Inteligência Artificial No Gerenciamento De Projetos: Uso De Redes Neurais Para Avaliação De Riscos

Autoria: C-ApA-IM 2024 - DGePM - 31

RESUMO

Este trabalho analisa a viabilidade de aplicar modelos de Inteligência Artificial (IA) na gestão de riscos de projetos da Marinha do Brasil (MB), com foco nos projetos sob responsabilidade da Diretoria de Gestão de Programas (DGePM). A pesquisa visa avaliar a adequação desses modelos para apoiar a análise qualitativa de riscos, especialmente na determinação da probabilidade e impacto de eventos, abordando um aspecto específico do processo de gestão de riscos sem realizar implementações práticas. Utilizando uma metodologia qualitativa com revisão bibliográfica e análise documental, o estudo discute as características de modelos de IA, sugerindo que sua aplicação pode reduzir a subjetividade na análise de riscos. Em conclusão, são recomendados estudos futuros para implementar modelos de IA em outras etapas da gestão de riscos e explorar seu uso em outros domínios do gerenciamento de projetos da MB, contribuindo para o aprimoramento contínuo e a modernização dos processos institucionais.

Palavras-chave: Inteligência Artificial; Redes Neurais Artificiais; Marinha do Brasil; Gestão de Riscos; Análise Qualitativa de Riscos.

1 INTRODUÇÃO

A Inteligência Artificial (IA) é uma área da ciência da computação voltada para o desenvolvimento de sistemas capazes de realizar tarefas que normalmente exigiriam inteligência humana, como reconhecer padrões, aprender com a experiência, interpretar informações e tomar decisões. Desde a década de 1950, a IA tem transformado setores essenciais, como indústria, saúde, finanças, educação e defesa. Em termos gerais, a IA busca imitar a capacidade humana em tarefas como resolver problemas complexos e lidar com grandes volumes de dados.

A IA tornou-se uma tecnologia estratégica global devido ao seu impacto na melhoria da eficiência, na qualidade das decisões e na viabilização de inovações antes impraticáveis. Com o aumento exponencial na geração de dados e o desenvolvimento de tecnologias de processamento mais avançadas, a IA é aplicada em áreas como reconhecimento de imagens e vozes, análise preditiva, automação de processos e sistemas autônomos. Sua capacidade de gerar respostas rápidas em ambientes complexos tem permitido que governos e organizações melhorem a precisão nas ações operacionais.

Nesse contexto, o uso de IA na gestão de riscos em projetos apresenta-se como uma solução promissora para enfrentar os desafios de alta complexidade e incerteza. No âmbito dos projetos da Marinha do Brasil (MB), a aplicação de IA tem o potencial de aprimorar a capacidade de identificação, análise e resposta a riscos, reforçando a segurança das operações e protegendo os interesses nacionais. Assim, surge o problema de pesquisa: a aplicação de modelos de IA pode melhorar a acurácia na gestão de riscos em projetos?

Com o objetivo de analisar a adequabilidade da IA na gestão de riscos em projetos e seu potencial para complementar os métodos tradicionais, este estudo investiga a viabilidade de implementar modelos de IA para fortalecer a gestão de riscos. Os objetivos específicos são:

I. Revisar conceitos fundamentais da IA;
II. Identificar modelos de IA aplicáveis à gestão de riscos em projetos; e

III. Avaliar a adequação desses modelos no contexto específico da MB.

A pesquisa é delimitada aos projetos de obtenção de meios operativos sob responsabilidade da Diretoria de Gestão de Programas da Marinha (DGePM), área em que há conhecimento técnico prévio, permitindo uma análise mais aprofundada e contextualizada. No extenso campo do gerenciamento de projetos, o foco recai sobre a gestão de riscos, oferecendo uma visão detalhada sobre as metodologias aplicadas para mitigar incertezas e assegurar o sucesso dos projetos da MB.

A relevância deste estudo é destacada pelos Objetivos Navais 6 e 7 (OBNAV 6 e 7) descritos no Plano Estratégico da Marinha (PEM), que enfatizam o fortalecimento e a modernização da capacidade operacional da força naval brasileira. O PEM determina que todas as Ações Estratégicas Navais (AEN) atendam a rigorosos critérios de programa ou projeto, com indicadores de desempenho e controle de custos. Nesse sentido, ao aplicar IA na gestão de riscos dos projetos da DGePM, este estudo não só promove a modernização dos processos de gestão, mas também contribui diretamente para a prontidão e a eficiência operacional, essenciais para o cumprimento da missão da MB de defender e proteger os interesses nacionais (BRASIL, 2020).

2 REFERENCIAL TEÓRICO

2.1 Inteligência Artificial

A IA é uma das áreas mais inovadoras da ciência da computação, com o objetivo de criar sistemas e máquinas capazes de simular aspectos da inteligência humana, como raciocínio, aprendizado, percepção e tomada de decisão. Desde sua concepção na década de 1950, a IA tem se expandido em diversas vertentes, como aprendizado de máquina, redes neurais, processamento de linguagem natural e robótica, transformando-se em uma tecnologia central para a transformação digital. Seu potencial vai além da simples automação: ela visa desenvolver agentes inteligentes que interajam de forma autônoma e eficiente com o ambiente, revolucionando setores como a indústria, saúde, educação e, mais recentemente, a gestão de projetos.

De acordo com Stuart Russell e Peter Norvig (2022, p. 11, tradução nossa), "Definimos IA como o estudo de agentes que recebem percepções do ambiente e realizam ações. Cada agente implementa uma função que mapeia sequências de percepções para ações, e abordamos diferentes maneiras de representar essas funções". Desde sua origem, a IA evoluiu consideravelmente, passando de uma ciência teórica para uma disciplina com aplicações práticas em diversas áreas, ganhando relevância na automação de processos decisórios e na mitigação de riscos organizacionais.

