

Inteligência Artificial aplicada ao Sistema de Gerenciamento de Manutenções (SIGMAN): Um Novo Paradigma de Manutenção Naval para a Marinha do Brasil

Autoria: C-ApA-IM-2024-DGePM-32

RESUMO

Este trabalho investiga a Inteligência Artificial (IA) como um novo paradigma de manutenção aplicado ao Sistema de Gerenciamento de Manutenção (SIGMAN) da Marinha do Brasil, visando transformar as práticas de manutenção preventiva, preditiva e prescritiva dos meios navais. Com uma metodologia baseada em pesquisa-ação e revisão bibliográfica estruturada, foi realizada uma análise integrativa para identificar oportunidades e desafios na implementação de IA no SIGMAN. Os resultados indicam que a IA pode reduzir tempos de inatividade e custos operacionais, além de aumentar a eficiência e disponibilidade dos ativos navais. Como produto final, foi desenvolvido um *framework* de implementação de IA no SIGMAN, apresentando diretrizes para consolidar essa transformação e promover uma modernização alinhada às necessidades estratégicas da Marinha do Brasil.

Palavras-chave: Inteligência Artificial; Manutenção dos Meios Navais; Sistema de Gerenciamento de Manutenção (SIGMAN); Otimização de Recursos.

1 INTRODUÇÃO

O avanço das tecnologias digitais, em especial da Inteligência Artificial (IA), tem gerado inovações significativas em diversos setores, destacando-se a manutenção de ativos críticos, como os meios navais, como uma área com grande potencial de aprimoramento (LEE, 2018). No contexto da Marinha do Brasil (MB), uma gestão eficiente da manutenção pode ser fundamental para assegurar a disponibilidade e a operacionalidade desses meios, contribuindo diretamente para a defesa nacional, conforme estabelecido na *Estratégia Nacional de Defesa* (END, 2020).

Este trabalho tem como objetivo geral analisar a aplicação da IA como um novo paradigma de manutenção para os meios navais da Marinha do Brasil (MB), utilizando o Sistema de Gerenciamento de Manutenções (SIGMAN) como base para essa transformação. A pesquisa explora como a integração da IA ao SIGMAN pode otimizar o investimento nas fases de Operação, Apoio e Desfazimento do ciclo de vida dos meios navais (BRASIL, 2002), gerando oportunidades para otimização operacional, redução de custos e aumento da disponibilidade dos ativos (NORVIG E RUSSELL, 2013).

A escolha do tema se justifica pelo impacto que a manutenção estratégica tem na prontidão da Marinha (BRASIL, 2002). A aplicação de IA no SIGMAN abre possibilidades para técnicas avançadas, como a manutenção preditiva e o diagnóstico automatizado de falhas (DOD, 2008), que podem transformar a maneira como os ativos são geridos, alinhando-se com os objetivos da Marinha de eficiência e redução de custos, conforme previsto no *Plano Estratégico da Marinha 2040* (PEM 2040).

Embora o SIGMAN ainda esteja em fase de obtenção, seu projeto já sugere um sistema estruturado de dados e processos, os quais poderão ser potencializados por

técnicas de IA em futuras etapas (DIRETORIA DE GESTÃO DE PROGRAMAS DA MARINHA, 2024). Esse contexto viabiliza uma análise teórica das possíveis implementações de IA ao sistema, promovendo sua evolução.

Os objetivos específicos deste trabalho incluem identificar ferramentas de IA aplicáveis às estratégias de manutenção preventiva, preditiva e prescritiva no contexto do SIGMAN, analisar a utilização de IA em sistemas de manutenção de outras forças armadas, investigar qualitativamente o potencial de integração da IA ao SIGMAN, e propor um modelo qualitativo de integração da IA com o sistema.

Para alcançar o objetivo este trabalho utilizou a metodologia de pesquisa-ação, aliada ao desenvolvimento de um *framework* teórico-prático para a integração de IA ao sistema de gerenciamento de manutenções. A pesquisa foi estruturada em etapas principais, incluindo uma revisão bibliográfica sistemática e uma revisão integrativa para fundamentar a construção do *framework*. Essa abordagem permitiu uma análise iterativa e prática, orientada pela aplicação direta dos conceitos e tecnologias de IA.

2 REFERENCIAL TEÓRICO


O referencial teórico deste trabalho tem como objetivo apresentar os principais conceitos, ferramentas e tecnologias de IA que podem ser aplicados para otimizar os processos relacionados à manutenção dos meios navais gerenciados a partir do SIGMAN.

2.1 Inteligência Artificial (IA)

A IA é uma área da ciência da computação que visa desenvolver sistemas capazes de realizar tarefas que, normalmente, exigiriam inteligência humana, como percepção, aprendizado e tomada de decisões (NORVIG & RUSSELL, 2013). Kai-Fu Lee (2018) destaca que a IA é uma ferramenta essencial para a automação de tarefas em setores onde é fundamental aumentar a eficiência operacional e reduzir a intervenção humana em tarefas rotineiras.

Segundo os autores, a IA abrange uma ampla gama de subcampos, desde algoritmos simples até sistemas complexos de aprendizado profundo, sendo aplicada em diversas áreas, como reconhecimento de padrões e otimização de processos (NORVIG & RUSSELL, 2013). Entre esses subcampos, destacam-se o *Machine Learning*, as redes neurais e as redes neurais profundas.

Figura 1 - Inteligência Artificial e seus subcampos



Fonte: PINKOWSKI (2023)

2.1.1 Machine Learning (ML)

No contexto da IA, ML é um ramo que se concentra no desenvolvimento de algoritmos que permitem que sistemas computacionais aprendam com dados, identifiquem padrões e façam previsões sem serem explicitamente programados para cada tarefa específica (KAI-FU LEE, 2018). Em vez de seguir regras fixas, os sistemas de ML ajustam seu comportamento com base nos dados que recebem, melhorando sua performance com o tempo.

2.1.2 Redes Neurais

As técnicas de ML para gerenciamento de manutenções incluem métodos como Redes Neurais, que podem identificar padrões complexos em grandes volumes de dados e prever falhas antes que ocorram. Redes Neurais são um tipo de ML inspirado no funcionamento do cérebro humano, usado para processar grandes volumes de dados, como destacado por Lee (2018).

Como discutido por Dutta (2020), essas redes são capazes de aprender a partir de grandes volumes de dados históricos, criando previsões precisas sobre quando os equipamentos podem falhar. Elas são especialmente úteis em cenários onde os dados não seguem um padrão linear simples, permitindo maior precisão em sistemas complexos. A utilização de redes neurais em manutenção está diretamente ligada à capacidade desses sistemas de identificar anomalias de forma proativa e automatizada.

Redes neurais profundas são um subcampo de redes neurais que utilizam várias camadas de neurônios artificiais para processar dados de maneira mais detalhada e extrair padrões complexos. Segundo Norvig e Russell (2013), as redes neurais profundas, também conhecidas como *Deep Learning*, são especialmente eficazes em tarefas que envolvem reconhecimento de imagens e linguagem natural, onde a profundidade das camadas possibilita a identificação de diferenças sutis nos dados de entrada.

2.2 Manutenção dos Meios Navais

De acordo com o “EMA-420”, que estabelece as normas para a logística de material da Marinha, a manutenção é definida como o conjunto de atividades técnicas e administrativas executadas com o objetivo de manter o material na melhor condição de uso, assegurando confiabilidade, segurança e custos adequados (BRASIL, 2002).

