

Detecção e Monitoramento de Anomalias em Data Centers Através de Análise Acústica: Abordagens e Direções Futuras

Renan Moura¹, Bruno L. Dalmazo², André Riker³, Ramon Fontes¹,
Itamir M. B. Filho¹, Roger Immich¹

¹ Universidade Federal do Rio Grande do Norte (UFRN)

² Universidade Federal do Rio Grande (FURG)

³ Universidade Federal do Pará (UFPA)

renan.moura@imd.ufrn.br, dalmazo@furg.br, ariker@ufpa.br,
{ramon.fontes, itamir.filho, roger}@imd.ufrn.br

Abstract. *The increasing complexity of Information Technology infrastructures, particularly in data centers, has intensified the need for continuous monitoring that encompasses not only computational aspects but also environmental factors that affect their operation. In this context, noise and sound generated by equipment emerge as a valuable source of information about the functional state of the infrastructure. This systematic mapping aims to identify, organize, and analyze studies that explore the use of acoustic signals in data center environments, with a focus on applications for monitoring and anomaly detection. The study also examines the evolution of research in this area, the main techniques and methodologies employed, and identifies gaps and opportunities in the literature. By synthesizing this evidence, the mapping contributes to outlining the current state of the art and positions acoustic analysis as a promising complementary source of information for monitoring critical IT infrastructures.*

Resumo. *A crescente complexidade das infraestruturas de Tecnologia da Informação, especialmente em data centers, tem ampliado a necessidade de monitoramento contínuo que considere não apenas aspectos computacionais, mas também fatores ambientais que impactam sua operação. Nesse contexto, ruídos e sons gerados pelos equipamentos emergem como uma fonte relevante de informação sobre o estado funcional da infraestrutura. Este mapeamento sistemático tem como objetivo identificar, organizar e analisar estudos que exploram o uso de sinais acústicos em ambientes de data centers, com foco em aplicações voltadas ao monitoramento e à detecção de anomalias. O trabalho também investiga a evolução das pesquisas, as principais técnicas e metodologias adotadas, bem como identifica lacunas e oportunidades na literatura. Ao sistematizar essas evidências, o mapeamento contribui para delinear o estado atual do conhecimento e para situar a análise acústica como uma fonte complementar de informação no monitoramento de infraestruturas críticas de TI.*

1. Introdução

O funcionamento ininterrupto dos *data centers* tornou-se um dos pilares da economia digital, viabilizando serviços de computação em nuvem, Inteligência Artificial (IA) e transações financeiras em escala global. Com essa expansão, o consumo energético desses ambientes ganhou relevância. Segundo a International Energy Agency (IEA) [Agency 2024], a demanda elétrica dos *data centers* pode alcançar até 3% do consumo mundial até 2030, superando países como o Brasil, e estudos mais recentes da

mesma agência [Agency 2025] apontam que cargas relacionadas à IA, impulsionadas por Unidades de Processamento Gráfico (GPUs) e Unidades de Processamento Tensorial (TPUs), poderão representar cerca de 10% desse total.

Garantir disponibilidade, confiabilidade e eficiência energética nesses ambientes requer estratégias de monitoramento capazes de detectar precocemente alterações no comportamento dos ativos. Nesse cenário, paradigmas como Computação Urbana e cidades inteligentes destacam a importância da coleta, integração e análise contínua de dados [Rodrigues et al. 2019]. Além disso, arquiteturas distribuídas baseadas em IoT, Computação de Borda e Névoa aproximam o processamento das fontes de dados, reduzindo latência e ampliando a capacidade de monitoramento contínuo em infraestruturas críticas [Pisani et al. 2020, Bittencourt et al. 2018]. Esses ambientes também demandam mecanismos inteligentes de prevenção e detecção de intrusões capazes de identificar comportamentos anômalos em tempo real [Alves et al. 2025]. Além de métricas tradicionais, como temperatura, consumo energético, vibração e desempenho de hardware, os sons produzidos por servidores, sistemas de ventilação e componentes de resfriamento representam uma fonte complementar de informação, pois alterações nos padrões acústicos podem indicar falhas e auxiliar na detecção de anomalias [Wüstrich et al. 2022].

Apesar desse potencial, a literatura sobre o uso de sinais acústicos em *data centers* ainda é dispersa, reunindo estudos que vão desde a caracterização do ruído ambiental até métodos de diagnóstico de falhas [Wüstrich et al. 2024]. Para organizar esse cenário, este trabalho conduz um mapeamento sistemático com três contribuições principais. A primeira é a proposição de uma taxonomia em cinco dimensões integradas, que envolvem fontes de sinal, arquitetura de sensoriamento, técnicas de análise, objetivos de monitoramento e escala de granularidade, articulando elementos antes tratados de forma isolada na literatura. A segunda é o cruzamento sistemático entre essas dimensões, apresentado nas Figuras 3 a e na Figura 8, que torna visíveis combinações consolidadas e também lacunas estruturais pouco discutidas até aqui. A terceira é a derivação de direções de pesquisa a partir dessas lacunas, oferecendo uma agenda objetiva para investigações futuras. As próximas seções descrevem a metodologia adotada, apresentam os resultados e sintetizam as direções identificadas.

2. Metodologia do mapeamento

No contexto desta pesquisa, adotam-se os princípios da Ciência Aberta, com foco em transparência, reprodutibilidade, replicabilidade e colaboração científica. Todos os artefatos produzidos, como dados brutos coletados, scripts de processamento e análise e códigos utilizados para geração de gráficos e visualizações, estão disponíveis em um repositório público no GitHub ¹. Também são disponibilizadas visualizações complementares, como gráficos analíticos e um diagrama de Sankey interativo, que permitem explorar melhor os fluxos e relações identificadas no estudo.

