MANUTENÇÃO PREDITIVA DE HELICÓPTEROS APOIADA EM HUMS BIG DATA ANALYTICS: UMA REVISÃO SISTEMÁTICA DA LITERATURA

Helicopter Predictive Maintenance Supported by HUMS and Big Data Analytics: A Systematic Literature Review

MARINA PRADO DA SILVA
UFF - UNIVERSIDADE FEDERAL FLUMINENSE

IARA TAMMELA
UFF - UNIVERSIDADE FEDERAL FLUMINENSE

RODOLFO CARDOSO
UFF - UNIVERSIDADE FEDERAL FLUMINENSE

ANDRE LUIS POLICANI FREITAS
UNIVERSIDADE ESTADUAL DO NORTE FLUMINENSE DARCY RIBEIRO - UENF

Comunicação:
O XIV SINGEP foi realizado em conjunto com a 14th Conferência Internacional do CIK (CYRUS Institute of Knowledge) e com a SPARK (Society for Promoting Academic Research and Knowledge), em formato híbrido, com sede presencial na UNINOVE - Universidade Nove de Julho, no Brasil.

Agradecimento à orgão de fomento:
Não se aplica.

MANUTENÇÃO PREDITIVA DE HELICÓPTEROS APOIADA EM HUMS BIG DATA ANALYTICS: UMA REVISÃO SISTEMÁTICA DA LITERATURA

Objetivo do estudo
Mapear as principais abordagens e lacunas sobre o uso de HUMS e Big Data Analytics na manutenção preditiva de helicópteros, investigando como essas tecnologias contribuem para a evolução da manutenção na aviação e os desafios de integração entre tecnologia e expertise humana.

Relevância/originalidade
O tema é recente e pouco consolidado. A originalidade reside em explorar o aproveitamento de dados subutilizados do HUMS e em posicionar a expertise humana como elemento central da manutenção preditiva, e não como alternativa marginal.

Metodologia/abordagem
Revisão sistemática conduzida segundo o método de Morandi e Camargo (2015), no âmbito da Design Science Research, com estratégia configurativa. Foram recuperados 1.228 documentos na base Scopus, dos quais 17 compuseram a síntese após triagem e avaliação de qualidade.

Principais resultados
Identificou-se ausência de consenso entre CBM e PdM, o papel do HUMS como origem do PHM, as limitações dos algoritmos embarcados e a emergência da manutenção baseada em conhecimento, revelando lacuna entre gerar dados e convertê-los em decisões de manutenção.

Contribuições teóricas/metodológicas
O estudo sintetiza os constructos teóricos do campo e sistematiza uma taxonomia de abordagens de manutenção preditiva, consolidando o entendimento sobre a integração entre dados e conhecimento humano e evidenciando a manutenção baseada em conhecimento como vertente legítima frente às soluções puramente

Contribuições sociais/para a gestão
As ferramentas de Business Intelligence despontam como alternativa prática para ampliar a análise de tendência e a correlação de parâmetros, apoiando decisões de manutenção mais seguras e eficientes, com impacto direto na segurança e nos custos da aviação offshore.

Palavras-chave: Manutenção preditiva, Helicópteros, HUMS, Big Data Analytics, Revisão sistemática

Helicopter Predictive Maintenance Supported by HUMS and Big Data Analytics: A Systematic Literature Review

Study purpose
To map the main approaches and gaps regarding the use of HUMS and Big Data Analytics in helicopter predictive maintenance, investigating how these technologies contribute to the evolution of maintenance in aviation and the challenges of integrating technology and human expertise.

Relevance / originality
The topic is recent and still poorly consolidated. Its originality lies in exploring the use of underutilized HUMS data and in positioning human expertise as a central element of predictive maintenance, rather than as a marginal alternative.

Methodology / approach
Systematic literature review conducted following the method of Morandi and Camargo (2015), within the Design Science Research approach, with a configurative strategy A total of 1,228 documents were retrieved from the Scopus database, of which 17 composed the synthesis after screening and

Main results
A lack of consensus between CBM and PdM was identified, along with the role of HUMS as the origin of PHM, the limitations of embedded algorithms, and the emergence of knowledge-based maintenance, revealing a gap between generating data and converting it into

Theoretical / methodological contributions
The study synthesizes the theoretical constructs of the field and systematizes a taxonomy of predictive maintenance approaches, consolidating the understanding of the integration between data and human knowledge and highlighting knowledge-based maintenance as a legitimate approach alongside purely algorithmic solutions.

Social / management contributions
Business Intelligence tools emerge as a practical alternative to expand trend analysis and parameter correlation, supporting safer and more efficient maintenance decisions, with a direct impact on the safety and costs of offshore aviation.

Keywords: Predictive maintenance, Helicopters, HUMS, Big Data Analytics, Systematic review

MANUTENÇÃO PREDITIVA DE HELICÓPTEROS APOIADA EM HUMS E BIG DATA ANALYTICS: UMA REVISÃO SISTEMÁTICA DA LITERATURA

1 Introdução

A manutenção deixou de ser compreendida apenas como o conjunto de ações destinadas a reparar um item avariado e passou a ser reconhecida como função estratégica das organizações. Kardec e Nascif (2013) sustentam que a missão da manutenção é garantir a disponibilidade da função dos equipamentos e instalações, atendendo aos processos de produção ou de serviço com confiabilidade, segurança, preservação ambiental e custo adequado. Nesse entendimento, encontrar o ponto de equilíbrio entre confiabilidade e disponibilidade torna-se um diferencial competitivo, sobretudo em setores de alta criticidade como o aeronáutico.

Na aviação, a garantia da aeronavegabilidade, condição da aeronave para operar com segurança, exige o cumprimento de programas de manutenção preventiva, com reflexos diretos sobre custos operacionais e disponibilidade das aeronaves. Contudo, observa-se uma tendência de migração de abordagens reativas para proativas, à medida que a verificação da integridade das aeronaves evolui da inspeção para o monitoramento contínuo, viabilizado pela multiplicação de sensores e pela crescente troca de dados entre sistemas embarcados e estações terrestres (Jha et al., 2017). Nesse contexto, os sistemas de monitoramento de saúde e uso (*Health and Usage Monitoring Systems* - HUMS) foram introduzidos na indústria de helicópteros como meio de aumentar a segurança e reduzir custos, possibilitando a manutenção baseada em condição (Camerini et al., 2018).