A referida norma subdivide o conceito de manutenção em manutenção preventiva, preditiva, corretiva e modificadora, cada uma com suas características específicas no que tange à gestão dos ativos navais (BRASIL, 2002). Contudo, adicionalmente, estudos elencam como evolução da manutenção preditiva a manutenção prescritiva, que não apenas prevê falhas iminentes, mas também prescreve ações corretivas específicas (NORVIG E RUSSELL, 2013).

Este trabalho se dedica a estudar exclusivamente as manutenções preventivas, preditivas e prescritivas pelo fato destas se basearem em uma abordagem planejada e fundamentada em dados.

2.2.1 Manutenção Preventiva

A manutenção preventiva é definida como um conjunto de intervenções programadas que visam reduzir ou evitar falhas e degradações nos sistemas e equipamentos. Essa abordagem é baseada em intervalos definidos de tempo ou uso, onde inspeções e ajustes são realizados para garantir que o material esteja em condições operacionais adequadas (BRASIL, 2002).

2.2.2 Manutenção Preditiva

A manutenção preditiva utiliza dados em tempo real para monitorar a condição dos equipamentos e prever falhas antes que estas ocorram, permitindo que as ações corretivas sejam realizadas apenas quando necessário. Essa abordagem baseia-se na análise de parâmetros de desempenho e condição dos sistemas, utilizando sensores e técnicas avançadas de monitoramento (BRASIL, 2002).

2.2.3 Manutenção Prescritiva

A manutenção prescritiva, conforme descrito por Lee, Bagheri e Kao (2015), utiliza dados em tempo real e algoritmos avançados para prever falhas e, além disso, recomendar ações corretivas de forma automatizada, permitindo que os sistemas de manutenção se adaptem às condições operacionais antes que falhas ocorram.

2.3 Sistemas de Gerenciamento de Ativos

Os sistemas de gerenciamento de ativos são ferramentas que permitem monitorar o desempenho, garantir a eficiência operacional e prolongar a vida útil dos ativos, além de reduzir os custos associados a falhas e paradas inesperadas. Dentro desse universo de soluções, destacam-se o *Enterprise Asset Management* e o *Product Lifecycle Management*, dois sistemas amplamente utilizados por empresas na gestão de ativos físicos e no ciclo de vida de produtos (GRIEVES, 2006; CAMPBELL, JARDINE & MCGLYNN, 2016).

2.3.1 Enterprise Asset Management (EAM)

O EAM, ou Gerenciamento de Ativos Corporativos, refere-se ao conjunto de práticas e tecnologias utilizadas para monitorar e gerenciar os ativos físicos de uma

organização. O EAM abrange a gestão de manutenção, o controle de inventário, a otimização de desempenho e a alocação eficiente de recursos. Conforme descrito pela IBM, o EAM é essencial para garantir que os ativos funcionem de forma eficiente e segura, minimizando custos operacionais e maximizando a vida útil dos equipamentos. Ele utiliza tecnologias avançadas, como IA e Internet das Coisas (IoT), para prever falhas, automatizar processos e aprimorar a tomada de decisões, promovendo uma gestão mais eficiente dos ativos físicos de uma organização (IBM, 2024).

2.3.2 Product Lifecycle Management (PLM)


Apesar de certa interseção entre os dois tipos de sistema, diferentemente do sistema EAM, que foca na gestão de ativos físicos já adquiridos ou em operação, o PLM, conforme descrito pela Oracle (2024), é uma abordagem integrada para a gestão de todas as fases do ciclo de vida, focando na concepção inicial do projeto.

O PLM envolve o gerenciamento de dados e processos relacionados ao desenvolvimento, produção, manutenção e descarte de produtos, com o objetivo de otimizar a eficiência e a qualidade em cada etapa. Essa tecnologia visa garantir que as informações essenciais sobre o produto estejam acessíveis e organizadas ao longo de todo o ciclo de vida (ALEKSANDROVA ET AL., 2015).

2.3.3 Gestão do Ciclo de Vida

A Gestão do Ciclo de Vida (GCV) é uma abordagem abrangente que envolve todas as fases do desenvolvimento, operação e descarte de sistemas complexos, como os meios navais. No contexto da Marinha do Brasil, a GCV busca otimizar o uso e a disponibilidade dos ativos navais ao longo de toda sua vida útil. O ciclo de vida de um sistema de defesa inclui fases desde a pré-concepção e o desenvolvimento até a operação, manutenção e desfazimento dos meios (MINISTÉRIO DA DEFESA, 2019).

Figura 2 - Estágios do Ciclo de Vida



Fonte: DGePM (s.d.)

2.3.4 Condition-Based Maintenance Plus (CBM+)

Após discutir os conceitos de EAM, PLM e GCV, que oferecem uma visão holística do ciclo de vida dos ativos, é relevante introduzir o conceito de *Condition-Based Maintenance Plus* (CBM+). Desenvolvido pelo Departamento de Defesa dos Estados Unidos, o CBM+ é um conjunto de princípios e práticas de manutenção que utiliza dados em tempo real para avaliar continuamente o estado dos sistemas e prever falhas antes que elas ocorram (DOD, 2008).

Segundo o Departamento de Defesa dos Estados Unidos (2008), enquanto o PLM e o GCV estabelecem a base para gerenciar o ciclo de vida completo dos ativos, o CBM+ agrega uma camada de proatividade, alinhando-se à necessidade de uma manutenção que considere o estado atual dos equipamentos, em vez de se basear apenas em intervalos de tempo fixos.

Para garantir a eficácia desse modelo, o CBM+ utiliza tecnologias avançadas como sensores, IoT e *Big Data*¹ para coleta e monitoramento de dados em tempo real. Esses dados são processados por algoritmos de análise preditiva, que identificam variações no desempenho dos ativos, sinalizando desgaste ou falhas iminentes. Com essas ferramentas tecnológicas, o CBM+ consegue realizar previsões precisas e respostas rápidas, aprimorando a capacidade de monitoramento e controle de sistemas complexos (DOD, 2008).

Além disso, a IA, quando integrada ao CBM+, fortalece suas capacidades preditivas e prescritivas, pois algoritmos de ML podem analisar grandes volumes de dados, identificar tendências e ajustar automaticamente os parâmetros de manutenção conforme a condição dos ativos (DOD, 2008). Essa combinação torna o CBM+ uma solução adaptativa e inteligente, que se alinha às demandas modernas por uma gestão eficiente e orientada por dados em sistemas de alta criticidade.

No setor de defesa, o CBM+ se destaca por garantir uma alta prontidão operacional, essencial para manter a eficiência e a segurança dos sistemas estratégicos. Sua ampla adoção por forças armadas demonstra a eficácia do modelo em reduzir tempos de inatividade e melhorar a eficiência logística, tornando-se um padrão nas práticas globais de manutenção e gestão de ativos de alta importância para a segurança nacional (DOD, 2008).

2.3.5 Sistema de Gerenciamento de Manutenções (SIGMAN)

O SIGMAN é uma iniciativa estratégica da MB voltada para o aprimoramento das atividades de manutenção dos seus meios navais. Conforme descrito pela Diretoria de Gestão de Programas da Marinha (DGePM), o projeto tem como objetivo a aquisição de uma solução integrada de tecnologia da informação especializada no gerenciamento da manutenção (DGEPM, 2024).