Este mapeamento sistemático foi realizado seguindo a metodologia proposta por Petersen [Petersen et al. 2008], que é constituída por 4 fases: (1) Questões de pesquisa, (2) Condução de busca e palavras chaves de artigos, (3) Seleção de trabalhos e (4) Extração e mapeamento dos dados. Através desta estrutura, foram definidas as questões de pesquisa para nortear este mapeamento sistemático, com o intuito de identificar quais são os estudos mais relevantes que discutem o tema abordado.

¹<https://projetosdti.imd.ufrn.br/msl-noisedc>

- RQ1. Como evoluiu a produção científica sobre análise de ruído em *data centers* ao longo do tempo e quais são as abordagens mais utilizadas nessa área?
- RQ2. Quais ativos de *data centers* são mais investigados quanto aos seus padrões sonoros e potenciais anomalias acústicas?
- RQ3. Quais combinações entre fontes de sinal, técnicas de análise e objetivos de monitoramento foram identificadas para detecção de falhas e manutenção preditiva em *data centers*?
- RQ4. Quais são as principais lacunas identificadas nos estudos sobre o monitoramento do ruído em infraestruturas de *data centers*?

A busca por trabalhos foi conduzida em bases de dados bibliográficos, foram selecionados 4 mecanismos de busca acadêmica (MBAs), são eles ACM, IEEE, Science Direct e Scopus [Buchinger et al. 2014]. A Tabela 1 apresenta as strings de busca adotadas por base. A busca foi realizada através de título, resumo e palavras-chave em cada repositório acadêmico.

Tabela 1. Sintaxe de busca

<i>Portais científicos</i>	Protocolos de busca
<i>ACM Digital Library</i>	TITLE-ABS-KEY ((“datacenter”OR “data center”OR “data processing center”OR “DCIM”) AND (“noise”OR “sound”))
<i>IEEEExplore</i>	(“datacenter”OR “data center”OR “data processing center”OR “DCIM”) AND (“noise”OR “sound”OR “audio”)
<i>ScienceDirect</i>	TITLE-ABS-KEY ((“datacenter”OR “data center”OR “data processing center”OR “DCIM”) AND (“noise”OR “sound”))
<i>Scopus</i>	((“datacenter”OR “data center”OR “data processing center”OR “DCIM”) AND (“noise”OR “sound”OR “audio”))

Foram estabelecidos critérios de inclusão (CI) e critérios de exclusão (CE) com o objetivo de assegurar a relevância, a qualidade e a adequação dos estudos selecionados ao escopo desta pesquisa. A Tabela 2 apresenta detalhadamente os critérios de inclusão e os critérios de exclusão adotados.

Tabela 2. Critérios de Inclusão (CI) e Exclusão (CE)

Critérios de Inclusão (CI)	Critérios de Exclusão (CE)
<ol style="list-style-type: none"> Estudos que abordam análise de ruído ou som em ambientes de data centers; Estudos que detectam falhas baseadas em ruído ou som em ambientes de data centers; 	<ol style="list-style-type: none"> Artigo duplicado; Artigo com 3 páginas ou menos (<i>short paper</i>); Artigo considerado de literatura cinza; Trabalhos publicados antes de 2015; Artigo indisponível (de acesso restrito ou não encontrados); Estudos secundários (revisões ou mapeamentos de literatura); Artigo fora do escopo de estudo; Trabalhos em andamento; Artigo em idioma diferente do inglês ou português;

A Figura 1 apresenta as fases de seleção dos estudos. Os 37 estudos potencialmente relevantes foram submetidos a uma leitura inicial do título, resumo e palavras-chave, seguido novamente de outra aplicação de CI e CE. Ao final, 29 artigos foram selecionados para condução deste mapeamento sistemático.




Figura 1. Fases para seleção dos estudos relevantes

3. Taxonomia do Monitoramento Acústico em Data Centers

A análise dos estudos selecionados mostra que o monitoramento acústico em *data centers* é abordado de forma fragmentada na literatura, sem uma estrutura conceitual que articule seus principais elementos. Para tratar essa limitação, propõe-se a taxonomia apresentada na Figura 2. Mais do que uma organização descritiva, ela funciona como instrumento analítico, pois permite posicionar trabalhos heterogêneos dentro de um mesmo arcabouço comparativo e, principalmente, evidenciar combinações pouco exploradas entre as dimensões, o que serve de base para as lacunas discutidas na Seção 4.