2.2 Machine Learning

O Aprendizado de Máquina, ou *Machine Learning* (ML) é um dos principais subconjuntos da IA e desempenha um papel fundamental no desenvolvimento de tecnologias capazes de aprender a partir de dados. De acordo com Belharet, Bharathan, Dzingina, Madhavan, Mathur e Toti (2020), essa área foca no desenvolvimento de algoritmos autônomos, capazes de realizar tarefas sem a necessidade de instruções explícitas, sendo imprescindível o uso de dados limpos e relevantes para garantir a eficiência desses algoritmos. Suas aplicações variam desde o reconhecimento de padrões até a previsão de tendências, ganhando destaque em áreas como a gestão de projetos, especialmente na gestão de riscos.

O aprendizado de máquina pode ser subdividido em três categorias principais: aprendizado supervisionado, não supervisionado e aprendizado por reforço. No aprendizado supervisionado, o objetivo é aprender uma função que se aproxima de uma saída esperada, a

partir de um conjunto de entradas e saídas, oferecendo feedback contínuo para correção de erros e aprimoramento das previsões (Koshiyama, Firoozye e Treleaven, 2020). Já no aprendizado não supervisionado, busca-se descobrir padrões ocultos nos dados sem a necessidade de rótulos pré-definidos, sendo útil para tarefas como agrupamento de dados e redução de dimensionalidade, onde um mapa oculto é aprendido para revelar estruturas subjacentes nos dados (Koshiyama, Firoozye e Treleaven, 2020). Por fim, no aprendizado por reforço, o foco é em um agente que interage com o ambiente e toma decisões que maximizam recompensas, aprendendo com as consequências das ações tomadas (Koshiyama, Firoozye e Treleaven, 2020).

Essas três categorias são a base do aprendizado de máquina, cada uma com aplicações distintas e complementares que tornam essa tecnologia uma ferramenta essencial em diversas áreas, incluindo a gestão de projetos.

2.3 Deep Learning, Redes Neurais Artificiais e Perceptron

O Deep Learning, ou aprendizado profundo, é uma subárea de ML que se destaca pelo uso de redes neurais profundas, que contêm múltiplas camadas de processamento. Cada camada representa dados de forma hierárquica, capturando diferentes níveis de abstração. De acordo com Bengio, Courville e Goodfellow (2017), o aprendizado profundo permite que sistemas computacionais aprendam com a experiência, organizando o mundo em uma hierarquia aninhada de conceitos. Cada conceito é definido em relação a conceitos mais simples, de modo que representações abstratas são construídas com base em representações menos abstratas, permitindo que a IA opere em ambientes complexos e dinâmicos (BENGIO; COURVILLE; GOODFELLOW, 2017).

Essa estrutura hierárquica torna o aprendizado profundo especialmente eficaz em aplicações onde métodos convencionais de ML têm limitações, como no reconhecimento de padrões complexos em imagens, textos e na previsão de riscos em projetos. As redes neurais profundas identificam nuances em dados visuais e textuais, facilitando análises detalhadas de estruturas subjacentes, como na interpretação de linguagem natural e na classificação de imagens. No contexto de gerenciamento de riscos, redes profundas podem fornecer resultados mais objetivos, ajudando na identificação e mitigação de riscos em projetos com maior eficiência (BENGIO; COURVILLE; GOODFELLOW, 2017).

As Redes Neurais Artificiais (RNAs) são sistemas inspirados na estrutura de processamento do cérebro humano, onde unidades interconectadas, conhecidas como neurônios artificiais, calculam funções matemáticas para aprender e representar padrões complexos. Inspiradas nos neurônios biológicos, essas redes são formadas por camadas: a camada de entrada, que recebe os dados; as camadas ocultas, onde ocorre o processamento intermediário; e a camada de saída, que gera o resultado final. Segundo Daibert, Braga, Oliveira e Rocha (2009), as RNAs consistem em sistemas distribuídos e paralelos, compostos por neurônios artificiais que trabalham em conjunto para realizar cálculos, refletindo a dinâmica do cérebro humano ao processar dados de forma integrada (DAIBERT et al., 2009).

No contexto do aprendizado profundo, as RNAs têm um papel fundamental, pois redes mais profundas, aquelas com múltiplas camadas ocultas, permitem uma representação hierárquica de conceitos, evoluindo de estruturas simples para estruturas complexas. O aprendizado nas RNAs ocorre por meio do ajuste dos “pesos” nas conexões entre neurônios, permitindo que a rede se adapte a diferentes problemas a partir de exemplos. À medida que o número de camadas aumenta, essas redes transformam-se em redes profundas (*Deep Neural Networks*), que têm ampla aplicação no reconhecimento de padrões complexos em imagens, textos e na previsão de riscos, na qual o ML convencional encontra limitações. A relação baseada na teoria dos conjuntos dos conceitos ora abordados é mais bem compreendida na figura 1 deste trabalho.