Trata-se de uma solução comercial pronta do tipo COTS (Commercial Off-The-Shelf), comprovadamente testada em ambiente militar e meios modernos, com características de Sistema de Informações Gerenciais (SIG) e de Sistema de Apoio à Decisão (SAD), projetada para atender às demandas específicas da Marinha (DGEPM, 2024).

Ainda de acordo com a DGePM, o SIGMAN terá a capacidade de monitorar e controlar de forma eficiente as atividades de manutenção, permitindo o gerenciamento dos resultados em termos de disponibilidade, confiabilidade, manutenibilidade e

custos ao longo de todo o Ciclo de Vida do meio. Sem esse sistema, a MB não possuirá uma ferramenta única que tenha a capacidade de, entre outros:

- (i) importar dados em formatos recomendados por normas internacionais;
- (ii) auxiliar na análise desses dados antes de sua aceitação (ex.: análise das mudanças ocorridas a cada versão dos bancos de dados logísticos²);
- (iii) armazenar e analisar grandes quantidades de dados provenientes dos inúmeros sensores existentes nos meios modernos;
- (iv) adotar e acompanhar os avanços tecnológicos empregados na manutenção dos meios (ex: uso de IA para análise de desgastes, análise preditiva); e
- (v) prover e atender às normas internacionais de segurança da informação e cibersegurança.

Figura 3 - SIGMAN



Fonte: DGePM (s.d.)

O SIGMAN pode ser classificado como um sistema EAM, já que, em sua concepção atual, está sendo projetado para gerenciar ativos navais durante suas fases operacionais, desde o uso até o desfazimento. No entanto, o potencial do SIGMAN vai além. O sistema tem a capacidade de, futuramente, incluir funcionalidades adicionais que permitam o gerenciamento de todo o ciclo de vida de um meio naval, desde a fase de concepção até o desfazimento. Esse conceito se alinha com os sistemas PLM, que, conforme definido pela Oracle (s.d.), integra dados e processos em todas as fases do ciclo de vida de um produto ou ativo.

Por fim, a integração das práticas previstas no CBM+ ao SIGMAN permitiria uma gestão mais inteligente e responsiva dos meios navais, utilizando dados para aumentar a disponibilidade dos ativos e reduzir custos operacionais (DOD, 2008).

3 METODOLOGIA DA PESQUISA

Para alcançar o objetivo proposto, empregou-se a metodologia de pesquisa-ação, que consiste em um método de investigação empírica, concebido e executado em associação com uma ação específica (WHITTEMORE; KNAFL, 2005; PATELI; GIAGLIS, 2004).

Na fase exploratória, foram aplicados métodos qualitativos de pesquisa, incluindo uma revisão bibliográfica sistemática e um levantamento de dados secundários sobre a aplicação de IA em manutenção de ativos, especialmente no contexto militar. A seleção dos artigos foi conduzida com base no protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), garantindo rigor e transparência na escolha de estudos relevantes.

Posteriormente, foi realizada uma revisão integrativa da literatura para sintetizar a análise dos estudos. Essa revisão permitiu integrar diferentes abordagens e práticas documentadas, consolidando os dados obtidos e fornecendo uma visão abrangente e crítica do estado atual de aplicação da IA na gestão de manutenção.

Após a conclusão da fase exploratória, iniciou-se a fase de planejamento. Nesta etapa, com base nas descobertas teóricas obtidas nas etapas anteriores, elaborou-se um modelo teórico preliminar ou *framework*, reunindo os principais tópicos e práticas identificados na revisão integrativa e sistemática em uma estrutura prática aplicável ao SIGMAN.

3.1 Revisão Bibliográfica

A metodologia utilizada neste trabalho tem como base a pesquisa bibliográfica, orientada por critérios sistemáticos de seleção e análise das fontes. A pesquisa bibliográfica é um elemento central para a construção de conhecimento científico, pois permite ao pesquisador compreender o tema estudado e identificar lacunas e contribuições relevantes (GIL, 2019).

3.1.1 Tipo de Pesquisa

O estudo terá uma abordagem qualitativa, pois o foco está na análise de conceitos e teorias que se aplicam à IA e à manutenção dos meios navais. A abordagem qualitativa é particularmente útil para entender fenômenos complexos, onde a interpretação dos dados é fundamental, possibilitando uma análise mais profunda das tecnologias emergentes e suas implicações para a MB (LAKATOS; MARCONI, 2017).

A pesquisa será do tipo exploratória, com o objetivo de fornecer uma visão inicial sobre o tema. Segundo Gil (2019), as pesquisas exploratórias são adequadas quando se deseja aprofundar o conhecimento em áreas ainda pouco estudadas, como é o caso da IA no setor de defesa naval. Esse tipo de pesquisa permite levantar informações relevantes e desenvolver hipóteses iniciais sobre o tema, criando bases para estudos mais aprofundados no futuro.

Para garantir uma revisão bibliográfica estruturada, será utilizada uma revisão sistemática. Esse método permite a seleção criteriosa de estudos e artigos relevantes, por meio de bases de dados reconhecidas, assegurando a validade e confiabilidade das informações coletadas (PAGE ET AL., 2022; GIL, 2019). A revisão sistemática inclui a identificação, seleção, análise e síntese das fontes disponíveis.

3.1.2 Coleta de Dados e Tratamento de Dados

A coleta de dados será conduzida por meio do protocolo PRISMA 2020, conforme proposto por Page et al. (2022), que oferece um *framework* robusto para assegurar transparência e rigor metodológico na revisão sistemática. Esse método permitirá organizar e avaliar de forma criteriosa os estudos mais relevantes sobre a aplicação da IA na manutenção dos meios navais (GIL, 2019; LAKATOS; MARCONI, 2017). A pesquisa será realizada em bases de dados científicas, onde serão selecionados artigos, livros e relatórios técnicos que discutam o uso de IA em manutenção de ativos.

Além disso, serão identificadas as regulamentações e diretrizes existentes na MB que tratam da manutenção de meios navais, verificando até que ponto contemplam a integração de IA. Os critérios de inclusão e exclusão serão aplicados para garantir que apenas as fontes mais relevantes e alinhadas ao objetivo da pesquisa sejam analisadas, assegurando uma abordagem crítica e sólida dos dados coletados (PAGE ET AL., 2022).

3.1.3 Realização da Pesquisa

Para garantir uma pesquisa abrangente e rigorosa, foram aplicados filtros de inclusão, como o período de publicação recente e o alinhamento com o tema de IA e manutenção naval, e critérios de exclusão, descartando estudos que não tinham relevância direta ou metodológica adequada (PAGE ET AL., 2022).

A análise dos dados incluiu uma comparação entre os resultados obtidos e as regulamentações atuais da MB, identificando possíveis lacunas e áreas em que a IA poderia ser implementada ou aprimorada na estratégia de manutenção de meios navais (BRASIL, 2002). Essa análise crítica permitiu formular recomendações baseadas nas melhores práticas identificadas na literatura científica e nas necessidades específicas da Marinha.

3.1.4 Identificação

Esta fase da pesquisa consistiu na identificação inicial dos estudos relevantes, que foram extraídos das bases de dados selecionadas, como Google Scholar e o Portal CAPES, além de documentos oficiais da Marinha. Essa busca resultou em uma lista preliminar de publicações focadas na aplicação de IA na manutenção naval. Nessa etapa, foi feito o processo de remoção de duplicatas para garantir que cada estudo fosse considerado apenas uma vez. Todos os dados sobre as bases consultadas e as estratégias de busca empregadas foram documentados, assegurando clareza no processo de revisão (PAGE ET AL., 2022).