A relevância do tema é reforçada por evidências de segurança e econômicas. Dados do relatório de segurança da aviação *offshore* global indicam que as falhas de componentes, excetuados os motores, constituíram a principal categoria de ocorrências associadas a acidentes entre 2013 e 2022 (Greaves, 2023). Lee et al. (2023) ilustram essa preocupação ao analisarem um incidente ocorrido em 2016 com um helicóptero S-92A, o mesmo modelo aqui discutido, no qual a dificuldade de interpretação da interface do software do fabricante figurou entre os fatores contribuintes, uma vez que um alerta registrado pelo HUMS no dia anterior não foi identificado pela equipe de manutenção. No plano econômico, Verhagen e De Boer (2018) estimam que os custos de manutenção podem representar de 10% a 15% das despesas operacionais de uma companhia aérea, o que evidencia o potencial de ganho associado a estratégias preditivas mais eficazes.

Apesar de seu potencial, a exploração dos dados gerados pelo HUMS ainda esbarra em limitações práticas. Os softwares fornecidos pelos fabricantes tendem a operar sobre dados recentes e a apresentar informações de forma fragmentada, o que dificulta análises de tendência de longo prazo (Mechouche et al., 2019; Daouayry et al., 2019). Some-se a isso o fenômeno das “ilhas de informação isoladas”, no qual o armazenamento disperso e a dificuldade de compartilhamento comprometem a transformação de dados em ações para a manutenção (Jiao et al., 2018). Verifica-se, assim, um descompasso entre o volume de dados disponíveis e sua efetiva conversão em decisões de manutenção.

É precisamente diante desse descompasso que emerge o conceito de *Big Data Analytics*. Os dados capturados pelos sistemas embarcados das aeronaves apresentam as características que definem o *Big Data*: volume, variedade, velocidade e veracidade, o que torna a simples coleta insuficiente e exige capacidades analíticas capazes de processar, correlacionar e interpretar grandes quantidades de informação de diferentes naturezas (Kashpruk, Piskor-Ignatowicz e Baranowski, 2023). Nesse sentido, o *Big Data Analytics* compreende o conjunto de técnicas e ferramentas voltadas à extração de conhecimento útil a partir desses dados, oferecendo recursos de visualização, identificação de tendências e correlação de parâmetros

que ultrapassam as limitações dos softwares embarcados (Hussain, Zhang e Seema, 2023). Sua aplicação à manutenção aeronáutica desponta, portanto, como caminho promissor para converter o elevado volume de dados gerados pelo HUMS em decisões efetivas de manutenção preditiva, aproximando a capacidade tecnológica de coleta da expertise humana necessária à sua interpretação.

Do ponto de vista acadêmico, o tema mostra-se recente e ainda pouco consolidado. Stanton et al. (2023) identificaram uma lacuna quanto a pesquisas abrangentes dedicadas exclusivamente à manutenção preditiva na indústria aeronáutica, apontando que o foco atual recai majoritariamente sobre motores, em razão da escassez de conjuntos de dados publicamente disponíveis. Essa constatação reforça a pertinência de investigações voltadas ao aproveitamento dos demais sistemas monitorados pelo HUMS.

Diante desse cenário, formula-se o seguinte problema de pesquisa: de que forma o uso de HUMS e do *Big Data Analytics* podem contribuir para a evolução das práticas de manutenção preditiva na aviação, e quais lacunas permanecem para a integração entre tecnologia e expertise humana? Para respondê-lo, esta revisão tem por objetivo geral mapear as principais abordagens e lacunas sobre o tema. Como objetivos específicos, busca-se:

(i) caracterizar as estratégias de manutenção e o papel do HUMS na manutenção preditiva;
(ii) identificar as principais abordagens, potenciais e desafios do uso de *Big Data Analytics* na aviação; e
(iii) sintetizar os constructos e as lacunas de pesquisa que orientem trabalhos futuros voltados à integração entre dados e conhecimento humano.

2 Referencial Teórico

2.1 Estratégias de manutenção

A literatura técnica e normativa converge para a existência de três grandes categorias de manutenção: corretiva, preventiva e preditiva. A manutenção corretiva é executada após a ocorrência da falha, permitindo o máximo aproveitamento da vida útil do ativo, mas com desvantagens em segurança, disponibilidade e custos com reparos emergenciais (ABNT, 1994; Moleda et al., 2023). A manutenção preventiva, por sua vez, é realizada em intervalos predeterminados, reduzindo a probabilidade de falha ao custo de eventuais substituições prematuras de componentes ainda em condições de operação (Verhagen e De Boer, 2018).

A manutenção preditiva, também denominada manutenção controlada, fundamenta-se na aplicação sistemática de técnicas de análise e monitoramento para antecipar falhas (ABNT, 1994; Korvesis, Besseau e Vazirgiannis, 2018). Nesse âmbito, a manutenção baseada em condição (CBM) representa a transição das práticas de “falha e conserto” para a lógica de “prever e prevenir” (Tahan et al., 2017). A CBM articula-se ainda ao conceito de prognóstico e gestão da saúde (PHM), abordagem sistemática que integra conhecimentos e informações para otimizar decisões de manutenção no nível do sistema (Jiang, 2015).

2.2 Sistemas HUMS em helicópteros

Segundo Elasha e MBA (2016) e Yan et al. (2017), o HUMS foi desenvolvido na década de 1980 nas operações do Mar do Norte, motivado por acidentes atribuídos à falha da transmissão principal. Autoridades aeronáuticas, como a britânica *Civil Aviation Authority*, emitiram recomendações e, posteriormente, requisitos que tornaram obrigatório o monitoramento de vibração em determinadas categorias de helicópteros (Janak e Hadas, 2015). O sistema combina dois subsistemas complementares: o monitoramento da saúde (*Health*

Monitoring), voltado à detecção de danos incipientes, e o monitoramento do uso (*Usage Monitoring*), destinado à avaliação do consumo de vida útil de componentes críticos (Samuel e Pines, 2005).

Com o tempo, o HUMS deixou de restringir-se à medição do uso e passou a incorporar formas de detecção de falhas por processamento de sinais, registrando ocorrências além dos limites prescritos, as chamadas excedências, que podem subsidiar ações de inspeção. Essa combinação de sensores e processamento constitui uma capacidade de indicar a condição do item e a necessidade de intervenção, sendo hoje reconhecida como precursora dos sistemas de PHM em aeronaves (Hünemohr, Litzba e Rahimi, 2022).