Figura 1 - Esquema de IA baseada na Teoria dos Conjuntos

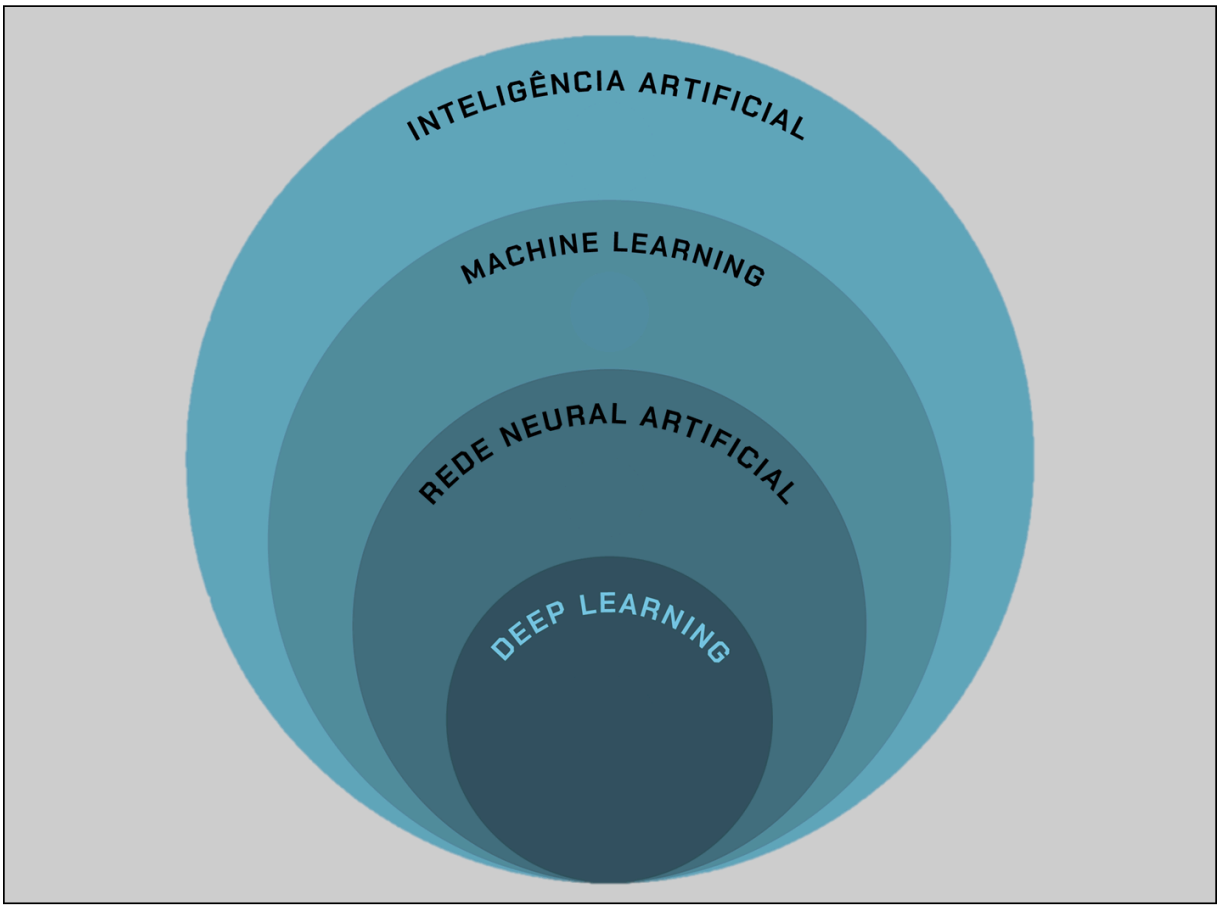

Fonte: Adaptado de PINKOWSKI (2023, p. 25)

O Perceptron, unidade básica de uma RNA, foi desenvolvido por Frank Rosenblatt em 1958 como o primeiro modelo de neurônio artificial, introduzindo o conceito de processamento inspirado em um neurônio biológico. Em sua estrutura simples, o Perceptron recebe um conjunto de entradas, que representam as variáveis de um problema específico, cada uma associada a um "peso" que indica sua importância relativa. Esses pesos, ajustáveis ao longo do tempo, desempenham um papel essencial no aprendizado da rede, pois influenciam diretamente a resposta do Perceptron. A partir das entradas e de seus respectivos pesos, o Perceptron calcula uma soma ponderada e a compara a um valor de limiar. Caso essa soma ultrapasse o limiar, o Perceptron é ativado, gerando uma saída positiva, geralmente representada pelo valor 1; caso contrário, a saída é negativa, representada pelo valor 0 (DAIBERT et al., 2009). Esse mecanismo de ativação binária permite que o Perceptron classifique dados em duas categorias, tornando-o ideal para resolver problemas de classificação linear. A descrição do Perceptron pode ser mais bem assimilada pela ilustração da figura 2 deste trabalho.

Esse modelo básico e inovador estabeleceu as bases para o aprendizado supervisionado e serviu de alicerce para o desenvolvimento de arquiteturas mais complexas, como as redes profundas. Em redes mais sofisticadas, múltiplos Perceptrons são combinados para formar camadas adicionais, permitindo que a rede aprenda padrões mais avançados. Durante o treinamento, os pesos dos Perceptrons são ajustados automaticamente para minimizar os erros de classificação, o que aprimora continuamente a precisão e eficiência da rede neural na resolução de problemas complexos. Dessa forma, o Perceptron tornou-se

essencial para o avanço de redes profundas, capazes de resolver problemas complexos e identificar padrões em diversos contextos (DAIBERT et al., 2009).

Figura 2 - Modelo Perceptron

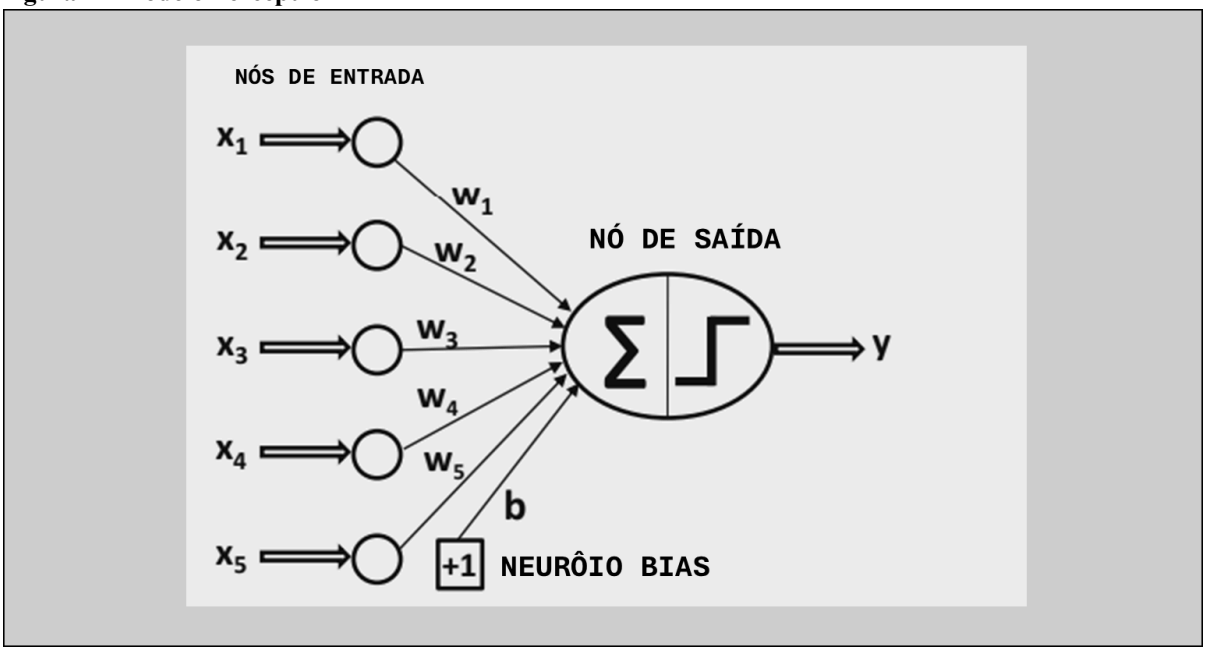

Fonte: Adaptado de AGGARWAL (2018, p. 5)

