi: 10.1109/TCC.2020.3041863.