Isto se torna possível pois além dos parâmetros operacionais e dos dados de vibração, o HUMS registra continuamente os resultados de autotestes (*Built-In Tests*) das unidades eletrônicas, gerando códigos de falha que documentam eventos e anomalias dos sistemas embarcados. Esses registros, contudo, nem sempre são acompanhados de alarmes perceptíveis à tripulação ou aos técnicos, permanecendo frequentemente subutilizados como fonte de informação para a manutenção (Samuel e Pines, 2005; Yan et al., 2017).

2.3 *Big Data*, *Business Intelligence* e manutenção baseada em conhecimento

O volume expressivo de dados capturados pelos sistemas embarcados aproxima a manutenção aeronáutica do universo do *Big Data*, caracterizado pelas dimensões de volume, variedade, velocidade e veracidade. Tais dimensões tornam a simples coleta de dados insuficiente, exigindo a incorporação de capacidades analíticas que permitam processar, interpretar e agir sobre as informações em tempo hábil (Kashpruk, Piskor-Ignatowicz e Baranowski, 2023). Nesse contexto, ferramentas de *Business Intelligence* (BI) ganham espaço por viabilizarem o processamento de grandes volumes de dados em diferentes formatos, oferecendo visualização de indicadores-chave de desempenho, dashboards interativos e relatórios customizados que favorecem a identificação de correlações relevantes (Hussain, Zhang e Seema, 2023).

Paralelamente, consolida-se a noção de manutenção baseada em conhecimento (*Knowledge-Based Maintenance* – KBM), que compreende a manutenção como um domínio intensivo em conhecimento nos níveis estratégico, tático e operacional (Nemeth, Ansari e Sihn, 2019). Para Wan et al. (2019), o conhecimento aplicado à manutenção reúne informações e recursos que auxiliam os engenheiros na decisão de planejamento, podendo estar registrado em documentos, codificado em sistemas ou retido na memória dos profissionais. A KBM aproxima-se, assim, dos sistemas especialistas, que buscam estruturar o saber acumulado em bases de conhecimento continuamente enriquecidas (Moleda et al., 2023).

3 Metodologia

A revisão foi conduzida como uma Revisão Sistemática da Literatura (RSL), seguindo o método proposto por Morandi e Camargo (2015) no âmbito da Design Science Research (DSR), conforme Dresch, Lacerda e Miguel (2015). O caráter sistemático justifica-se pela necessidade de o pesquisador conhecer o que já foi investigado, como foi investigado, quais resultados foram alcançados e, sobretudo, o que ainda não foi explorado. A estratégia de revisão adotada foi configurativa, isto é, voltada a interpretar e organizar conceitos para gerar entendimento sobre o fenômeno, e não a agregar estatisticamente resultados (Morandi e Camargo, 2015). A questão norteadora replicou o problema de pesquisa apresentado na Introdução.

A presente revisão integra-se a uma pesquisa mais ampla, estruturada segundo as cinco etapas da DSR propostas por Lacerda et al. (2013): (i) identificação e conscientização do

problema; (ii) proposição de um artefato; (iii) desenvolvimento do artefato; (iv) avaliação do artefato; e (v) conclusão. A conscientização do problema é sustentada pela pesquisa documental e pela revisão da literatura. Nessa etapa foram sistematizados os principais conceitos do tema: estratégias de manutenção, HUMS, CBM, *Big Data Analytics* e manutenção baseada em conhecimento. Tais conceitos constituem a base teórica que orienta as etapas subsequentes de proposição, desenvolvimento e avaliação do artefato. O presente artigo concentra-se na etapa de conscientização, correspondente à revisão sistemática, enquanto as demais etapas constituem objeto de trabalho complementar.

A base científica Scopus foi definida como fonte principal, complementada por manuais técnicos e normas. Estabeleceu-se o horizonte temporal de 2010 a 2025, justificado por pesquisa exploratória prévia que evidenciou o crescimento significativo de publicações sobre o tema a partir de 2010. Foram adotados como critérios de inclusão as publicações cujo tema se alinhava à questão da revisão; como critérios de exclusão, o ano de publicação anterior a 2010 e a ocorrência de termos homônimos (por exemplo, o uso da sigla HUMS em contextos médicos). O Quadro 1 sintetiza as oito combinações de termos empregadas.

#	**Combinação de termos (Scopus)**	**Objetivo da busca**
1	(maintenance) AND (predictive OR CBM OR PHM) AND (big AND data)	Uso de Big Data em manutenção preditiva em geral
2	(maintenance) AND (predictive OR CBM OR PHM) AND (HUMS) AND (helicopter)	Manutenção preditiva de helicópteros com HUMS
3	(maintenance) AND (predictive OR CBM OR PHM) AND (big AND data) AND (hums OR helicopter)	Combinação de Big Data com HUMS ou helicópteros
4	((maintenance) AND (predictive OR CBM OR PHM) AND (big AND data) AND ((hums OR helicopter OR aviation OR aeronautical)))	Big Data e HUMS em diferentes aeronaves
5	(maintenance) AND (predictive OR CBM OR PHM) AND (big data OR flight data)	Dados de voo associados ao Big Data
6	(fail* OR fault) AND (predictive OR CBM OR PHM) AND (big data) AND (helicopter OR aircraft OR aviation)	Falhas e defeitos em aeronaves com Big Data
7	(maintenance AND predictive OR CBM OR PHM AND (big data OR flight data) AND (sensor data OR health monitoring) AND failure prediction)	Dados de voo e monitoramento de saúde na previsão de falhas
8	(maintenance AND predictive OR CBM OR PHM AND (data-driven AND maintenance) AND failure AND (helicopter OR aircraft))	Manutenção preditiva orientada a dados em aeronaves

Quadro 1: Estratégias de busca empregadas.
Fonte: Adaptado de Autoria suprimida (2025).

A busca foi conduzida na base Scopus, definida como fonte principal por sua abrangência multidisciplinar, aplicando-se as oito estratégias apresentadas no Quadro 1 aos campos de título, resumo e palavras-chave. As combinações articularam, por meio dos operadores booleanos AND e OR, três eixos derivados da questão de pesquisa: as estratégias

de manutenção (maintenance, predictive, CBM, PHM), as tecnologias de dados (big data, flight data, sensor data) e o domínio de aplicação (*helicopter, aircraft, aviation,* HUMS). A aplicação conjunta das oito estratégias resultou em 1.228 documentos identificados, ponto de partida do processo de triagem.