2.4 Gerenciamento de Projetos

O gerenciamento de projetos pode ser entendido como a aplicação de conhecimentos, habilidades, ferramentas e técnicas para garantir que as atividades de um projeto atendam aos requisitos estabelecidos. Já um projeto é definido como um esforço temporário com o objetivo de criar um produto, serviço ou resultado único (PMI, 2021). Esses conceitos são essenciais para orientar a execução de projetos em diferentes áreas, permitindo uma abordagem estruturada e eficiente para alcançar os objetivos propostos.

Nesse contexto, os domínios de desempenho no gerenciamento de projetos surgem como áreas fundamentais de atividade, que garantem a entrega eficaz de um projeto. Esses domínios abrangem aspectos que vão desde o engajamento das partes interessadas até a gestão da incerteza, e são interdependentes, operando de forma integrada para assegurar o sucesso do projeto como um todo (PMI, 2021). Entre os oito domínios de desempenho identificados, destacam-se: Partes Interessadas, Equipe, Abordagem de desenvolvimento e ciclo de vida, Planejamento, Trabalho do projeto, Entrega, Medição e Incerteza. Cada um desses domínios desempenha um papel essencial na execução eficiente e alinhada das atividades do projeto, formando uma base sólida para o gerenciamento de qualquer iniciativa.

Dentre eles, o domínio de desempenho da incerteza merece especial atenção, pois envolve a identificação, análise e resposta a riscos e oportunidades que podem impactar o projeto. Esse domínio é crítico, pois a incerteza é inerente a qualquer iniciativa, especialmente em ambientes dinâmicos e complexos, como os de projetos. O gerenciamento eficaz da incerteza inclui a capacidade de antecipar e mitigar possíveis ameaças, ao mesmo tempo em que se aproveitam oportunidades que podem agregar valor ao projeto. Isso requer uma abordagem proativa, que inclui a utilização de ferramentas de análise de risco e técnicas de resposta adequadas para garantir que as incertezas não comprometam os objetivos do projeto (PMI, 2021).

A integração desse domínio com os demais garante que a incerteza seja gerida de forma contínua, permitindo ajustes ao planejamento e à execução conforme novas

informações surgem e o projeto avança. Dessa forma, a gestão da incerteza torna-se uma peça-chave para a adaptação e resiliência do projeto diante de possíveis mudanças e desafios.

2.5 Gestão de Riscos

A gestão de riscos é definida como um conjunto de atividades coordenadas para dirigir e controlar uma organização em relação aos riscos, compreendidos como os efeitos da incerteza sobre os objetivos (ABNT, 2018). No contexto da MB, essa definição se torna particularmente relevante, uma vez que a identificação e o controle de riscos são essenciais para a execução dos projetos de obtenção de meios operativos, que visam garantir a segurança e a prontidão operacional. A implementação de uma abordagem estruturada e contínua para a gestão de riscos permite a identificação de ameaças e oportunidades que possam impactar a eficiência e o sucesso desses projetos.

Além disso, a norma ISO 31000 destaca que a gestão de riscos é uma parte integrante de todas as atividades organizacionais, o que inclui o gerenciamento de projetos, uma área organizacional essencial para o alcance dos objetivos estratégicos da MB. Assim, ao aplicar a gestão de riscos no âmbito de projetos, a MB assegura que os riscos são gerenciados de forma sistemática e integrada, promovendo um ambiente de tomada de decisão mais seguro e eficiente, o que contribui para a sustentabilidade e o sucesso de suas operações estratégicas (ABNT, 2018).

2.6 Matriz de Riscos

A matriz de probabilidade/impacto é amplamente reconhecida como uma ferramenta fundamental para o gerenciamento de riscos, pois possibilita a combinação de classificações qualitativas ou semi-quantitativas de impactos e probabilidades, gerando um nível de risco ou uma classificação correspondente. Conforme destaca a norma ABNT NBR ISO/IEC 31010:2012, a matriz de risco serve para estabelecer uma escala entre a probabilidade de ocorrência de um evento e a severidade dos impactos desse evento, permitindo uma visualização simplificada e objetiva dos riscos envolvidos no projeto. Esse tipo de matriz é particularmente útil em contextos em que dados quantitativos completos são escassos, mas a avaliação de riscos ainda é necessária para orientar a tomada de decisões e priorizar ações (ABNT, 2012).

O uso da matriz de probabilidade/impacto também contribui para a comunicação dos níveis de risco qualitativos em toda a organização, promovendo um entendimento compartilhado entre as partes envolvidas. Ela pode ser aplicada para categorizar riscos que demandam tratamento imediato, identificação de riscos que podem ser considerados aceitáveis, e para definir ações apropriadas de resposta a esses riscos. Ao combinar de maneira sistemática as escalas de probabilidade e impacto, essa matriz facilita o alinhamento do apetite ao risco com as práticas organizacionais, sendo uma ferramenta valiosa para o gerenciamento de projetos, onde o risco de eventos indesejáveis deve ser constantemente monitorado e controlado para garantir a execução segura e eficiente do projeto (ABNT, 2012). A figura 3 contribui para uma melhor compreensão da matriz de riscos.