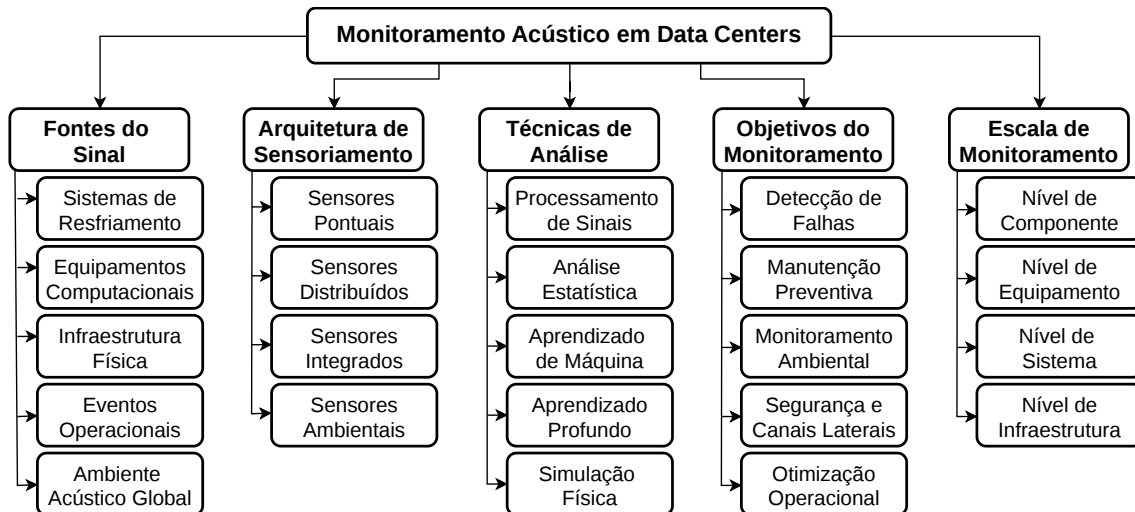


Figura 2. Taxonomia do Monitoramento Acústico em Data Centers

A taxonomia proposta organiza o domínio de pesquisa em cinco dimensões principais, sendo elas as fontes do sinal acústico, a arquitetura de sensoriamento, as técnicas de análise, os objetivos do monitoramento e a escala de monitoramento. As fontes do sinal acústico correspondem aos elementos da infraestrutura responsáveis pela geração dos sons analisados, incluindo sistemas de resfriamento, como ventiladores de servidores, *racks* e HVAC, além de dispositivos computacionais, como servidores e unidades de armazenamento. Ruídos provenientes de eventos operacionais também podem compor esse cenário, sendo frequentemente interpretados em conjunto como uma assinatura acústica global do data center.

A partir dessas fontes, define-se a arquitetura de sensoriamento, que estabelece como os sinais são capturados. Essa arquitetura pode envolver sensores pontuais posicionados próximos a componentes específicos, sensores distribuídos no ambiente, sensores integrados aos equipamentos ou sensores ambientais voltados ao registro do nível geral de ruído. Os dados coletados são então processados por meio de técnicas de análise, que incluem desde métodos tradicionais, como análise espectral, extração de características e abordagens estatísticas, até modelos mais avançados baseados em aprendizado de máquina e aprendizado profundo para detecção de anomalias [Santo et al. 2023]. Em alguns casos, também são utilizadas simulações físicas para compreender a propagação do som no ambiente. Essas análises são conduzidas com diferentes objetivos de monitoramento, como detecção de falhas, manutenção preditiva, monitoramento das condições acústicas, investigação de segurança por canais laterais e apoio à otimização operacional da infraestrutura. Por fim, todo esse processo se organiza em diferentes escalas de monitoramento, que definem o nível de granularidade da análise, variando desde componentes e equipamentos individuais até sistemas completos e a infraestrutura como um todo, permitindo uma visão que vai do comportamento local ao padrão acústico global do data center.

4. Detecção e Monitoramento de Anomalias em Data Centers

Esta seção apresenta as questões de pesquisa que orientam este estudo e discute as principais evidências identificadas na literatura.

4.1. Como evoluiu a produção científica sobre análise de ruído em data centers ao longo do tempo e quais são as abordagens mais utilizadas nessa área? (RQ1)

A análise temporal mostra que o uso de sinais acústicos no monitoramento de *data centers* é recente e apresenta crescimento gradual. Entre 2015 e 2017, os estudos focam na caracterização do ruído e no mapeamento acústico [Sevillano et al. 2016, Miljković 2016, Levy and Hallstrom 2017], com uso de WSN para coleta distribuída [Ahmed et al. 2017], além de abordagens relacionadas à infraestrutura eletrônica [Garcia-Mora et al. 2016] e ao controle de redes internas [Lee et al. 2017]. Entre 2018 e 2021, há diversificação das aplicações, incluindo detecção de falhas e segurança. Destacam-se trabalhos sobre canais acústicos como vetores de ataque [Islam et al. 2018], impactos de sistemas de supressão [Mihalache et al. 2019], efeitos na saúde [Alnuaimy et al. 2022], além do uso de aprendizado de máquina [Lin 2021] e análise de ruído em comunicações ópticas [Katz and Sonkin 2019].

A partir de 2022, o crescimento se consolida, com foco em monitoramento não intrusivo e manutenção preditiva, integrando sinais acústicos [Wüstrich et al. 2022], telemetria [Mebratu et al. 2022] e impactos operacionais [Wasala et al. 2022]. Entre 2023 e 2025, intensifica-se o uso de IA, especialmente aprendizado profundo [Wüstrich et al. 2024, Yang et al. 2024] [Liang et al. 2025], com aplicações em resfriamento [Chowdhury et al. 2024], comunicações ópticas [Zeng et al. 2025] [Chen et al. 2025], *data centers* quânticos [Campbell et al. 2025], interferências eletromagnéticas [Sen Gupta 2024], enlacs Ethernet [Prevedelli et al. 2025, Liu 2025] e séries temporais [Ge et al. 2022].

A Figura 3 evidencia essa transição, com métodos tradicionais como processamento de sinais e análise estatística predominando nos primeiros anos e crescimento

expressivo de aprendizado de máquina e *deep learning* partir de 2022. A análise integrada revela predominância de processamento de sinais associado ao monitoramento ambiental, enquanto *deep learning* emerge com foco em detecção de falhas e anomalias, e simulações físicas se associam à otimização operacional. Identifica-se ainda uma estratificação das técnicas conforme a escala do sistema, com lacunas na integração entre simulação e aprendizado de máquina.




Figura 3. Técnica de análise vs Ano

A Figura 4 reforça essa concentração, destacando a associação entre processamento de sinais e monitoramento ambiental e entre *deep learning* e detecção de falhas. Observa-se que abordagens baseadas em *machine* e *deep learning* concentram-se principalmente em objetivos como detecção de falhas, anomalias e monitoramento preditivo, refletindo a capacidade desses métodos de lidar com grandes volumes de dados e identificar padrões complexos de forma automatizada. Por outro lado, técnicas mais tradicionais, como processamento de sinais e análise estatística, aparecem fortemente associadas ao monitoramento ambiental e à análise contínua de sistemas, indicando seu papel consolidado em cenários mais interpretáveis e determinísticos [Wu et al. 2025]. Já métodos como simulação física e modelagem computacional são predominantemente utilizados em otimização operacional, evidenciando seu uso em estudos exploratórios e de avaliação de desempenho. Técnicas como modelagem acústica, análise espectral e simulação térmico-acústica [Yang 2025] aparecem com ocorrências pontuais, indicando abordagens ainda incipientes. A maior parte das combinações entre técnicas e objetivos permanece inexplorada, com lacunas relevantes em objetivos como saúde ocupacional [Alnuaimy et al. 2022], mitigação de impacto acústico e monitoramento preditivo, apontando direções para pesquisas futuras.