Sobre o conjunto inicial de 1.228 documentos, foram aplicados os filtros disponíveis na própria base, correspondentes aos critérios de exclusão de ano de publicação anterior a 2010, idioma distinto do português e do inglês e ocorrência de termos homônimos, como o uso da sigla HUMS em contextos médicos. Essa etapa reduziu o conjunto para 337 documentos, excluindo 891 registros não aderentes.

Os 337 documentos remanescentes foram submetidos à leitura de título e resumo, etapa em que se avaliou a aderência preliminar de cada estudo à questão de revisão. Foram descartados 220 registros cujo escopo não se alinhava ao objeto de pesquisa, resultando em 117 documentos. Em seguida, procedeu-se à remoção de registros duplicados, decorrentes da sobreposição entre as oito estratégias de busca, o que conduziu a um conjunto de 108 documentos distintos.

Os 108 documentos foram então submetidos à leitura integral, associada à avaliação de qualidade e à verificação de disponibilidade de acesso. A avaliação seguiu os três critérios propostos por Dresch et al. (2015) e Harden e Gough (2012): qualidade metodológica, relevância para a questão de revisão e aderência ao foco. Cada estudo foi classificado em alta, média ou baixa correlação, mantendo-se apenas aqueles com alta correlação simultânea nos três critérios. Os demais, somados a um documento indisponível para acesso integral, totalizaram 91 exclusões, resultando nos 17 estudos que compõem a síntese da revisão.

A Figura 1 sintetiza, em fluxograma, o processo de identificação, triagem e inclusão dos estudos, desde os 1.228 documentos recuperados até os 17 selecionados.

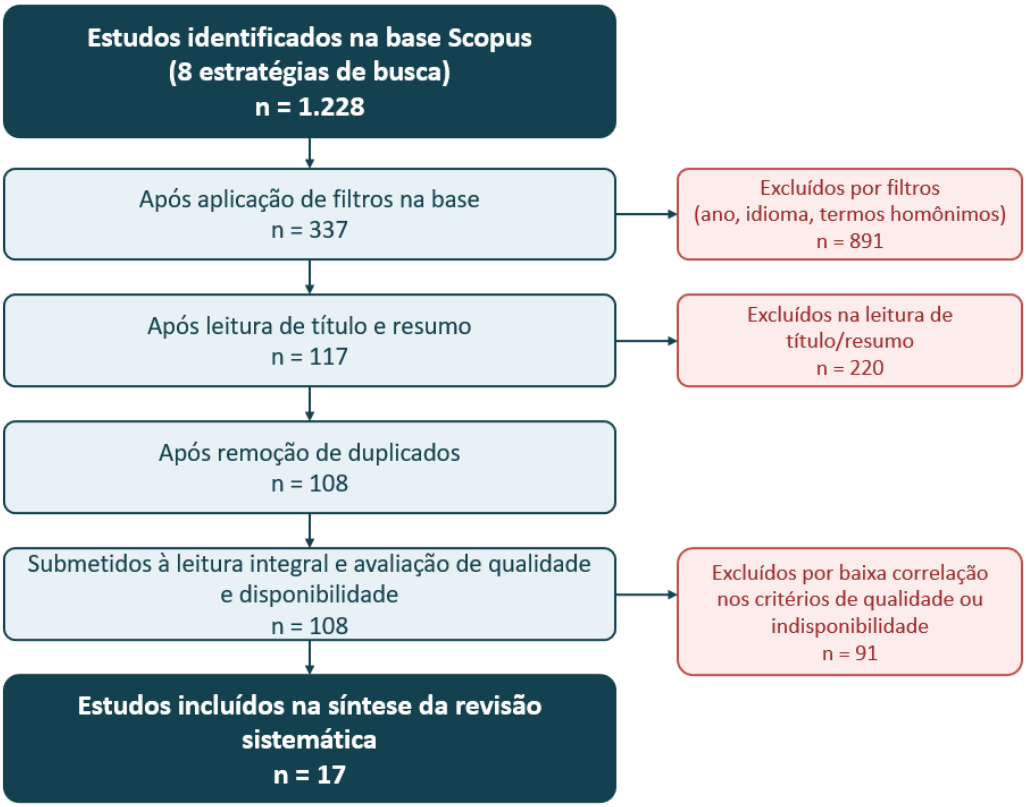


Figura 1: Fluxo de identificação, triagem e inclusão dos estudos.
Fonte: Adaptado de Autoria suprimida (2025).

4 Análise dos resultados e Discussões

4.1 Panorama dos estudos selecionados

Dos 108 artigos submetidos à leitura integral, apenas um não estava disponível para acesso. A distribuição por área revelou concentração em três campos: Aviação/Aeroespacial, Indústria Geral e Manufatura. Após a avaliação de qualidade, foram selecionados 17 estudos, com predomínio da área aeronáutica, seguida por publicações de caráter mais genérico. Observou-se, ainda, que a maior parte das pesquisas em manutenção preditiva na aviação concentra-se na estimativa da vida útil remanescente de componentes, o que reforça a relevância de abordagens voltadas à visualização de dados e à correlação de parâmetros operacionais.

A Figura 2 apresenta a distribuição dos 108 estudos submetidos à leitura integral segundo a área de conhecimento, evidenciando a predominância dos campos aeronáutico e industrial e a natureza multissetorial da produção sobre manutenção preditiva orientada a dados.