3.1.5 Triagem

Na fase de triagem, foram revisados os títulos e resumos dos estudos identificados para avaliar se correspondiam aos critérios de inclusão definidos. A pesquisa focou em textos que abordam a aplicação de IA em análise de negócios ou na definição de estratégias organizacionais e que tratam do impacto da IA na tomada de decisões em organizações. Aqueles que não cumpriam esses critérios ou que não tinham relevância direta ao tema central foram excluídos (PAGE ET AL., 2022).

Para esse processo, foi aplicado o filtro “aplicações de IA em análise de manutenção”, resultando em 635 publicações. Posteriormente, foi estabelecido um

critério de restrição para artigos publicados a partir de 2012, resultando na exclusão de 533 artigos. Ao final, mantendo um foco nas publicações mais relevantes, foram selecionadas 52 teses e 50 dissertações, somando 102 publicações no total.

3.1.6 Elegibilidade


Após a triagem, os estudos foram avaliados em detalhes na fase de elegibilidade, onde cada texto foi lido integralmente para confirmar sua relevância e qualidade metodológica. Foram analisados os objetivos, as metodologias empregadas e as conclusões de cada estudo, garantindo que apenas os que oferecem uma contribuição substancial ao tema da aplicação da IA na manutenção naval fossem incluídos (PAGE ET AL., 2022).

Além dos estudos acadêmicos, também foram considerados os normativos internos da Marinha que tratam da aplicação de IA. A inclusão desses documentos oficiais permitiu uma análise mais completa e contextualizada das diretrizes e regulamentações já existentes, alinhando a revisão teórica às práticas e normas vigentes na instituição.

3.1.7 Inclusão

Por fim, na fase de inclusão, os estudos que cumpriram todos os critérios de elegibilidade foram integrados à revisão final. O processo completo de seleção foi documentado por meio do fluxograma PRISMA a seguir, permitindo que se visualize claramente o caminho percorrido desde a identificação inicial até a inclusão dos estudos. Isso demonstra que o processo de revisão seguiu um padrão sistemático, que pode ser auditado com transparência e rigor, como proposto por Page et al. (2022) com o PRISMA 2020.

Figura 4 - Protocolo PRISMA



Fonte: elaborado pelo autor, com base em PAGE *et al.* (2022).

3.2 Revisão Integrativa

Após a Revisão Bibliográfica, foi adotada uma Revisão Integrativa, metodologia que permite a síntese de diferentes tipos de estudos, sejam experimentais ou não experimentais, com o objetivo de proporcionar uma compreensão ampla de um fenômeno. Segundo Whitemore e Knafl (2005), esse método é utilizado para integrar e analisar criticamente literatura de diversas abordagens metodológicas, permitindo a combinação de resultados heterogêneos para construir uma visão mais completa do tema investigado.

A escolha dessa abordagem justifica-se por sua capacidade de fornecer uma síntese abrangente do conhecimento existente, além de identificar lacunas teóricas e práticas que podem orientar futuras pesquisas, especialmente em áreas de estudo com múltiplas perspectivas e abordagens.

3.2.1 Formulação do Problema

A formulação do problema nesta revisão integrativa buscou responder à questão central: "Como a IA pode ser integrada ao SIGMAN da Marinha para otimizar a manutenção dos meios navais?".

Essa questão foi delineada para investigar, de acordo com as informações obtidas a partir da revisão bibliográfica, como a aplicação de tecnologias de IA, como ML e redes neurais, pode melhorar o planejamento e execução das manutenções, proporcionando maior eficiência operacional e redução de custos. O problema também aborda os desafios específicos da integração de IA no SIGMAN, incluindo a necessidade de infraestrutura tecnológica, capacitação de pessoal e segurança cibernética, considerando o contexto estratégico e operacional da Marinha. Dessa forma, a formulação do problema buscou identificar tanto os benefícios potenciais quanto as barreiras à implementação dessa tecnologia no âmbito militar (WHITTEMORE E KNAFL, 2005).

3.2.2 Seleção dos Estudos para a Revisão Integrativa

Nesta etapa, a partir dos estudos previamente selecionados durante a revisão bibliográfica, a revisão integrativa foi realizada com o objetivo de sintetizar os principais achados e proporcionar uma visão crítica e mais aprofundada dos temas relacionados ao SIGMAN e à otimização da manutenção dos meios navais (WHITTEMORE; KNAFL, 2005).

3.2.3 Critérios para Inclusão na Revisão Integrativa

Para a revisão integrativa, foram aplicados novos critérios de seleção, focados na profundidade das contribuições teóricas e empíricas de cada estudo em relação à integração da IA ao SIGMAN. Foram priorizados estudos que apresentassem resultados aplicáveis ao contexto militar, que tratassem de tecnologias emergentes no gerenciamento de ativos, e que oferecessem análises detalhadas sobre a utilização de ML e redes neurais para a manutenção de ativos. Estudos com foco apenas teórico ou com pouca aplicabilidade prática ao SIGMAN foram excluídos nesta fase (WHITTEMORE; KNAFL, 2005).

3.2.4 Avaliação Crítica dos Estudos Seleccionados

Após a seleção dos estudos para a revisão integrativa, foi realizada uma avaliação crítica de cada artigo, com o objetivo de identificar suas contribuições específicas para a aplicação de IA na manutenção de ativos navais e, mais especificamente, no SIGMAN. A avaliação considerou critérios como a robustez metodológica, a qualidade das evidências apresentadas e a relevância dos achados para o contexto deste estudo. Estudos que apresentaram uma sólida base empírica, com dados claros e aplicáveis, foram considerados mais relevantes para a análise integrativa, enquanto estudos com metodologias superficiais ou pouca aplicabilidade ao contexto naval foram preteridos (WHITTEMORE; KNAFL, 2005).

3.2.5 Síntese dos Dados

A síntese dos dados obtidos na revisão integrativa seguiu um processo de análise temática, no qual os principais temas e padrões emergentes foram identificados e organizados. Os estudos foram agrupados em categorias temáticas, como: algoritmos de *machine learning*, aplicação de IA no setor militar, otimização de recursos por meio de IA, e desafios na implementação de sistemas de IA. A partir desses grupos temáticos, foi realizada uma comparação entre os diferentes estudos, destacando-se as similaridades nos resultados e as abordagens diferenciadas que poderiam ser aplicadas ao SIGMAN. Essa abordagem permitiu uma visão integrada dos principais benefícios e desafios da IA para o gerenciamento de ativos navais (WHITTEMORE; KNAFL, 2005).


3.3 Modelo Teórico Preliminar

O tema deste trabalho, por ser eminentemente teórico, requer um *framework* estruturado que integre não apenas a revisão bibliográfica, mas também a implementação de modelos de IA adaptados às necessidades específicas da Marinha.

A partir de uma revisão sobre *frameworks* aplicáveis a modelos de negócio e tecnologias digitais (PATELI & GIAGLIS, 2004), propõe-se um modelo que reúne etapas de definição de objetivos, componentes essenciais, desenvolvimento do modelo, implementação e testes, além da avaliação contínua. Tal estrutura permite que a integração da IA ao SIGMAN seja realizada de maneira prática e mensurável, facilitando ajustes e evoluções no modelo de acordo com os resultados observados.