Figura 3 - Matriz de probabilidade/impacto de riscos

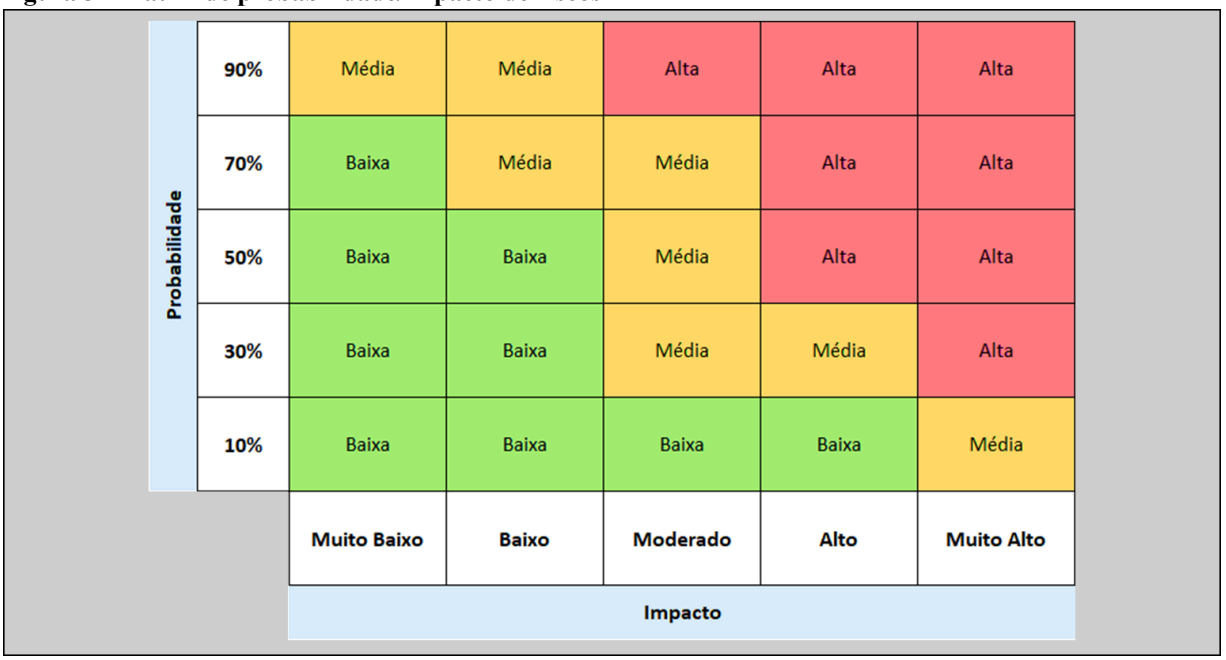

Fonte: Adaptado de PMI (2017, p. 408)

3 METODOLOGIA DA PESQUISA

Este trabalho adota a abordagem qualitativa, na qual o ambiente natural constitui a principal fonte de dados, exigindo que o pesquisador mantenha contato direto e imersivo com o objeto de estudo. Essa abordagem permite que os fenômenos sejam analisados em seu contexto original, sem intervenções, promovendo uma compreensão autêntica das questões observadas. Diferentemente da abordagem quantitativa, que prioriza dados estatísticos, a qualitativa se concentra em dados descritivos, buscando capturar a complexidade do fenômeno ao abranger o máximo possível de elementos da realidade estudada. Esse enfoque favorece a descrição detalhada dos processos em vez de resultados numéricos, viabilizando uma análise exploratória e aprofundada do tema investigado (Prodanov; Freitas, 2013).

Como suporte teórico, este trabalho utiliza pesquisa bibliográfica e pesquisa documental, métodos fundamentais para estudos acadêmicos, especialmente na revisão de literatura e na contextualização de dados. Segundo Gil (2017), a pesquisa bibliográfica é construída a partir de material publicado, como livros, periódicos e teses, além de recursos digitais disponíveis na internet. Essa modalidade é essencial, pois oferece a fundamentação teórica necessária para análise e discussão do tema. Neste trabalho, a pesquisa bibliográfica permite uma revisão abrangente das abordagens sobre gestão de riscos com o uso de IA, proporcionando uma análise crítica das técnicas existentes.

Já a pesquisa documental complementa a bibliográfica ao utilizar fontes não publicadas formalmente, como documentos internos e relatórios administrativos, que frequentemente carecem de tratamento analítico. Conforme Gil (2017), essa modalidade se vale de materiais brutos para fins de análise, sendo especialmente útil para uma investigação detalhada das práticas organizacionais. A opção pela pesquisa documental justifica-se pela relevância de examinar dados internos da MB, possibilitando uma compreensão aprofundada das práticas de gestão de riscos no contexto dos projetos, além de avaliar o potencial e as limitações das tecnologias de IA.

A pesquisa descritiva e a exploratória também foram selecionadas por serem compatíveis com os objetivos deste estudo sobre o uso de IA na gestão de riscos. A pesquisa descritiva, conforme Gil (2017), visa caracterizar os elementos de uma população ou

fenômeno específico, sendo adequada para descrever o estado atual da gestão de riscos em projetos da MB. Em complemento, a pesquisa exploratória foi escolhida por sua capacidade de expandir o entendimento inicial sobre o problema, permitindo que o pesquisador refine suas ideias e intuições, especialmente em contextos em que as variáveis e hipóteses ainda estão em definição (Gil, 2017). Essa abordagem exploratória é essencial para investigar a aplicação de IA em um campo complexo, onde a adaptabilidade e a flexibilidade são fundamentais para identificar aspectos que contribuam para a compreensão aprofundada do tema.

Para justificar o uso de entrevistas como método de coleta de dados neste estudo qualitativo, optou-se pela condução das entrevistas via aplicativos de áudio e texto. Esse formato proporciona uma interação flexível, adaptada às necessidades dos entrevistados e ao contexto investigado, sendo fundamental para captar informações diretamente do objeto de estudo. Segundo Marconi e Lakatos (2017, p. 212), "a entrevista é um encontro entre duas pessoas, a fim de que uma delas, mediante conversação, obtenha informações a respeito de determinado assunto", o que reforça a relevância desse método para obtenção de dados qualitativos de forma contextualizada e aprofundada. Embora a presença física seja, tradicionalmente, um requisito para a realização de entrevistas, Vergara (2004, p. 55) observa que "a presença física de ambos é necessária no momento da entrevista, mas, se você dispõe de mídia interativa, ela se torna dispensável". Dessa forma, o uso de mídias interativas não só torna viáveis as entrevistas remotas, mas também preserva a qualidade dos dados coletados, permitindo que o processo seja realizado de maneira prática e segura, com vistas a uma análise posterior detalhada e precisa.