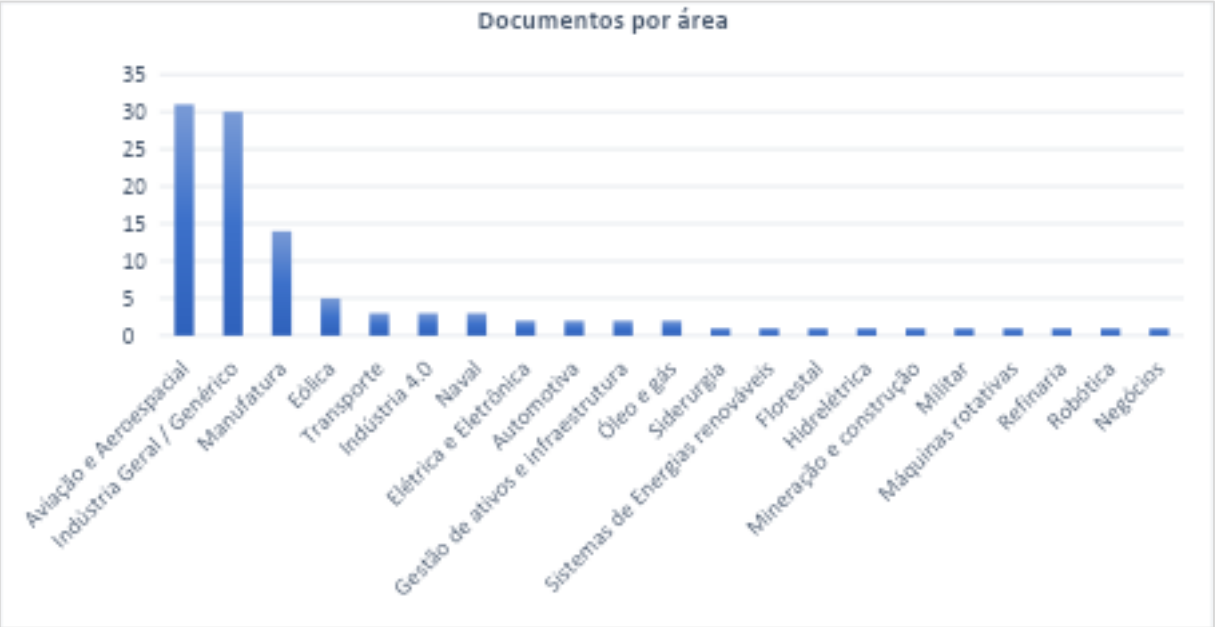


Figura 2: Distribuição dos estudos por área de conhecimento.
Fonte: Autoria suprimida (2025).

O quadro 2 apresenta os 17 estudos que compuseram a síntese final, com seus respectivos títulos, autores e ano de publicação, oferecendo transparência quanto ao corpus analisado.

Autores e ano	Título abreviado
Larrinaga et al. (2019)	A Big Data implementation of the MANTIS reference architecture for predictive maintenance
Bieber e Verhagen (2022)	A generic framework for prognostics of complex systems
Maione et al. (2024)	A machine learning framework for condition-based maintenance of marine diesel engines
Vallim Filho et al. (2022)	A machine learning modeling framework for predictive maintenance based on equipment load cycle

Ersöz et al. (2022)	A systematic literature review of the predictive maintenance from transportation systems aspect
Hussain, Zhang e Seema (2023)	Adoption of big data analytics for energy pipeline condition assessment
Ranasinghe et al. (2022)	Advances in Integrated System Health Management for aerospace applications
Teixeira, Lopes e Braga (2020)	Condition-based maintenance implementation: a literature review
Daouayry et al. (2019)	Data-centric helicopter failure anticipation: the MGB oil pressure virtual sensor case
Jimenez, Bouhmala e Gausdal (2020)	Developing a predictive maintenance model for vessel machinery
Moleda et al. (2023)	From corrective to predictive maintenance: a review for the power industry
Tong e Bakhshi (2022)	Industry 4.0 for aerospace manufacturing: CBM methodology and challenges
Stanton et al. (2023)	Predictive maintenance analytics and implementation for aircraft
Verhagen e De Boer (2018)	Predictive maintenance for aircraft components using proportional hazard models
Mallioris, Aivazidou e Bechtsis (2024)	Predictive maintenance in Industry 4.0: a systematic multi-sector mapping
Fu e Avdelidis (2023)	Prognostic and health management of critical aircraft systems and components
Hünemohr, Litzba e Rahimi (2022)	Usage monitoring of helicopter gearboxes with ADS-B flight data

Quadro 2: Estudos selecionados para a síntese da revisão.
Fonte: Adaptado de Autoria suprimida (2025).

4.2 Divergências conceituais entre CBM e PdM

Uma das constatações centrais da revisão é a ausência de consenso quanto às definições e fronteiras entre manutenção baseada em condição (CBM) e manutenção preditiva (PdM). Maione et al. (2024) observam que diferentes autores empregam nomenclaturas distintas para estratégias semelhantes. Larrinaga et al. (2019) posicionam a CBM como forma de manutenção preditiva, fundamentada no monitoramento contínuo da condição dos ativos. Vallim Filho et al. (2022) tratam a CBM como subcategoria da PdM, entendendo esta última como evolução que incorpora técnicas avançadas de ciência de dados, como aprendizado de máquina.

Mallioris, Aivazidou e Bechtsis (2024) avançam na ideia de complementaridade: a CBM atuaria sobre o estado atual do equipamento, ao passo que a PdM ampliaria o horizonte ao estimar a vida útil remanescente com apoio de inteligência artificial. Já Tong e Bakhshi (2022) descrevem a CBM como etapa inicial de coleta e análise de dados em um processo incremental rumo a modelos preditivos e prescritivos. Verhagen e De Boer (2018) e Stanton et al. (2023) reforçam, na aviação, a CBM como base fundamental para a PdM em sistemas críticos, nos quais o monitoramento da condição é pré-requisito para qualquer prognóstico confiável. Essa pluralidade conceitual justifica a adoção de abordagens flexíveis, capazes de acomodar diferentes interpretações sem restringir a análise.

Aprofundando essa organização, Mallioris et al. (2024) propõem que os modelos de PdM sejam agrupados em três categorias: baseados em modelos físicos, que empregam leis

físicas e funções de distribuição de probabilidade para representar o comportamento do sistema; baseados em conhecimento, que partem de regras, casos anteriores e experiências humanas codificadas em bases de conhecimento; e baseados em dados, que aplicam técnicas de aprendizado de máquina, aprendizado profundo, estatística e modelos híbridos para extrair padrões sem necessariamente conhecer a estrutura física do sistema. Essa taxonomia é particularmente útil ao presente estudo, pois posiciona a abordagem centrada no conhecimento humano, como uma das três vertentes legítimas da manutenção preditiva, e não como alternativa marginal às soluções puramente algorítmicas.

4.3 O HUMS como base da CBM na aviação

Há convergência na literatura quanto ao papel singular do HUMS na indústria de helicópteros, frequentemente reconhecido como origem dos atuais sistemas de PHM (Hünemohr, Litzba e Rahimi, 2022). Ranasinghe et al. (2022) destacam sua função de viabilizar a coleta, o processamento e a análise de parâmetros críticos de desempenho, permitindo detecção precoce de falhas. Stanton et al. (2023) ressaltam que a transformação dos dados coletados em conhecimento útil depende tanto da confiabilidade dos sensores quanto da competência analítica da organização.