No contexto deste trabalho, o *framework* proposto representa uma ferramenta metodológica fundamental para operacionalizar a manutenção com base em dados, conforme recomendam estudos sobre integração de IA em sistemas de gestão e manutenção de ativos (WHITTEMORE; KNAFL, 2005).

Figura 5 - Framework de Implementação do SIGMAN



Fonte: elaborada pelo autor.

3.3.1 Definição de Objetivo e Escopo

O objetivo central deste *framework* é integrar a IA ao SIGMAN para otimizar a manutenção dos meios da Marinha, com foco em aumentar a eficiência operacional e reduzir os custos de manutenção.

A definição do escopo delimita as funções e os tipos de ativos que serão incluídos na integração da IA com o SIGMAN. Esta fase é fundamental para garantir que o *framework* atenda às necessidades específicas da Marinha e considere as particularidades dos diferentes meios navais. O escopo definido orienta quais sensores, fontes de dados e componentes de infraestrutura devem ser priorizados, assegurando que o sistema esteja alinhado aos requisitos e objetivos da organização.

3.3.2 Componentes Essenciais

Nesta etapa, é necessário identificar e mapear os dados essenciais para a operação da IA, que incluem informações de sensores, históricos de manutenção e registros operacionais. Esses dados servirão de base para a análise e predição de falhas. Para garantir a compatibilidade e integração contínua ao longo do tempo, recomenda-se que as futuras aquisições de meios navais exijam sensores e sistemas de dados compatíveis com o SIGMAN, assegurando uma coleta e monitoramento contínuos e precisos.

A seleção de modelos de IA envolve a escolha de algoritmos de aprendizado de máquina adequados para as necessidades de manutenção. Modelos como redes neurais são recomendados para a previsão de falhas, enquanto algoritmos prescritivos são utilizados para sugerir ou automatizar ações corretivas. A escolha dos modelos é orientada pela necessidade de precisão e adaptabilidade às variáveis operacionais dos

meios navais, garantindo que o *framework* seja eficaz e robusto o suficiente para lidar com diferentes cenários operacionais.

Em seguida, é essencial mapear os requisitos tecnológicos e a infraestrutura de TI necessários para suportar o sistema. Isso inclui tanto o *software* quanto o *hardware* que precisam ser compatíveis com o SIGMAN. A infraestrutura de tecnologia deve ser robusta o suficiente para processar grandes volumes de dados e permitir o treinamento eficiente dos modelos de IA. Com uma base tecnológica adequada, o *framework* poderá suportar o crescimento e a complexidade da aplicação de IA na manutenção dos meios navais.

3.3.3 Desenvolvimento e Design do Modelo

O processo de análise e pré-processamento de dados envolve a coleta e preparação dos dados de entrada para garantir sua qualidade e consistência. Técnicas de filtragem e normalização³ são utilizadas para remover ruídos e otimizar os dados para os modelos preditivos e prescritivos. Esse processamento inicial é essencial para que as análises futuras sejam precisas e eficazes, garantindo a confiabilidade dos resultados e aumentando a robustez dos modelos de IA.

Os modelos preditivos são configurados para antecipar falhas com base em padrões históricos e no monitoramento em tempo real dos ativos. Esses algoritmos possibilitam uma intervenção planejada e preventiva, reduzindo o risco de falhas inesperadas. O uso de dados históricos, combinado com os dados em tempo real, permite que o sistema antecipe problemas e indique quando uma manutenção corretiva deve ser realizada.

Os modelos prescritivos complementam os preditivos, sugerindo ações corretivas específicas e até automáticas para otimizar o processo de manutenção. Com base nos insights dos modelos preditivos, os algoritmos prescritivos recomendam medidas corretivas e preventivas, garantindo maior confiabilidade e rapidez nas ações preventivas e corretivas. Isso permite que o sistema de manutenção seja mais proativo e menos dependente de intervenções manuais.

3.3.4 Implementação e Testes

Para validar o *framework* em um ambiente controlado, recomenda-se realizar a implementação inicial em navios de menor porte. Esse projeto-piloto permite testar a integração da IA ao SIGMAN em uma escala reduzida, com menor impacto operacional em caso de ajustes necessários. Durante essa fase, o desempenho do sistema é monitorado, e as lições aprendidas servem de base para a futura expansão para meios maiores e para otimizar o modelo antes de sua aplicação em toda a frota.

Com base nos resultados e observações durante a fase piloto, são realizados ajustes no modelo e nas configurações dos algoritmos para aprimorar a precisão e adaptabilidade às necessidades operacionais. Esse processo de ajuste garante que o sistema esteja otimizado antes de uma expansão mais ampla e que todas as variáveis e fatores críticos tenham sido validados.

3.3.5 Avaliação e Monitoramento

Para avaliar a eficácia do *framework*, são definidos e monitorados KPIs (*Key Performance Indicators*), como tempo de inatividade dos ativos, taxa de falhas

evitadas e redução nos custos de manutenção. Esses indicadores permitem uma avaliação objetiva do impacto do sistema e fornecem informações essenciais para medir o sucesso da implementação e identificar áreas para melhoria contínua.

A fase de *feedback* e aprimoramento contínuo baseia-se nos dados coletados pelos KPIs e nas observações práticas obtidas ao longo do processo. Esse *feedback* é fundamental para realizar ajustes constantes no *framework*, assegurando um ciclo contínuo de aprimoramento e adaptação às necessidades operacionais da Marinha. Esse ciclo de *feedback* torna o *framework* dinâmico e flexível, permitindo que ele se ajuste a novas demandas e aos avanços tecnológicos.

4 ANÁLISE DOS RESULTADOS

A análise de resultados deste trabalho explora como a IA pode ser aplicada na estratégia de manutenção dos meios navais da MB, com ênfase nas possibilidades de integração ao SIGMAN.

4.1 Aplicações da IA na Manutenção dos Meios Navais

A aplicação de IA na manutenção dos meios navais representa um avanço significativo, permitindo a análise preditiva com base em grandes volumes de dados gerados pelos equipamentos. Como discutido por Norvig e Russell (2013), o *machine learning* é uma das técnicas mais adequadas para essa tarefa, pois os algoritmos podem aprender com dados históricos e padrões de uso, antecipando falhas antes que estas ocorram. Isso garante maior precisão nas previsões e evita paradas inesperadas, ao mesmo tempo em que permite um planejamento de manutenção mais eficiente. Ao ser integrado ao SIGMAN essa capacidade preditiva pode ajudar a melhorar a disponibilidade dos ativos navais, ao reduzir o tempo de inatividade e otimizar a logística necessária ao complexo processo de manutenção, sob responsabilidade da Diretoria de Abastecimento da Marinha (DABM).

Em paralelo, o uso da Inteligência Artificial (IA) para manutenção preditiva, conforme discutido no guia CBM+, vai além da simples previsão de falhas. Ele permite otimizar processos de maneira dinâmica e em tempo real, utilizando dados contínuos capturados por sensores embarcados. Essa abordagem possibilita que a Marinha adote um sistema de manutenção baseado nas condições reais dos ativos, em vez de seguir um cronograma fixo, o que pode resultar em redução de custos operacionais, aumento da vida útil dos equipamentos e maior resiliência operacional, especialmente em missões críticas onde o tempo de resposta é essencial (DOD, 2008).