Comparativamente, há uma diferença qualitativa entre as fases identificadas. Os estudos iniciais, entre 2015 e 2017, priorizam a caracterização determinística do ambiente sonoro, enquanto os trabalhos a partir de 2022 deslocam o foco para a inferência automática de estados anômalos. Essa transição reflete mais do que uma evolução metodológica, indicando também uma mudança no próprio objeto investigado, o que explica por que técnicas tradicionais e modelos baseados em aprendizado coexistem na literatura

sem competir diretamente, já que atendem a objetivos distintos.

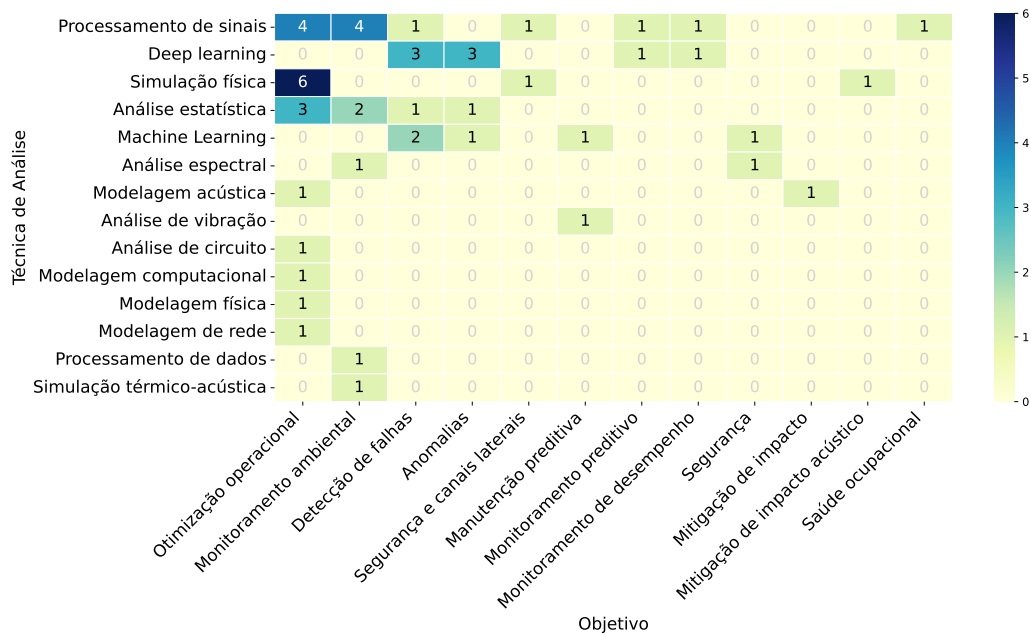


Figura 4. Técnica de Análise vs Objetivos

4.2. Quais ativos operacionais de *data centers* são mais investigados quanto aos seus padrões sonoros e potenciais anomalias acústicas? (RQ2)

Os ativos mais investigados quanto a padrões sonoros e anomalias acústicas concentram-se nos sistemas de resfriamento e ventilação [Killeen et al. 2023] [Jingyi et al. 2024]. Ventiladores de servidores, ventiladores de racks e sistemas de Aquecimento, Ventilação e Ar-Condicionado (HVAC) aparecem de forma recorrente, tanto em estudos de caracterização do ruído ambiental [Chowdhury et al. 2024] quanto em investigações voltadas à predição de falhas por análise de vibração [Mebratu et al. 2022] e espectro sonoro [Miljković 2016], dado que seu comportamento acústico reflete diretamente o estado operacional, a carga térmica e o desgaste mecânico.

Servidores e racks também são frequentemente analisados como fontes acústicas integradas. O ambiente sonoro do data center resulta da operação simultânea de vários equipamentos, permitindo identificar padrões associados a estados específicos de operação ou eventos anômalos [Wüstrich et al. 2024], e abordagens baseadas em canais acústicos exploram esse perfil global como fonte complementar de informação para monitoramento da infraestrutura [Wüstrich et al. 2022]. O armazenamento mecânico, especialmente os discos rígidos (HDD), também se destaca na literatura, com estudos sobre sua sensibilidade a ruídos intensos e estratégias de isolamento acústico para mitigar impactos sobre desempenho e integridade dos dados [Wasala et al. 2022]. Investigações sobre sistemas de supressão de incêndio por gás inerte ampliam esse escopo, considerando eventos críticos de alta intensidade sonora capazes de afetar equipamentos sensíveis [Mihalache et al. 2019].

A Figura 5 apresenta o mapeamento entre Sensoriamento e Técnica de Análise, evidenciando uma forte interdependência entre as estratégias de aquisição de dados e os

métodos analíticos empregados. Observa-se que abordagens baseadas em sensores integrados estão predominantemente associadas a técnicas mais avançadas, como *machine learning* e *deep learning*, bem como processamento de sinais e simulação física, o que sugere que a maior disponibilidade e integração de dados favorecem o uso de modelos mais complexos e também os orientados à inferência automática. Em contraste, sensores distribuídos e sensores pontuais aparecem frequentemente vinculados a técnicas mais tradicionais, como processamento de sinais, análise estatística e simulação física, indicando um perfil de análise mais determinístico e voltado à interpretação direta dos dados coletados. De forma geral, a figura demonstra que a escolha da técnica de análise não é aleatória, mas condicionada pela natureza e pela forma de coleta dos dados, evidenciando um alinhamento consistente entre infraestrutura de sensoriamento e complexidade analítica nas soluções propostas. No entanto, um aspecto particularmente relevante é a baixa representatividade dos sensores acústicos, que aparecem de forma bastante limitada no conjunto de estudos analisados. Essa escassez indica uma lacuna importante, especialmente considerando o potencial dos sinais acústicos para capturar fenômenos físicos e operacionais de forma não invasiva.