Vale ressaltar que o HUMS não é o único sistema de uma aeronave capaz de armazenar dados. Embora os demais sistemas não tenham a manutenção como objetivo final, estudos como o de Hünemohr, Litzba e Rahimi (2022) demonstram como fontes de dados operacionais alternativas, como os registros ADS-B (*Automatic Dependent Surveillance-Broadcast)*, podem complementar ou até substituir parcialmente os dados típicos de HUMS, permitindo a inferência de padrões de uso que impactam a integridade das caixas de engrenagem principais dos helicópteros (MGB). De modo semelhante, Daouayry et al. (2019) apresentam o uso de sensores virtuais para estimar parâmetros críticos de operação, como a pressão de óleo na MGB, oferecendo uma abordagem centrada em dados para a antecipação de falhas. Essas iniciativas refletem uma tendência ampla no setor aeronáutico, no qual *Big Data* e técnicas analíticas ganham espaço como instrumentos de valorização do conhecimento operacional, permitindo transformar dados brutos em inteligência aplicável à manutenção.

4.4 Limitações dos sistemas embarcados

Um ponto recorrente refere-se às limitações analíticas dos algoritmos embarcados. Daouayry et al. (2019) apontam que tais algoritmos operam apenas com dados recentes e não realizam análises de tendência baseadas em histórico, o que restringe seu acionamento a situações em que a falha já é crítica. Mechouche et al. (2019) acrescentam que a limitação de capacidade computacional e o uso de dados gerados exclusivamente no voo corrente comprometem a antecipação de degradações sutis. Essas restrições fundamentam a proposição de dashboards customizados capazes de sustentar análises temporais e a integração de múltiplas fontes de dados.

Além das restrições computacionais, Verhagen e De Boer (2018) alertam que as abordagens estatísticas aplicadas à manutenção aeronáutica frequentemente ignoram a complexidade operacional inerente às aeronaves. Fatores como o ambiente de operação influenciam diretamente os modos e os tempos de falha: uma aeronave que opera em ambientes quentes e arenosos está sujeita a condições substancialmente distintas daquelas que operam em ambientes frios e úmidos. Esse aspecto é especialmente relevante para a aviação offshore e reforça a necessidade de análises contextualizadas, capazes de incorporar variáveis operacionais ao processo decisório.

4.5 Manutenção baseada em conhecimento (KBM)

Embora a estratégia inicial da revisão se concentrasse em termos como PdM e CBM, a análise dos resultados fez emergir uma abordagem complementar ainda pouco explorada: a manutenção baseada em conhecimento. O conceito foi identificado de maneira implícita em Jimenez, Bouhmala e Gausdal (2020), que enfatizam a importância do conhecimento acumulado por especialistas como fundamento para decisões de manutenção, sobretudo quando os dados disponíveis são limitados ou os modelos automatizados não se aplicam. Mallioris et al. (2024) também situam a KBM entre os modelos de PdM, ao lado das abordagens baseadas em modelos físicos e em dados.

O fundamento conceitual da KBM remete à chamada Pirâmide do Conhecimento, na qual dados brutos, quando contextualizados e interpretados, transformam-se em informação e, posteriormente, em conhecimento aplicável à decisão (Wan et al., 2019). Nessa perspectiva, o conhecimento aplicado à manutenção abrange desde regras de diagnóstico e procedimentos até a experiência tácita retida na memória dos profissionais. Moleda et al. (2023) discutem, nesse âmbito, os sistemas especialistas, que buscam capturar e estruturar o saber de profissionais experientes em uma base de conhecimento continuamente enriquecida, funcionando como ponte entre o conhecimento tácito e sua aplicação prática sistematizada.

Nemeth, Ansari e Sihn (2019) alertam, contudo, para uma lacuna importante: ainda faltam abordagens práticas que expliquem como os ativos de conhecimento geram valor nas organizações e como medir e desenvolver, de forma estruturada, essa capacidade. A KBM reforça, portanto, o posicionamento de soluções centradas no ser humano, nas quais dados e julgamento técnico se integram para apoiar a decisão.

4.6 *Big Data Analytics*: potenciais, desafios e *frameworks*

A adoção de abordagens preditivas pressupõe não apenas o uso de sensores, mas a capacidade de transformar dados em conhecimento útil. Hussain, Zhang e Seema (2023) apontam dificuldades na consolidação de uma compreensão teórica robusta sobre o uso de *Big Data* em ambientes críticos, bem como a escassez de *frameworks* consolidados e de estudos voltados aos aspectos gerenciais. Os autores destacam ainda a necessidade de equipes multidisciplinares capazes de interpretar os dados com profundidade, evidenciando que a implementação depende tanto da tecnologia quanto da qualificação das pessoas.

Essas barreiras não são apenas técnicas, mas também organizacionais. Um estudo de caso conduzido por Kortian et al. (2024) em uma empresa ferroviária revelou desafios relacionados à qualidade dos dados, à integração entre sistemas e à ausência de uma cultura organizacional orientada a dados, fatores que dificultam a consolidação de ambientes robustos de analytics. De forma complementar, Larrinaga et al. (2019) destacam desafios de ordem técnica, como transmitir eficientemente os dados a partir do sistema físico, criar representações padronizadas e processar grandes fluxos de forma escalável, respeitando restrições de tempo real e de comunicação.

Em contraponto ao investimento exclusivo em algoritmos cada vez mais complexos, Bieber e Verhagen (2022) argumentam que abordagens mais simples podem apresentar desempenho superior quando aplicadas a sistemas reais, defendendo *frameworks* genéricos que permitam selecionar o algoritmo mais adequado a cada componente. Nesse panorama, as soluções de BI ampliam a capacidade analítica das equipes ao processar e representar graficamente grandes volumes de dados. Iniciativas de sistematização também são observadas em Fu e Avdelidis (2023), que descrevem uma sequência estruturada — da coleta e limpeza dos dados à exploração, modelagem, validação e, finalmente, visualização e interpretação — e em Tong e Bakhshi (2022), que dividem a implementação em três fases: identificação de partes

críticas e infraestrutura de sensores; uso prático das informações com ferramentas de visualização e BI; e implantação em escala com definição de alertas e mecanismos de resposta.