A IA também pode desempenhar um papel crucial no diagnóstico avançado de falhas, identificando rapidamente as causas de problemas mecânicos ou eletrônicos nos meios navais. Norvig e Russell (2013) explicam que os sistemas de IA podem utilizar redes neurais e técnicas de aprendizado profundo para identificar padrões que humanos ou sistemas tradicionais não conseguem detectar. Integrar essas capacidades ao SIGMAN permitiria realizar diagnósticos mais rápidos e precisos, propondo soluções de forma automatizada, o que otimizaria o tempo de resposta e reduziria a dependência de diagnósticos manuais.

A otimização de recursos é outro campo em que a IA pode trazer grandes benefícios, ajustando o uso de peças sobressalentes, mão de obra e energia conforme as necessidades reais dos meios navais. Bittencourt (2021) aponta que as Forças Armadas dos EUA têm aplicado IA para aumentar a eficiência de suas operações

logísticas e reduzir custos, e essa mesma abordagem pode ser aplicada no contexto brasileiro. A IA pode criar algoritmos que otimizam o planejamento de manutenções e o gerenciamento de inventário de peças, garantindo que recursos estejam disponíveis no momento certo, evitando tanto excessos quanto escassez.

Além disso, a Marinha da Índia também tem investido na aplicação de IA para gestão de inventários e manutenção prescritiva, integrando dados operacionais em tempo real e ajustando o consumo de recursos com base no estado dos ativos. Segundo Dutta (2020), essa abordagem melhora a alocação de recursos humanos e materiais, minimizando o desperdício e maximizando a eficiência operacional. Ao aplicar essas técnicas no SIGMAN, a MB poderá aprimorar o gerenciamento de sua cadeia logística, otimizando o uso de peças sobressalentes e garantindo a operação contínua e eficiente de seus meios navais.

4.2 Integração com o Sistema de Gerenciamento da Manutenção (SIGMAN)

O SIGMAN, ainda em aquisição, oferecerá uma base sólida para a integração de IA, com sua capacidade de coleta e armazenamento de dados operacionais dos meios navais. A estrutura modular do sistema permitirá que ele seja progressivamente aprimorado com algoritmos de aprendizado supervisionado⁴, permitindo que previsões mais precisas sejam feitas sobre o estado dos ativos. A introdução de IA em sistemas como o SIGMAN pode permitir a criação de sistemas preditivos e adaptativos, ajustando-se automaticamente às necessidades operacionais e prolongando a vida útil dos equipamentos.

O sistema será projetado para lidar com grandes volumes de informações técnicas, tais como histórico de manutenções, condições operacionais e relatórios de desempenho. Isso oferece a base perfeita para o uso de algoritmos de aprendizado não supervisionado⁵, conforme discutido por Norvig e Russell (2013), para identificar padrões que passariam despercebidos por métodos tradicionais. Tais algoritmos podem analisar comportamentos incomuns nos sistemas e gerar alertas antes que os problemas se tornem críticos, reforçando a ideia de uma manutenção preditiva mais eficaz.

Cabe mencionar que o sistema sob análise tem o potencial de influenciar futuras aquisições ou, até mesmo, projetos já em desenvolvimento. A capacidade de processamento de dados poderá ser potencializada caso os equipamentos incorporados à Marinha sejam capazes de enviar em tempo real dados ao SIGMAN, dispensando uma transferência manual. Isso sinaliza o potencial disruptivo desta tecnologia sem precedentes nesta Força Armada, incorporando a chamada "Internet das Coisas" aos meios navais, trazendo potenciais ganhos de eficiência.

Além disso, como discutido por Kai-Fu Lee (2018), os sistemas de IA podem otimizar o gerenciamento de recursos, como peças de reposição e mão de obra, ajustando automaticamente os cronogramas de manutenção e evitando o excesso ou a escassez de materiais. Esse tipo de análise inteligente, baseada em dados gerados pelo SIGMAN, também permite uma melhor alocação de pessoal e recursos financeiros, garantindo que a manutenção seja realizada no momento ideal e com o menor custo possível.

4.3 Desafios e Limitações

A implementação de IA no SIGMAN enfrenta barreiras tecnológicas e desafios significativos, como a necessidade de uma infraestrutura adequada e sistemas robustos capazes de processar grandes volumes de dados em tempo real.

4.3.1 Segurança Cibernética

A segurança cibernética é um dos maiores desafios para a implementação da IA no SIGMAN. A experiência de outros países, como os Estados Unidos, demonstra que o uso de IA em ambientes militares, como qualquer sistema de informação introduzido, traz consigo um aumento na exposição a ameaças cibernéticas, conforme mencionado por Johnson (2020).

A interconexão entre os sistemas de IA e os sistemas críticos de comunicação e controle torna essencial garantir que a integridade dos dados seja mantida e que ataques de negação de serviço (DDoS)⁶ ou invasões maliciosas não comprometam a operação dos meios navais. Uma eventual alteração maliciosa nos sistemas ou em suas informações pode causar danos significativos a subsistemas críticos ou até mesmo resultar em acidentes operacionais.

Além disso, vazamentos de dados podem expor informações estratégicas, como a capacidade operacional, os destinos, e até mesmo detalhes técnicos dos meios militares. Esse tipo de ameaça é particularmente preocupante em sistemas interconectados e autônomos, onde a exposição de dados sensíveis compromete a segurança e eficácia dos ativos, uma preocupação crescente em ambientes militares que utilizam IA (JOHNSON, 2020; BITTENCOURT, 2021).

Para enfrentar esse desafio, é necessário implementar protocolos de segurança avançados que garantam a integridade e confidencialidade dos dados processados e transmitidos pelo SIGMAN. Como discutido por Bittencourt (2021), o Departamento de Defesa dos EUA também investiu pesadamente em ciberdefesa ao introduzir IA em suas operações, pois uma falha nesse aspecto pode comprometer a eficiência e a segurança operacional. A MB precisará adotar uma abordagem semelhante, garantindo que sistemas de defesa cibernética robustos estejam integrados ao SIGMAN, protegendo os dados e as comunicações de possíveis ameaças externas.

4.3.2 Vulnerabilidade a Falhas

Conforme discutido por Johnson (2020), uma das principais limitações observadas em aplicações militares de IA é a vulnerabilidade dos sistemas a falhas, especialmente em cenários onde a coleta de dados ocorre em ambientes dinâmicos e desafiadores, como no setor naval. Outro desafio está relacionado à capacidade de armazenar, processar e analisar dados de manutenção de forma eficaz, o que exige o uso de algoritmos complexos e redes neurais que demandam uma alta capacidade computacional, como ressaltado por Norvig e Russell (2013).

Experiências internacionais também destacam esses desafios. No contexto militar dos Estados Unidos, por exemplo, a integração de IA nas forças armadas mostrou que, sem uma infraestrutura computacional avançada e sistemas integrados de redes de comunicação, o uso de IA pode ser prejudicado pela latência dos dados⁷ e pela falta de confiabilidade das redes, conforme discutido por Price et al. (2018). A MB, ao implementar o SIGMAN com IA, precisará enfrentar esses obstáculos, garantindo uma infraestrutura robusta, capaz de operar em alto mar e em condições adversas, para que os dados possam ser processados e analisados em tempo real.