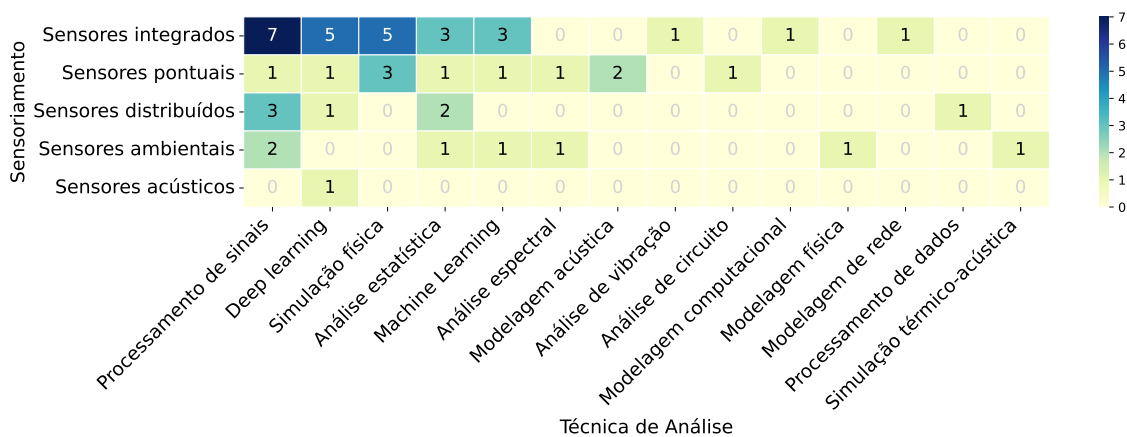


Figura 5. Sensoriamento vs Técnica de Análise

A Figura 6 apresenta as relações entre a Fonte do Sinal e Escala. Observa-se uma clara concentração de determinadas fontes em escalas específicas, indicando uma especialização estrutural: sinais provenientes de eventos operacionais tendem a ser analisados na escala de sistema, enquanto dados oriundos de equipamentos computacionais concentram-se em análises de componente, e o ambiente acústico aparece predominantemente associado à escala de infraestrutura. A Figura 7 apresenta as relações entre o Sensoriamento e Escala. Ela complementa a visão ao evidenciar como as estratégias de coleta de dados se distribuem ao longo dessas escalas, revelando que sensores integrados estão fortemente associados a análises em nível de sistema, ao passo que sensores pontuais e distribuídos aparecem com maior frequência em escalas mais granulares ou específicas. Em conjunto, esses dois gráficos demonstram que não apenas o tipo de sinal, mas também a forma como ele é capturado, influenciam diretamente o nível de abstração das soluções propostas, evidenciando a existência de padrões consolidados na literatura.

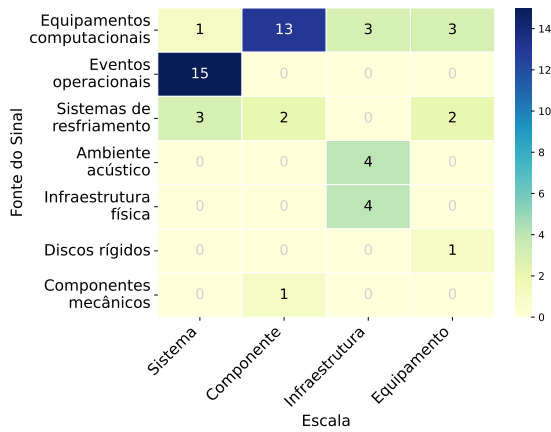


Figura 6. Fonte do Sinal vs Escala

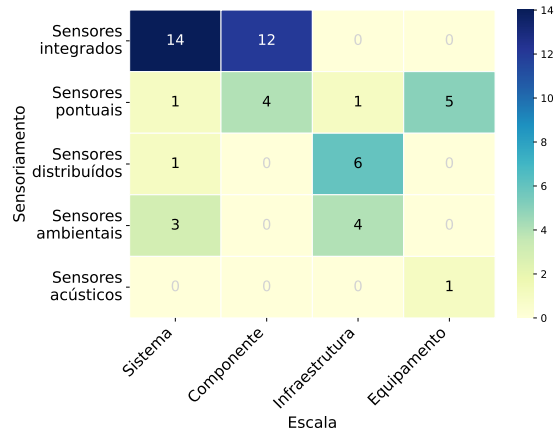


Figura 7. Sensoriamento vs Escala

4.3. Quais combinações entre fontes de sinal, técnicas de análise e objetivos de monitoramento foram identificadas para detecção de falhas e manutenção preditiva em *data centers*? (RQ3)

Os estudos analisados mostram que certas combinações entre fonte, técnica e objetivo aparecem com frequência em *data centers*. A Figura 8 demonstra que fontes, como equipamentos computacionais e eventos operacionais, convergem majoritariamente para sensores integrados, que alimentam técnicas de processamento de sinais, *deep learning* e análise de vibração voltadas à detecção de falhas, anomalias e manutenção preditiva. Técnicas como processamento de sinais e *deep learning* apresentam maior dispersão de aplicações, enquanto análise de vibração mantém associação mais específica com manutenção preditiva.