Além disso, a análise de conteúdo "visa descrever de forma objetiva, sistemática e qualitativa o conteúdo manifesto da comunicação" (GIL, 2017, p. 54), sendo uma técnica adequada para o exame de documentos sobre o processo de gestão de riscos em projetos na MB. Esse método é justificado pela necessidade de investigar com rigor as normas e diretrizes oficiais, permitindo uma compreensão detalhada dos elementos presentes nas regulamentações e procedimentos institucionais. Adicionalmente, ao considerar que "documentos referem-se a textos escritos ou transcritos, como matéria veiculada em jornais e revistas, cartas, relatórios, cartazes e panfletos, ou à comunicação não verbal, como gestos e posturas" (GIL, 2017, p. 54), o uso da análise de conteúdo amplia o escopo de análise, contemplando uma diversidade de fontes. Dessa forma, a aplicação dessa técnica viabiliza um exame sistemático das diretrizes e normas, facilitando a identificação de aspectos críticos para a gestão de riscos e contribuindo para uma visão mais detalhada e integrada das práticas adotadas pela MB.

4 ANÁLISE DOS RESULTADOS

4.1 Análise argumentativa

4.1.1 Gestão de Riscos na MB

A partir de um estudo de análise da Metodologia de Gerenciamento de Projetos de Obtenção de Meios de Superfície, norma da DGePM, observa-se que, no contexto dos projetos, o planejamento do gerenciamento de riscos é uma etapa essencial que organiza e estrutura as atividades relacionadas à identificação, análise e resposta a riscos ao longo do ciclo de vida do projeto. De acordo com as diretrizes adotadas, o planejamento deve alinhar-se às práticas recomendadas por instituições como o Project Management Institute (PMI) e o Tribunal de Contas da União (TCU), além de obedecer às normas internas da MB. Dessa forma, busca-se garantir que os riscos sejam adequadamente gerenciados e que ações

mitigadoras sejam aplicadas conforme necessário, minimizando os impactos negativos e aproveitando oportunidades para o sucesso do projeto (BRASIL, 2024).

Além disso, a norma define risco como qualquer evento ou condição incerta que possa impactar positivamente ou negativamente os objetivos do projeto, diferenciando-o de "problema", que se refere a um evento já ocorrido e que gerou impactos indesejáveis no andamento do projeto. Enquanto o risco permite uma abordagem preventiva, o problema demanda ações corretivas para minimizar seus efeitos. Essa distinção direciona as estratégias de gerenciamento, assegurando que os recursos do projeto sejam aplicados de forma eficaz tanto na mitigação de incertezas futuras quanto na resolução de questões concretas já manifestadas (BRASIL, 2024).

As responsabilidades no gerenciamento de riscos concentram-se na coordenação e supervisão das atividades de identificação, análise e mitigação de incertezas, com suporte de equipes colaborativas. Reuniões periódicas facilitam o compartilhamento de informações e a avaliação dos possíveis impactos sobre os objetivos do projeto. Essa estrutura organizacional cria um sistema robusto de gestão de riscos, no qual cada membro tem um papel específico na identificação e no tratamento de incertezas (BRASIL, 2024).

De maneira contínua, a identificação de riscos se estende ao longo de todo o ciclo de vida do projeto, envolvendo o registro dos riscos em ferramentas específicas, como o Quadro Canvas, que organiza de forma estruturada e visual os elementos de risco. Para garantir clareza, utiliza-se uma sintaxe padronizada que descreve a causa, o evento de risco e suas potenciais consequências. Esse processo ocorre em reuniões dedicadas, nas quais as equipes discutem os riscos e documentam de forma sistemática as incertezas que podem impactar os objetivos do projeto, estabelecendo uma base sólida para o desenvolvimento das estratégias de análise e resposta aos riscos (BRASIL, 2024).

Por fim, a análise de riscos engloba aspectos qualitativos e quantitativos, permitindo uma priorização eficaz conforme a probabilidade de ocorrência e o impacto potencial. A análise qualitativa utiliza uma escala predefinida para classificar os riscos, facilitando a avaliação inicial e a priorização com base em critérios consistentes. A análise quantitativa, embora opcional, é aplicada quando há dados suficientes e o projeto apresenta alta complexidade, possibilitando uma avaliação mais detalhada. Esse duplo enfoque adapta a gestão de riscos às necessidades específicas de cada projeto, maximizando a eficácia das ações de mitigação e oferecendo uma compreensão mais profunda das incertezas que podem influenciar os resultados esperados (BRASIL, 2024).

Em relação à análise de risco qualitativa, foco deste trabalho, a norma estabelece que a probabilidade e o impacto de cada risco devem ser classificados em cinco categorias de intensidade, variando de “muito baixa” a “muito alta”. A categoria "Muito Baixa" abrange uma probabilidade entre 0% e 20%, com um peso atribuído de 0,1. A "Baixa" probabilidade corresponde à faixa de > 20% a ≤ 40%, com peso de 0,3. A classificação "Média" se situa entre > 40% e ≤ 60%, recebendo um peso de 0,5. Na categoria "Alta", a probabilidade varia de > 60% a ≤ 80%, com peso de 0,7. Finalmente, a categoria "Muito Alta" engloba probabilidades de > 80% até próximo de 100%, com um peso atribuído de 0,9. Essa estrutura de classificação padroniza a avaliação dos riscos, facilitando a priorização e a aplicação de estratégias de tratamento adequadas conforme o nível de risco identificado. A tabela 1 ilustra essa classificação.

Tabela 1 - Classificação de probabilidade e impacto de riscos

Qualificação	Percentual	Peso
Muito Baixa	> 0% | ≤ 20%	0,1

Qualificação	Percentual	Peso
Baixa	> 20% | ≤ 40%	0,3
Média	> 40% | ≤ 60%	0,5
Alta	> 60% | ≤ 80%	0,7
Muito Alta	> 80% | ≤ 100%	0,9

Fonte: Adaptado de Brasil (2024).