4.7 Síntese dos constructos e lacunas identificadas

A sistematização dos constructos extraídos da revisão fornece o vocabulário conceitual necessário à especificação de soluções para o problema estudado (Lacerda et al., 2013). O Quadro 3 consolida os principais conceitos, seus autores de referência e suas implicações para o desenho de artefatos voltados à manutenção preditiva de helicópteros.

Conceito	Autores	Implicação
Divergências entre CBM e PdM	Larrinaga et al. (2019); Vallim Filho et al. (2022); Mallioris et al. (2024)	Necessidade de análises flexíveis, sem categorização restritiva
HUMS como base da CBM na aviação	Stanton et al. (2023); Ranasinghe et al. (2022); Hünemohr et al. (2022)	Uso dos dados de HUMS como principal fonte de informação
Limitações dos sistemas embarcados	Mechouche et al. (2019); Daouayry et al. (2019)	Dashboards que possibilitem análise de tendência e histórico
Conhecimento humano e KBM	Jimenez et al. (2020); Nemeth et al. (2019); Moleda et al. (2023)	Especialista como intérprete central, complementando a análise automática
Big Data Analytics e seus desafios	Hussain, Zhang e Seema (2023); Verhagen e De Boer (2018)	Integração de ferramentas de BI para processar e visualizar dados
Frameworks para manutenção preditiva	Fu e Avdelidis (2023); Tong e Bakhshi (2022)	Estruturas de implementação que orientam a sistematização de artefatos

Quadro 3: Síntese dos constructos extraídos da RSL.
Fonte: Adaptado de Autoria suprimida (2025).

A leitura conjunta dos estudos permite identificar uma lacuna central: embora existam inúmeros avanços em algoritmos e modelos preditivos, a aplicação prática em sistemas reais ainda é limitada pela ausência de *frameworks* consolidados, pela dificuldade de integração de dados e pela subutilização da expertise humana. A KBM desponta como caminho promissor, e as ferramentas de BI, como alternativa prática para ampliar a análise de tendência e a correlação de parâmetros sem a dependência de algoritmos avançados.

5 Considerações Finais

A revisão sistemática permitiu mapear o panorama atual sobre o uso de HUMS e *Big Data Analytics* na manutenção preditiva de helicópteros, respondendo à questão de pesquisa proposta. Constatou-se que o HUMS, embora eficiente na coleta de dados e na detecção de falhas, apresenta limitações nas análises precoces, demandando estratégias complementares de análise temporal e de integração de dados. Verificou-se, ainda, a persistência de divergências conceituais entre CBM e PdM e a emergência da manutenção baseada em conhecimento como vertente capaz de legitimar a integração entre expertise humana e ferramentas analíticas.

A principal contribuição deste trabalho reside na síntese dos constructos e na identificação de uma lacuna consistente: a distância entre a capacidade tecnológica de gerar

dados e a efetiva conversão desses dados em decisões de manutenção. As soluções de *Business Intelligence* apresentam-se como resposta prática a esse desafio, na medida em que ampliam a análise de tendência e a correlação de parâmetros sem exigir a sofisticação de modelos algorítmicos complexos, mostrando-se especialmente aderentes à realidade da aviação offshore.

Como agenda futura, recomenda-se o desenvolvimento e a validação empírica de artefatos que operacionalizem a integração entre dados de HUMS e conhecimento humano, bem como a investigação de sua aplicabilidade a diferentes modelos de aeronaves e a programas de confiabilidade formalmente aceitos pelas autoridades aeronáuticas.

6 Declaração de Uso de Inteligência Artificial

Em conformidade com a Política sobre Uso de Inteligência Artificial Generativa do SINGEP, declara-se que este trabalho utilizou a ferramenta de IA Generativa Microsoft Copilot como apoio às seguintes atividades: paráfrase e adequação da redação a partir de conteúdo de autoria própria (dissertação de mestrado), organização e estruturação textual do manuscrito. Todo o conteúdo científico, incluindo a definição do problema de pesquisa, a metodologia, os dados, os resultados, as análises, as figuras e as conclusões são de autoria intelectual humana. Os autores realizaram revisão crítica integral do manuscrito, verificando a exatidão das informações, a validade das referências e a consistência dos dados, e assumem integral responsabilidade pelo trabalho submetido. A ferramenta de IA não é autora nem coautora do trabalho.

7 Referências

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR 5462: confiabilidade e mantenabilidade.* Rio de Janeiro: ABNT, 1994.

AUTOR. Título suprimido para avaliação às cegas. 2025.

BIEBER, M.; VERHAGEN, W. J. C. A generic framework for prognostics of complex systems. *Aerospace*, v. 9, n. 12, p. 839, 2022.

CAMERINI, V.; COPPOTELLI, G.; BENDISCH, S. Fault detection in operating helicopter drivetrain components based on support vector data description. *Aerospace Science and Technology*, v. 73, p. 48–60, 2018.

DAOUAYRY, N. et al. Data-centric helicopter failure anticipation: the MGB oil pressure virtual sensor case. In: *2019 IEEE International Conference on Big Data (Big Data)*. Los Angeles: IEEE, 2019. p. 1784–1793.

DRESCH, A.; LACERDA, D. P.; MIGUEL, P. A. C. Uma análise distintiva entre o estudo de caso, a pesquisa-ação e a design science research. *Revista Brasileira de Gestão de Negócios*, v. 17, n. 56, p. 1116–1133, 2015.

ELASHA, F.; MBA, D. Improving condition indicators for helicopter health and usage monitoring systems. *International Journal of Structural Integrity*, v. 7, n. 4, 2016.

ERSÖZ, O. Ö. et al. A systematic literature review of the predictive maintenance from transportation systems aspect. *Sustainability*, v. 14, n. 21, p. 14536, 2022.

FU, S.; AVDELIDIS, N. P. Prognostic and health management of critical aircraft systems and components: an overview. *Sensors*, v. 23, n. 19, p. 8124, 2023.

GREAVES, M. HeliOffshore Safety Performance Report. 2023. Disponível em: https://www.helioffshore-industry-report.org/accident-types. Acesso em: 11 jul. 2023.

HARDEN, A.; GOUGH, D. Quality and relevance appraisal. In: GOUGH, D.; OLIVER, S.; THOMAS, J. (Ed.). *An introduction to systematic reviews.* London: SAGE, 2012. p. 153–178.

HÜNEMOHR, D.; LITZBA, J.; RAHIMI, F. Usage monitoring of helicopter gearboxes with ADS-B flight data. *Aerospace*, v. 9, n. 11, p. 647, 2022.