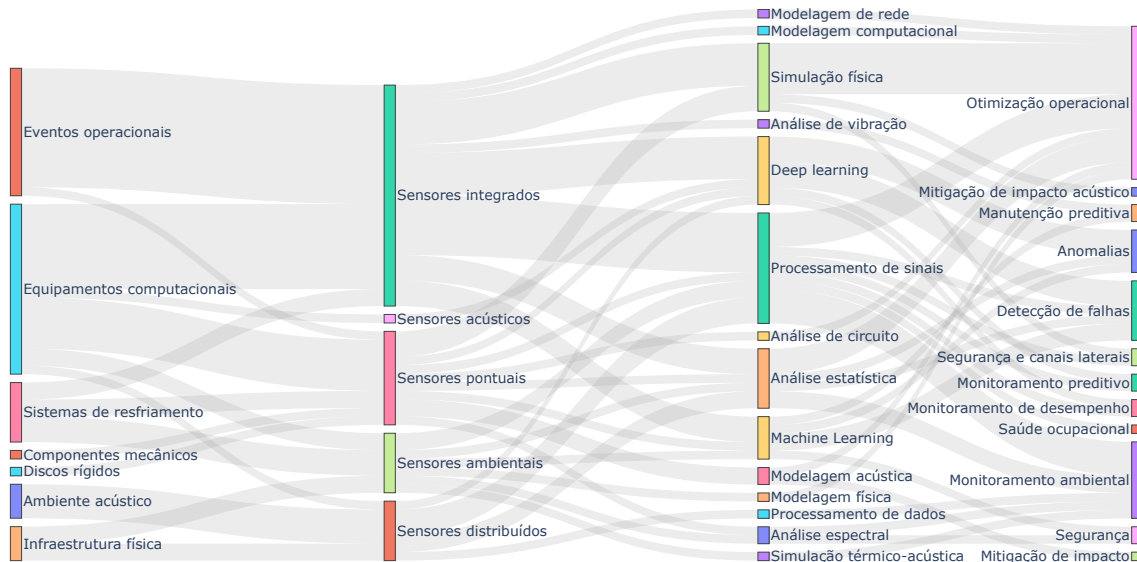


Figura 8. Interligação entre Fonte, Sensoriamento, Técnicas e Objetivo

No contexto de servidores, *beeps* e vibrações anômalas foram identificados como indicadores de falhas de hardware e possíveis comandos maliciosos do tipo *spoofing*, com redes neurais convolucionais alcançando acurácia de 95% na identificação de eventos anômalos, em bancada controlada e com um conjunto reduzido de servidores [Wüstrich et al. 2022]. Estudos de telemetria de hardware indicam que vazamentos em

sistemas de resfriamento podem ser detectados pela correlação entre sinais acústicos e dados operacionais [Mebratu et al. 2022]. Em componentes mecânicos como ventiladores e rolamentos, alterações no espectro sonoro entre 1 e 5 kHz foram associadas ao desgaste progressivo, permitindo detecção antecipada de falhas com acurácia de 96% por máquinas de vetores de suporte aplicadas a uma base pública de falhas de rolamentos, em regime de validação cruzada [Lin 2021].

Em relação a discos rígidos, níveis de pressão sonora superiores a 120 dB durante descargas de sistemas de supressão de incêndio com gás inerte mostraram-se capazes de provocar danos físicos diretos, e estratégias de reposicionamento com materiais de absorção acústica permitiram reduzir esses níveis em até 20 dB [Wasala et al. 2022]. Na dimensão de segurança cibernética, padrões irregulares de ventilação podem ser explorados como canal lateral para ataques de sobrecarga energética em infraestruturas multi-inquilinos [Islam et al. 2018], com análise espectral combinada a aprendizado de máquina alcançando acurácia de 54% na identificação de comportamentos anômalos, desempenho que reflete a maior dificuldade da tarefa em ambiente multi-inquilino e que, por isso, não é diretamente comparável às acurácias acima, obtidas em cenários controlados.

Essas métricas, embora ilustrativas do potencial das abordagens, devem ser lidas no contexto experimental de cada estudo, seja em bancadas controladas, bases públicas específicas ou cenários adversariais, e não admitem comparação direta entre si. De modo geral, os estudos demonstram que variações acústicas e vibracionais foram utilizadas como indicadores de anomalias em servidores, sistemas de ventilação, dispositivos de armazenamento e subsistemas energéticos, combinando sensores acústicos, extração de características espectrais e métodos de classificação.

4.4. Quais são as principais lacunas identificadas nos estudos sobre o monitoramento do ruído em infraestruturas de *data centers*? (RQ4)

A literatura apresenta uma ausência de estudos longitudinais, concentrando-se majoritariamente na detecção de falhas específicas ou na caracterização de assinaturas acústicas de componentes isolados, especialmente ventiladores e sistemas de resfriamento. Não foram identificados modelos que relacionem a exposição acústica contínua a indicadores globais de eficiência e disponibilidade operacional, nem análises que considerem impactos cumulativos no desempenho, na confiabilidade ou na degradação dos equipamentos ao longo do tempo.

Observa-se também uma falta de padronização metodológica, uma vez que os estudos utilizam diferentes métricas e abordagens, como níveis de pressão sonora em dB(A), análises espectrais em variadas faixas de frequência, medições de vibração e modelos de aprendizado de máquina. Não há consenso sobre faixas espectrais relevantes, limiares de anomalia ou protocolos de validação em ambientes reais, o que dificulta a comparação entre resultados e compromete a reprodutibilidade dos experimentos. Poucos trabalhos investigam os efeitos do ambiente acústico sobre operadores e equipes técnicas em *data centers*, e são raras as análises de viabilidade econômica ou de custo-benefício relacionadas à adoção de soluções de monitoramento acústico.