A classificação do risco nas categorias de probabilidade e impacto apresenta um grau considerável de subjetividade, sendo responsabilidade direta do Gerente do Programa ou Projeto. Contudo, esse processo conta com o apoio de outros membros do Grupo de Gerenciamento do Projeto (GGP), que contribuem para a análise e avaliação dos riscos envolvidos (BRASIL, 2024). Apesar dessa colaboração, a classificação ainda carrega certa subjetividade, em grande parte pela ausência de uma base de dados históricos consolidada que apoie as decisões de forma mais objetiva. A limitação de dados históricos reduz a precisão das estimativas, levando os responsáveis a se basearem principalmente em experiências anteriores e julgamentos profissionais, o que pode resultar em variações na avaliação dos riscos.

Ademais, após a realização de uma entrevista com um representante da organização, concluiu-se que, atualmente, a instituição não utiliza modelos de IA para determinar a probabilidade e o impacto dos riscos nos projetos de obtenção de meios. Essa ausência de modelos de IA na análise de riscos reforça a dependência de julgamentos com base na experiência dos gestores, o que pode comprometer a precisão das classificações e, consequentemente, a eficácia das estratégias de mitigação. A implementação de IA nessa tarefa apresenta-se como uma oportunidade relevante, uma vez que o uso de algoritmos avançados permitiria uma análise baseada em dados consistentes e em padrões históricos, reduzindo significativamente a carga subjetiva do processo.

4.1.2 Análise de possíveis modelos de IA adequados ao caso

4.1.2.1 Quanto à aprendizagem

Como já discutido neste trabalho no campo de ML, os métodos de aprendizado supervisionado, não supervisionado e por reforço se destacam pelas suas abordagens e aplicações distintas. O aprendizado supervisionado é caracterizado pela presença de pares de dados de entrada e saída, no qual o objetivo é treinar o modelo para aprender uma função f(x) que aproxime a saída desejada "y" com base nos exemplos fornecidos. Define-se aprendizagem supervisionada como:

> Dado um conjunto de entradas/variáveis independentes/preditores **x** e saídas/variáveis dependentes/alvos **y**, o objetivo é aprender uma função $f(\mathbf{x})$ que aproxima **y**. Isso é realizado supervisionando $f(\mathbf{x})$, ou seja, fornecendo a ela exemplos ($\mathbf{x}1$, $\mathbf{y}1$), …, ($\mathbf{x}n$, $\mathbf{y}n$) e feedback sempre que ela comete erros ou previsões precisas. (KOSHIYAMA, 2024, p. 4, tradução nossa).

Esse tipo de aprendizado é amplamente utilizado em problemas de classificação e regressão, nos quais os dados possuem rótulos conhecidos que orientam o modelo em direção ao resultado correto.

Por outro lado, o aprendizado não supervisionado lida com dados que não possuem rótulos ou alvos predefinidos, o que significa que o modelo precisa identificar padrões ou estruturas ocultas nos dados de forma autônoma. Em relação ao aprendizado não supervisionado:

> Dados vários objetos/amostras/transações $\mathbf{x}1$, …, $\mathbf{x}n$, o objetivo é aprender um mapa oculto $h(\mathbf{x})$ que pode descobrir uma estrutura oculta nos dados. Este mapa oculto

> pode ser usado para 'comprimir' **x** (também conhecido como redução de dimensionalidade) ou para atribuir a cada **x**i um grupo *ck* (também conhecido como agrupamento ou modelagem de tópicos). (KOSHIYAMA, 2024, p. 4, tradução nossa).

Este método é frequentemente aplicado em técnicas de agrupamento, como a clusterização, onde os dados são segmentados em grupos com características semelhantes.

O aprendizado por reforço, por sua vez, envolve um agente que interage com um ambiente e toma ações em diferentes estados, buscando maximizar uma recompensa ao longo do tempo. Esse processo é descrito como:

> Dado um ambiente formado por vários estados $s1$, $s2$, …, sn, um agente e uma função de recompensa, o objetivo é aprender uma política π que guiará as ações de um agente $a1$, $a2$, …, ak através do espaço de estados de forma a maximizar as recompensas ocasionais. (KOSHIYAMA, 2024, p. 4, tradução nossa).

Este tipo de aprendizado é bastante utilizado em problemas de controle, otimização e jogos, onde o agente aprende a tomar decisões baseadas no feedback de suas ações no ambiente.

Para o caso específico de determinação da probabilidade e impacto de riscos em cinco categorias distintas (muito baixa, baixa, média, alta e muito alta) como feito na MB, a abordagem de aprendizado supervisionado é a mais adequada. Isso ocorre porque, nesse contexto, é possível utilizar dados históricos rotulados, a partir dos quais os níveis de probabilidade e impacto foram previamente classificados com base em variáveis conhecidas e mensuráveis. Com um conjunto de dados rotulado, o modelo supervisionado pode ser treinado para associar as características dos riscos a uma das cinco categorias de classificação, permitindo uma avaliação mais precisa e consistente dos riscos futuros.

Em contrapartida, o aprendizado não supervisionado não seria adequado para este caso, pois ele é projetado para identificar padrões ocultos em dados sem rótulos predefinidos, o que dificulta a tarefa de classificação em categorias específicas. Esse tipo de aprendizado é mais indicado para cenários nos quais o objetivo é agrupar dados semelhantes ou reduzir a dimensionalidade dos dados, sem uma definição clara das categorias de saída. No contexto da determinação de probabilidade e impacto de riscos, o aprendizado não supervisionado não possui a estrutura necessária para categorizar dados em níveis específicos sem orientação.

Da mesma forma, o aprendizado por reforço também não é adequado para esta tarefa, uma vez que ele se aplica melhor a situações onde um agente deve tomar decisões e interagir com um ambiente dinâmico para maximizar recompensas ao longo do tempo. Esse tipo de aprendizado é amplamente utilizado em robótica e em jogos, onde as ações do agente influenciam diretamente o ambiente. No caso de categorização de probabilidade e impacto de riscos, não há interação com um ambiente em tempo real, nem um sistema de recompensas que guie o aprendizado. Assim, o aprendizado por reforço não se alinha aos requisitos de uma tarefa que visa apenas classificar dados históricos em categorias predefinidas.