4.3.3 Capacitação

Outro desafio crítico é a capacitação de pessoal para operar e manter sistemas de IA no SIGMAN. A Marinha precisará desenvolver programas de treinamento especializados para que seus militares possam lidar com tecnologias complexas associadas à IA. O Departamento de Defesa dos Estados Unidos, por exemplo, criou o Joint Artificial Intelligence Center (JAIC) com o propósito de capacitar militares em IA e garantir que tecnologias emergentes sejam integradas eficientemente às operações diárias, por meio de programas como o "AI 101" e outras iniciativas de alfabetização em dados. Nos Estados Unidos, além do treinamento técnico em ferramentas, os militares são preparados em conceitos estratégicos, incluindo o uso ético e a segurança operacional da IA, promovendo uma cultura organizacional que incentiva a inovação tecnológica (BORCHERT; SCHÜTZ; VERBOVSZKY, 2024).

Para que a IA seja bem-sucedida no SIGMAN, a Marinha do Brasil precisará adotar uma abordagem similar, onde os operadores não apenas entendam o uso da tecnologia, mas também estejam preparados para tomar decisões críticas baseadas em dados. Isso demandará uma ampla reformulação dos programas de treinamento e o desenvolvimento de competências técnicas voltadas para o uso de algoritmos de aprendizado de máquina, análise de dados e segurança cibernética.

4.4 Implementação

Para superar os desafios tecnológicos e de segurança na implementação de IA no SIGMAN, uma das soluções viáveis seria a possibilidade de já adquirir o sistema com recursos que utilizem IA. Além disso, seria fundamental investir em infraestrutura computacional avançada e garantir a interconexão robusta entre os sistemas navais.

Como visto nas experiências das Forças Armadas dos EUA, uma infraestrutura robusta foi fundamental para garantir que os dados fossem processados em tempo real e que os algoritmos de IA pudessem ser aplicados de forma eficaz, conforme discutido por Price et al. (2018). Além disso, a criação de parcerias com universidades e indústrias tecnológicas poderia acelerar o desenvolvimento de soluções específicas para a Marinha, como sensores mais eficientes e sistemas de processamento de dados otimizados para o ambiente naval.

A implementação da IA no SIGMAN deve seguir uma abordagem gradual, começando por projetos-piloto que testem a eficiência dos algoritmos de aprendizado de máquina e de redes neurais profundas em ambientes controlados. Isso foi uma estratégia adotada pelas forças armadas dos EUA, que iniciaram com fases de teste controladas antes de expandir o uso da IA para operações mais complexas. A Marinha do Brasil poderia replicar essa estratégia, utilizando um meio menor porte como projeto inicial para testar o sistema em um ambiente operacional, monitorando a eficiência em tempo real e ajustando os parâmetros conforme necessário.

Após a fase de testes, seria recomendável implementar a IA de forma modular e escalável, começando com a integração em sistemas de manutenção preditiva e, posteriormente, expandindo para outras áreas de gestão e logística. Isso garantiria que a IA fosse introduzida de maneira controlada, permitindo ajustes durante o processo. Além disso, como observado nas recomendações da Estratégia Nacional de Defesa, é fundamental garantir a segurança cibernética em cada etapa da implementação, com a

adoção de protocolos de segurança e a constante avaliação das vulnerabilidades do sistema.

4.5 Benefícios Esperados

Uma das principais justificativas para os investimentos na integração de IA no SIGMAN é a redução significativa de custos operacionais a longo prazo. Ao implementar sistemas de manutenção preditiva, a Marinha poderá identificar falhas antes que elas se tornem críticas, evitando paradas inesperadas e prolongando a vida útil dos equipamentos navais.

A literatura revisada ressalta que a integração da IA ao SIGMAN traria benefícios expressivos para a manutenção preditiva e prescritiva, permitindo à MB otimizar a gestão de seus ativos navais. Um dos principais ganhos identificados é a redução do tempo de inatividade dos meios navais, uma vez que o uso de algoritmos de ML permitiria prever falhas com antecedência e agir de maneira proativa para evitar interrupções operacionais.

Dutta (2020) destaca que marinhas de outros países, como a Índia, já colhem os frutos da aplicação de IA, com melhoria da eficiência logística e aumento da disponibilidade operacional. No contexto do SIGMAN, essa capacidade de previsão, aliada à manutenção automatizada, pode garantir que os meios navais estejam operacionais por mais tempo, reduzindo a necessidade de manutenções corretivas emergenciais.

Outro benefício observado nos estudos é a otimização da alocação de recursos. A IA permite não apenas prever falhas, mas também analisar o desempenho dos ativos e sugerir o uso mais eficiente de peças de reposição, mão de obra e energia. Segundo Price (2018), a aplicação de IA na gestão de ativos reduz o desperdício e melhora a precisão na alocação de materiais, garantindo que os recursos estejam disponíveis quando e onde são mais necessários. Isso é particularmente relevante no contexto da Marinha do Brasil, onde a gestão eficiente de recursos é crítica para a manutenção de meios navais em operação contínua, garantindo uma cadeia logística mais fluida e eficiente.

Conforme discutido por Johnson (2020), os sistemas de IA, quando integrados a processos militares, podem melhorar a eficiência logística e reduzir o tempo de resposta durante operações complexas. Esses ganhos em eficiência não apenas melhoram o desempenho da Marinha, mas também justificam os investimentos.

5 CONSIDERAÇÕES FINAIS

A integração dessas estratégias ao SIGMAN possibilitará uma gestão proativa, onde as decisões são baseadas em dados, e a manutenção é realizada de forma eficiente e no momento correto, sem esperar que falhas ocorram.

Com base na revisão bibliográfica, a revisão integrativa permitiu responder à pergunta de pesquisa ao identificar as principais aplicações de IA em sistemas de manutenção, destacando tanto os benefícios quanto os desafios dessa implementação no contexto militar. Com base nos estudos analisados, verificou-se que a IA oferece uma série de vantagens, como a redução do tempo de inatividade, o aumento da eficiência logística e a otimização dos recursos, o que contribui diretamente para a prontidão operacional dos ativos navais.

Os resultados também destacaram desafios significativos, como a necessidade de infraestrutura tecnológica avançada e a capacitação de pessoal, que são elementos fundamentais para a operacionalização eficaz do SIGMAN com IA. Esses desafios exigem um investimento inicial elevado, porém os benefícios a longo prazo, como a redução de custos operacionais e o aumento da vida útil dos equipamentos, podem justificar esse investimento.

Além disso, foi enfatizada a importância de uma abordagem de segurança cibernética robusta para proteger o sistema de possíveis ameaças externas, uma consideração crítica para o ambiente militar.

Este trabalho alcançou seu objetivo principal, que foi analisar como a IA pode ser aplicada ao SIGMAN, estabelecendo um novo paradigma de manutenção naval para a Marinha do Brasil, ao otimizar as manutenções preventiva, preditiva e prescritiva dos meios navais.

Finalmente, recomenda-se que a Marinha do Brasil adote uma estratégia de implementação gradual e modular da IA no SIGMAN, começando com projetos-piloto e expandindo progressivamente para outras áreas de manutenção e logística.

A parceria com instituições acadêmicas e a base industrial de defesa poderá acelerar o desenvolvimento de soluções adaptadas às necessidades específicas da MB. Como perspectiva futura, sugere-se que novas pesquisas sejam realizadas para avaliar o impacto dessas tecnologias na eficiência operacional e na segurança dos ativos navais, consolidando a IA como um recurso estratégico para a modernização e autossuficiência tecnológica da Marinha do Brasil.