Por fim, identifica-se uma integração ainda incipiente com outras fontes de monitoramento. Embora alguns estudos combinem sinais acústicos com telemetria de hardware e métricas energéticas, essas abordagens permanecem restritas a cenários experimentais. Sistemas distribuídos para gerenciamento integrado de informação e conheci-

mento também podem contribuir para ampliar interoperabilidade, integração multimodal e análise contextual em ambientes críticos [Akabane et al. 2018]. Em conjunto, essas lacunas indicam que a análise acústica em *data centers* ainda se encontra em estágio inicial de maturidade metodológica, e que investigações futuras voltadas à padronização, integração multimodal e validação em ambientes operacionais reais podem contribuir de forma expressiva para o avanço do campo.

5. Conclusões

O monitoramento eficiente de *data centers* permanece um desafio crescente, e este trabalho apresentou um mapeamento sistemático sobre o uso de sinais acústicos como fonte complementar para detecção de falhas e anomalias. Os resultados mostram a predominância de processamento de sinais, sensores distribuídos e modelos de aprendizado aplicados a ventiladores, sistemas de resfriamento e componentes mecânicos, com resultados promissores em cenários controlados.

Quatro lacunas estruturais foram identificadas e organizam a agenda futura. A primeira é a ausência de estudos longitudinais que capturem efeitos cumulativos da exposição acústica sobre desempenho e degradação. A segunda é a falta de padronização metodológica quanto a faixas espectrais, limiares de anomalia e protocolos de validação, o que compromete a reprodutibilidade. A terceira é a integração ainda incipiente entre sinais acústicos e outras fontes de telemetria. A quarta é a escassez de validação em ambientes operacionais reais.

Como contribuição, o trabalho organiza o estado da arte, propõe uma taxonomia articuladora e aponta direções concretas para pesquisas subsequentes, em especial a validação empírica da taxonomia por especialistas, o desenvolvimento de diretrizes aplicáveis a ambientes de produção e a avaliação crítica aprofundada da maturidade das evidências.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Este trabalho utilizou ferramentas de IA exclusivamente para aprimoramento textual, incluindo correção gramatical e melhorias de clareza e legibilidade. Todo o conteúdo técnico, ideias e contribuições são de inteira responsabilidade dos autores.

Referências

- Agency, I. E. (2024). Data centres and data transmission networks. Accessed: 2025-10-30.
- Agency, I. E. (2025). Energy demand from ai. Accessed: 2025-10-30.
- Ahmed, S., Ahsan, M., Hadi, F., Ahmed, I., and Khan, A. (2017). A novel noise-measuring system based on wsn. In *2017 International Conference on Innovations in Electrical Engineering and Computational Technologies (ICIEECT)*, pages 1–6.
- Akabane, A. T., Immich, R., Pazzi, R. W., Madeira, E. R. M., and Villas, L. A. (2018). Trusted: A distributed system for information management and knowledge distribution in vanets. In *2018 IEEE Symposium on Computers and Communications (ISCC)*, pages 1–6.

- Alnuaimy, Ahmed, Shushurab, O., and Zhyrov, G. (2022). Impact of noise inside server room.
- Alves, D., Dalmazo, B., Riker, A., Filho, G. R., and Immich, R. (2025). Prevenção e detecção de intrusões em redes iot: Um mapeamento sistemático de soluções na borda e na nuvem. In *Anais do XVII Simpósio Brasileiro de Computação Ubíqua e Pervasiva*, pages 111–120, Porto Alegre, RS, Brasil. SBC.
- Bittencourt, L., Immich, R., Sakellariou, R., Fonseca, N., Madeira, E., Curado, M., Villas, L., DaSilva, L., Lee, C., and Rana, O. (2018). The internet of things, fog and cloud continuum: Integration and challenges. *Internet of Things*, 3-4:134 – 155.
- Buchinger, D., de Siqueira Cavalcanti, G. A., and da Silva Hounsell, M. (2014). Mecanismos de busca acadêmica: uma análise quantitativa. *Revista Brasileira de Computação Aplicada*, 6(1):108–120.
- Campbell, K., Lawey, A., and Razavi, M. (2025). Quantum data centres: a simulation-based comparative noise analysis. *Quantum Science and Technology*, 10(1). Cited by: 1; All Open Access, Green Open Access, Hybrid Gold Open Access.
- Chen, Z., Xiang, J., Xiang, M., Fu, S., and Qin, Y. (2025). Deep neural network-based joint monitoring of carrier-to-signal power ratio (cspr) and optical signal-to-noise ratio (osnr) for directly detected optical single-sideband transmission. *Opt. Express*, 33(6):12375–12388.
- Chowdhury, U., Rodriguez, J., Tradat, M., Soud, Q., Wallace, S., O’Brien, D., Hambruch, S., Heydari, A., Radmard, V., and Shahi, P. (2024). Acoustics analysis of air and hybrid cooled data center. In *2024 23rd IEEE Intersociety Conference on Thermal and Thermomechanical Phenomena in Electronic Systems (ITherm)*, pages 1–11.
- Garcia-Mora, D. M., Garcia-Garcia, D., Yahyaei-Moayyed, F., Cinco-Galicia, J. C., Sanchez-Ortiz, C. R., and Sala, C. A. (2016). Filter design methodology for low noise power domains in datacenter platforms. In *2016 IEEE MTT-S Latin America Microwave Conference (LAMC)*, pages 1–3.
- Ge, C., Chen, X., Wang, M., and Wang, J. (2022). Deep baseline network for time series modeling and anomaly detection. page 1137 – 1142. Cited by: 0.
- Islam, M. A., Yang, L., Ranganath, K., and Ren, S. (2018). Why some like it loud: Timing power attacks in multi-tenant data centers using an acoustic side channel. *Proc. ACM Meas. Anal. Comput. Syst.*, 2(1).
- Jingyi, Guo, Hu, J., Rui, Z., and Wang, Z. (2024). Admm-1dnet: Online monitoring method for outdoor mechanical equipment part signals based on deep learning and compressed sensing. *Applied Sciences*, 14(6).
- Katz, G. and Sonkin, E. (2019). Level optimization of pam-4 transmission with signal-dependent noise. *IEEE Photonics Journal*, 11(1):1–6.
- Killeen, J., Davis, I., Wang, J., and Bennett, G. J. (2023). Fan-noise reduction of data centre telecommunications’ server racks, with an acoustic metamaterial broadband, low-frequency sound-absorbing liner. *Applied Acoustics*, 203. Cited by: 31; All Open Access, Green Open Access, Hybrid Gold Open Access.
- Lee, C., Park, C., Jang, K., Moon, S., and Han, D. (2017). Dx: Latency-based congestion control for datacenters. *IEEE/ACM Transactions on Networking*, 25(1):335–348.