HUSSAIN, M.; ZHANG, T.; SEEMA, M. Adoption of big data analytics for energy pipeline condition assessment – a systematic review. *International Journal of Pressure Vessels and Piping*, v. 206, p. 105061, 2023.

JANAK, L.; HADAS, Z. Machine tool health and usage monitoring system: an initial analyses. *MM Science Journal*, v. 4, p. 794–798, 2015.

JHA, A. K.; NAYAK, S.; VEERABHADRAPPA, N. K. An architecture for performing real time integrated health monitoring of aircraft systems using avionics big data. In: *2017 2nd International Conference on Computational Systems and Information Technology for Sustainable Solution (CSITSS)*. Bengaluru: IEEE, 2017. p. 1–5.

JIANG, R. *Introduction to quality and reliability engineering.* Beijing: Science Press; Berlin: Springer, 2015.

JIAO, X.; JING, B.; JIAO, B. Research of prognostic and health management for avionics system based on massive data mining. In: *2018 Prognostics and System Health Management Conference (PHM-Chongqing)*. Chongqing: IEEE, 2018. p. 350–357.

JIMENEZ, V. J.; BOUHMALA, N.; GAUSDAL, A. H. Developing a predictive maintenance model for vessel machinery. *Journal of Ocean Engineering and Science*, v. 5, n. 4, p. 358–386, 2020.

KARDEC, A.; NASCIF, J. *Manutenção: função estratégica.* 4. ed. Rio de Janeiro: Qualitymark, 2013.

KASHPRUK, N.; PISKOR-IGNATOWICZ, C.; BARANOWSKI, J. Time series prediction in Industry 4.0: a comprehensive review and prospects for future advancements. *Applied Sciences,* v. 13, n. 22, p. 12374, 2023.

KORTIAN, Viken; PAL, Souvik; GHEVONDIAN, Nejhdeh; HARRISON, Norma. Challenges and issues in implementing and operationalising big data analytics capabilities in a major Australian railway organisation: a case study. *SN Computer Science*, v. 5, n. 639, 2024. DOI: 10.1007/s42979-024-02953-8.

KORVESIS, P.; BESSEAU, S.; VAZIRGIANNIS, M. Predictive maintenance in aviation: failure prediction from post-flight reports. In: *2018 IEEE 34th International Conference on Data Engineering (ICDE)*. Paris: IEEE, 2018. p. 1414–1422.

LACERDA, D. P. et al. Design science research: método de pesquisa para a engenharia de produção. *Gestão & Produção*, v. 20, n. 4, p. 741–761, 2013.

LARRINAGA, F. et al. A big data implementation of the MANTIS reference architecture for predictive maintenance. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, v. 233, n. 10, p. 1361–1375, 2019.

LEE, Juseong et al. Analyzing emerging challenges for data-driven predictive aircraft maintenance using agent-based modeling and hazard identification. *Aerospace*, v. 10, n. 2, p. 186, 2023.

MAIONE, F. et al. A machine learning framework for condition-based maintenance of marine diesel engines: a case study. *Algorithms*, v. 17, n. 9, p. 411, 2024.

MALLIORIS, P.; AIVAZIDOU, E.; BECHTSIS, D. Predictive maintenance in Industry 4.0: a systematic multi-sector mapping. *CIRP Journal of Manufacturing Science and Technology*, v. 50, p. 80–103, 2024.

MECHOUCHE, A.; DAOUAYRY, N.; CAMERINI, V. Helicopter big data processing and predictive analytics: feedback and perspectives. In: *45th European Rotorcraft Forum (ERF 2019)*. Varsóvia, 2019. p. 143.

MOLĘDA, M. et al. From corrective to predictive maintenance – a review of maintenance approaches for the power industry. *Sensors*, v. 23, n. 13, p. 5970, 2023.

MORANDI, M. I. W. M.; CAMARGO, L. F. R. Revisão sistemática da literatura. In: DRESCH, A.; LACERDA, D. P.; ANTUNES JÚNIOR, J. A. V. *Design science research: método de pesquisa para avanço da ciência e tecnologia.* Porto Alegre: Bookman, 2015. p. 141–172.

NEMETH, T.; ANSARI, F.; SIHN, W. A maturity assessment procedure model for realizing knowledge-based maintenance strategies in smart manufacturing enterprises. In: *25th International Conference on Production Research (ICPR 2019)*. Chicago, 2019.

RANASINGHE, K. et al. Advances in integrated system health management for mission-essential and safety-critical aerospace applications. *Progress in Aerospace Sciences*, v. 128, p. 100758, 2022.

SAMUEL, P. D.; PINES, D. J. A review of vibration-based techniques for helicopter transmission diagnostics. *Journal of Sound and Vibration*, v. 282, n. 1–2, p. 475–508, 2005.

STANTON, I. et al. Predictive maintenance analytics and implementation for aircraft: challenges and opportunities. *Systems Engineering*, v. 26, n. 2, p. 216–237, 2023.

TAHAN, M. et al. Performance-based health monitoring, diagnostics and prognostics for condition-based maintenance of gas turbines: a review. *Applied Energy*, v. 198, p. 122–144, 2017.

TEIXEIRA, H. N.; LOPES, I.; BRAGA, A. C. Condition-based maintenance implementation: a literature review. Procedia Manufacturing, v. 51, p. 228–235, 2020.

TONG, X.; BAKHSHI, R.; PRABHU, C. Industry 4.0 for aerospace manufacturing: condition-based maintenance methodology, implementation and challenges. In: *Annual Conference of the PHM Society*. [S. l.]: PHM Society, 2022.

VALLIM FILHO, A. R. A. et al. A machine learning modeling framework for predictive maintenance based on equipment load cycle: an application in a real world case. *Energies*, v. 15, n. 10, p. 3724, 2022.

VERHAGEN, W. J. C.; DE BOER, L. W. M. Predictive maintenance for aircraft components using proportional hazard models. *Journal of Industrial Information Integration*, v. 12, p. 23–30, 2018.

WAN, S. et al. A knowledge based machine tool maintenance planning system using case-based reasoning techniques. *Robotics and Computer-Integrated Manufacturing*, v. 58, p. 80–96, 2019.

YAN, H. et al. The investigation and demand analysis of HUMS on the civil helicopter. In: *2017 Prognostics and System Health Management Conference (PHM-Harbin)*. Harbin: IEEE, 2017. p. 1–6.