NOTAS

1. *Big Data*: Conjunto de dados de grande volume, variedade e velocidade. Maiores informações disponíveis em: <https://abrir.link/eIImM>.
2. Banco de Dados Logísticos: Sistema que armazena e gerencia informações relacionadas à cadeia de suprimentos. Maiores informações disponíveis em: <https://abrir.link/sslJA>.
3. Normalização: Ajuste dos dados para que estejam em uma escala comum. Maiores informações disponíveis em: <https://abrir.link/YeSQb>.
4. Aprendizado supervisionado: Método de treinamento de IA em que o algoritmo aprende com dados rotulados para classificar ou prever resultados. Maiores informações disponíveis em: <https://abrir.link/eeAzf>.
5. Aprendizado não supervisionado: Método de treinamento de IA que identifica padrões e relacionamentos ocultos sem orientação prévia. Maiores informações disponíveis em: <https://abrir.link/MIXWo>.
6. DDoS (*distributed denial-of-service*): Tipo de ataque cibernético em que múltiplos sistemas sobrecarregam um servidor ou rede. Maiores informações disponíveis em: <https://abrir.link/HRAMX>.
7. Latência de dados: Tempo de transferência de um dado. Maiores informações disponíveis em: <https://abrir.link/IXdWk>.

REFERÊNCIAS

- ALEKSANDROVA, M.; IVANOVA, T.; MISHONOVA, M. Digital technology and quality management. **Journal of Business and Technology**, v. 6, n. 2, p. 14-28, 2015.
- ATZORI, L.; IERA, A.; MORABITO, G. The internet of things: A survey. **Computer Networks**, v. 54, n. 15, p. 2787-2805, 2010.
- BITTENCOURT, T. *O futuro é hoje: EUA e a integração de inteligência artificial em suas forças armadas*, 2021.
- BORCHERT, Heiko; SCHÜTZ, Torben; VERBOVSZKY, Joseph (Eds.). **The Very Long Game: 25 Case Studies on the Global State of Defense AI. Contributions to Security and Defence Studies**. Cham, Switzerland: Springer Nature, 2024. Disponível em: <https://doi.org/10.1007/978-3-031-58649-1>. Acesso em: 1 nov. 2024.
- BRASIL. Ministério da Defesa. Marinha do Brasil. **EMA-420: Normas para logística de material**. Rio de Janeiro: Marinha do Brasil, 2002.
- BRASIL. Ministério da Defesa. **Manual de boas práticas para a gestão do ciclo de vida de sistemas de defesa**. Brasília: Ministério da Defesa, 2019.
- BRASIL. Ministério da Defesa. **Estratégia Nacional de Defesa**. Brasília: Ministério da Defesa, 2020.
- BRASIL. Ministério da Defesa. Marinha do Brasil. **Plano Estratégico da Marinha 2040**. Brasília: Ministério da Defesa, 2020.
- CAMPBELL, J. D.; JARDINE, A. K. S.; McGLYNN, J. **Asset management excellence: optimizing equipment life-cycle decisions**. 3. ed. CRC Press, 2016.
- DEPARTMENT OF DEFENSE. **Condition based maintenance plus DoD guidebook**. U.S. Department of Defense, 2008.
- DIRETORIA DE GESTÃO DE PROGRAMAS DA MARINHA. Projeto SIGMAN. Disponível em: <https://www.dgepm.mb/node/269>. Acesso em: 18 out. 2024.
- DUTTA, S. **Artificial intelligence and machine learning for the Indian Navy**. New Delhi: National Maritime Foundation, 2020. Disponível em: <http://www.maritimeindia.org>. Acesso em: 2 nov. 2024.
- GIL, A. C. **Métodos e técnicas de pesquisa social**. 7. ed. São Paulo: Atlas, 2019.
- GRIEVES, M. **Product lifecycle management: driving the next generation of lean thinking**. McGraw-Hill, 2006.
- GUBBI, J.; BUYYA, R.; MARUSIC, S.; PALANISWAMI, M. Internet of things (IoT): A vision, architectural elements, and future directions. **Future Generation Computer Systems**, v. 29, n. 7, p. 1645-1660, 2013.

IBM. **O que é gerenciamento de ativos corporativos (EAM)?** IBM, 2024. Disponível em: <https://www.ibm.com>. Acesso em: 18 out. 2024.

JOHNSON, M. Military applications of artificial intelligence: risks and opportunities. **Journal of Defense Studies**, v. 5, n. 4, p. 223-240, 2020.

KAI-FU, L. **Inteligência artificial: como os robôs estão mudando o mundo**. São Paulo: Harper Collins, 2018.

LAKATOS, E. M.; MARCONI, M. A. **Fundamentos de metodologia científica**. 6. ed. São Paulo: Atlas, 2017.

LEE, J.; BAGHERI, B.; KAO, H. A. A cyber-physical systems architecture for industry 4.0-based manufacturing systems. **Manufacturing Letters**, v. 3, p. 18-23, 2015.

LEE, KAI-FU. **Inteligência artificial**. São Paulo: HarperCollins, 2018.

MOBLEY, R. K. **An introduction to predictive maintenance**. 2. ed. Elsevier, 2002.

NORVIG, P.; RUSSELL, S. **Inteligência artificial**. 3. ed. São Paulo: Pearson, 2013.

ORACLE. What is PLM (Product Lifecycle Management). Disponível em: <https://www.oracle.com/pt/scm/product-lifecycle-management/what-is-plm/>. Acesso em: 18 out. 2024.

PATELI, A. G.; GIAGLIS, G. M. A research framework for analyzing eBusiness models. **European Journal of Information Systems**, v. 13, n. 4, p. 302-314, 2004. doi:10.1057/palgrave.ejis.3000513.

PINKOWSKI, M. L. Aplicação da inteligência artificial na gestão de projetos: aderência, impacto e grau de desenvolvimento. 2023. 128 f. Dissertação (Mestrado em Administração) – Universidade Nove de Julho, São Paulo, 2023.

PRICE, M.; WALKER, S.; WILEY, W. **The machine beneath: implications of artificial intelligence in strategic decision making**. **PRISM**, v. 7, n. 4, p. 92-105, 2018. Disponível em: <https://www.jstor.org/stable/10.2307/26542709>. Acesso em: 18 out. 2024.

PAGE, M. J., MCKENZIE, J. E., BOSSUYT, P. M., BOUTRON, I., HOFFMANN, T. C., MULROW, C. D., et al. **The PRISMA 2020 statement: An updated guideline for reporting systematic reviews**. **BMJ**, 2022. Disponível em: <https://www.prisma-statement.org/>

DA SILVA, Daniel Guilherme Marques; SANTOS, Luis Henrique. Aspectos positivos do uso da Inteligência Artificial/Machine Learning na gestão e planejamento da manutenção aeronáutica.

WHITTEMORE, R.; KNAFL, K. The integrative review: updated methodology. **Journal of Advanced Nursing**, v. 52, n. 5, p. 546-553, 2005.

XU, L. D.; HE, W.; LI, S. Internet of things in industries: A survey. **IEEE Transactions on Industrial Informatics**, v. 10, n. 4, p. 2233-2243, 2014.