- Levy, M. and Hallstrom, J. O. (2017). A new approach to data center infrastructure monitoring and management (dcimm). In *2017 IEEE 7th Annual Computing and Communication Workshop and Conference (CCWC)*, pages 1–6.
- Liang, J., Liu, Y., Fang, M., and Xu, J. (2025). Fault prediction technology of data center based on voiceprint recognition. In *International Conference on Electronics, Electrical, and Information Engineering (ICEEIE 2025)*, volume 14003, pages 185–193. SPIE.
- Lin, S.-L. (2021). Application of machine learning to a medium gaussian support vector machine in the diagnosis of motor bearing faults. *Electronics*, 10(18).
- Liu, C. (2025). Research on noise suppression in optical communication of data centers based on multi core fiber. *IET Conference Proceedings*, 2025(2):103 – 107. Cited by: 0.
- Mebratu, D., John, J. J., Desai, R., and Khanna, R. (2022). Online server fan failure prediction by vibration analysis augmented by hardware and software telemetry. In *2022 21st IEEE Intersociety Conference on Thermal and Thermomechanical Phenomena in Electronic Systems (iTherm)*, pages 1–9.
- Mihalache, C.-M., Bigan, C., Panduru, V., and Tsakiris, C. (2019). Modelling of noise reduction for datacentre buildings fire protection with inert gas systems. *MATEC Web of Conferences*, 290:12006.
- Miljković, D. (2016). Noise within a data center. In *2016 39th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, pages 1145–1150.
- Petersen, K., Feldt, R., Mujtaba, S., and Mattsson, M. (2008). Systematic mapping studies in software engineering. *Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering*.
- Pisani, F., de Oliveira, F., Gama, E. S., Immich, R., Bittencourt, L. F., and Borin, E. (2020). Fog computing on constrained devices: Paving the way for the future iot. *Advances in Edge Computing: Massive Parallel Processing and Applications*, 35:22.
- Prevedelli, D., Bergamaschi, L., Acquaviva, A., Persia, F., and Massolini, R. (2025). A 0.1-26ghz serdes-based broadband white noise generator for ethernet compliance tests. *IEEE Transactions on Instrumentation and Measurement*, PP:1–1.
- Rodrigues, D. O., Santos, F. A., Filho, G. P. R., Akabane, A. T., Cabral, R., Immich, R., Junior, W. L., Cunha, F. D., Guidoni, D. L., Silva, T. H., Rosario, D., Cerqueira, E., Loureiro, A. A. F., and Villas, L. A. (2019). Computação urbana da teoria à prática: Fundamentos, aplicações e desafios. Technical report, Minicurso do Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC).
- Santo, Y., Immich, R., Dalmazo, B. L., and Riker, A. (2023). Fault detection on the edge and adaptive communication for state of alert in industrial internet of things. *Sensors*, 23(7).
- Sen Gupta, P. (2024). Phd forum abstract: Knowledge from noise: Emi-guided power monitoring. In *2024 23rd ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN)*, page 317–318. IEEE Press.

- Sevillano, X., Socoró, J. C., Alías, F., Bellucci, P., Peruzzi, L., Radaelli, S., Coppi, P., Nencini, L., Cerniglia, A., Bisceglie, A., Benocci, R., and Zambon, G. (2016). DYNA-MAP – development of low cost sensors networks for real time noise mapping. *Noise Mapping*, 3(1).
- Wasala, S., Stevens, L., Sosseh, R., and Persoons, T. (2022). Acoustic noise insulation for air-cooled data centre hard disk drive enclosures: Effect on thermal management. In *2022 28th International Workshop on Thermal Investigations of ICs and Systems (THERMINIC)*, pages 1–4.
- Wu, A., Zhu, C., Jiang, X., and Yang, Q. (2025). Streaming data anomaly detection in energy big data center using unsupervised learning. *2025 37th Chinese Control and Decision Conference (CCDC)*, pages 1776–1781.
- Wüstrich, L., Gallenmüller, S., Günther, S., Carle, G., and Pahl, M.-O. (2024). Shells bells: Cyber-physical anomaly detection in data centers. *MATEC Web of Conferences*, pages 1–10.
- Wüstrich, L., Gallenmüller, S., Pahl, M.-O., and Carle, G. (2022). AC/DCIM: Acoustic channels for data center infrastructure monitoring. *MATEC Web of Conferences*, pages 1–5.
- Yang, C.-W., Lo, Y.-C., Tsai, T.-L., and Wu, A.-Y. (2024). Memory-oriented structural pruning for anomalous sound detection system on microcontrollers. page 669 – 673. Cited by: 1.
- Yang, D. (2025). Modeling and key parameter identification method of data center thermal dynamic system towards demand response. *Electric Power Automation Equipment*, 45(4):186–193.
- Zeng, W., Zhang, C., Liang, X., Xia, J., Li, Y., and Lin, Y. (2025). Chaos-enhanced quantization noise injection via dual delta-sigma modulation for secure data center optical interconnects. In *2025 Asia Communications and Photonics Conference (ACP)*, pages 1–4.