4.1.2.2 Quanto à linearidade

No contexto de ML, os algoritmos podem ser classificados em três categorias principais. De acordo com Silva, Almeida e Ramalho (2016, p. 6):

> De um modo geral, na etapa de aprendizado, os algoritmos de ML podem ser divididos nas seguintes categorias: lineares (regressão logística); não lineares (*K – nearest neighbors, naïve bayes classifier, neural network e support vector machines*); e modelos baseados em árvores de decisão (*regression trees, classification trees, bagging, random forest* e *gradiente boosting*).

Cada uma dessas categorias é adaptada a diferentes tipos de problemas: os modelos lineares, como a regressão logística, são indicados quando a relação entre as variáveis

preditoras e a variável alvo é aproximadamente linear; os modelos não lineares, como redes neurais e máquinas de vetores de suporte, são mais eficazes para padrões complexos e não lineares; e os modelos baseados em árvores de decisão são especialmente úteis para problemas que envolvem relações complexas e não lineares, dividindo o espaço de preditores em regiões distintas e permitindo previsões baseadas nas características de cada uma.

Para o caso da determinação de níveis de probabilidade e impacto de riscos classificados em cinco categorias, um modelo não linear é o mais adequado. Este tipo de modelo, que inclui métodos como redes neurais, *K-nearest neighbors* e *support vector machines*, é projetado para capturar padrões complexos e relações não lineares entre variáveis, características que são vantajosas quando se trata de fatores de risco variados que influenciam probabilidades e impactos. Com um modelo não linear, é possível utilizar um conjunto diversificado de variáveis para prever com mais precisão a categoria de risco, permitindo um ajuste flexível e refinado às variações dos dados de entrada.

Por outro lado, os modelos lineares, como a regressão logística, são limitados em sua capacidade de representar relações complexas entre variáveis e podem não ser adequados para uma tarefa com múltiplas classes de saída, como neste caso, onde é necessário categorizar em cinco níveis distintos. Embora os modelos baseados em árvores de decisão também sejam eficazes para classificação, a escolha por um modelo não linear se justifica pela necessidade de capturar com maior sensibilidade as nuances dos dados e pela flexibilidade dos modelos não lineares em lidar com padrões de dados que podem não se ajustar a divisões rígidas do espaço de preditores.

4.1.2.3 Quanto à regressão ou classificação

Para determinar o nível de probabilidade e impacto dos riscos a partir de atributos qualitativos e quantitativos, o problema se enquadra mais adequadamente na categoria de classificação. Isso ocorre porque,segundo James, Witten, Hastie e Tibshirani (2013, p. 28, tradução nossa), "problemas que envolvem uma resposta qualitativa são frequentemente referidos como problemas de classificação". Nesse caso, a resposta é categórica, queremos prever uma das cinco classes (muito baixa, baixa, média, alta e muito alta) para cada situação de risco, não sendo, portanto, um problema de natureza quantitativa.

A regressão, por outro lado, é mais indicada para situações em que a variável de saída é numérica, como explica James et al. (2013, p. 28, tradução nossa): "Problemas com uma resposta quantitativa tendem a ser referidos como problemas de regressão". Embora seja possível utilizar a regressão para respostas qualitativas binárias por meio de uma codificação de 0 ou 1, esse método apresenta limitações para situações com mais de duas categorias. Nesse sentido, "não há uma forma natural de converter uma variável de resposta qualitativa com mais de dois níveis em uma resposta quantitativa pronta para regressão linear" (JAMES et al., 2013, p. 130, tradução nossa). Essa limitação torna o uso de métodos de classificação mais adequado, uma vez que eles são projetados especificamente para tratar de variáveis qualitativas, oferecendo maior precisão e interpretabilidade para a previsão de classes em diferentes níveis de probabilidade e impacto.

4.1.2.4 Quanto à função ativação de saída

Para a determinação dos níveis de probabilidade e impacto de riscos em cinco categorias distintas (muito baixa, baixa, média, alta e muito alta) com base em dados históricos e atributos variados, a utilização de um modelo de aprendizado supervisionado e não linear, como RNAs, mostra-se particularmente apropriada. Conforme argumentado, o aprendizado supervisionado é ideal para cenários onde há rótulos predefinidos que orientam o modelo, permitindo que ele associe as características dos riscos a uma das categorias desejadas com base em exemplos passados (KOSHIYAMA, 2024). Além disso, RNAs, sendo

modelos não lineares, são eficazes para capturar padrões complexos e interações entre variáveis, que frequentemente caracterizam dados de risco com múltiplos fatores influenciadores e relações não lineares (SILVA; ALMEIDA; RAMALHO, 2016). Enquanto métodos de classificação são mais indicados para problemas com saídas qualitativas (JAMES et al., 2013), a flexibilidade das redes neurais para ajustar-se a dados não lineares reforça sua adequação para uma tarefa de categorização como esta, onde é essencial capturar as nuances dos dados de entrada para uma previsão precisa dos níveis de risco.

Nas RNAs, a função de ativação é fundamental para transformar as saídas das camadas intermediárias em sinais que podem ser propagados para as camadas seguintes ou gerar o resultado final. Esse mecanismo espelha o funcionamento dos neurônios biológicos, onde estímulos precisam ultrapassar um limiar para que uma resposta seja gerada. No Perceptron, modelo básico de neurônio artificial, a função de ativação é binária. Caso a soma ponderada das entradas ultrapasse o limiar, o Perceptron é ativado, gerando uma saída positiva, geralmente representada pelo valor 1, caso contrário, a saída é negativa, representada pelo valor 0 (DAIBERT et al., 2009). Esse mecanismo binário, que permite classificações simples, estabeleceu as bases para arquiteturas mais complexas, onde funções como sigmóide ou ReLU permitem modelar padrões não lineares. Em redes profundas, essas funções facilitam a representação hierárquica dos dados, essencial para a identificação de padrões complexos em problemas de classificação e previsão de riscos, aumentando a capacidade de aprendizado da rede.

Para determinar os níveis de probabilidade e impacto de riscos em cinco categorias distintas, a função de ativação Softmax é especialmente adequada para a camada de saída de uma rede neural, pois transforma os valores de saída em probabilidades associadas a cada classe, facilitando a interpretação dos resultados em termos de classificação multiclasse. Como explica Aggarwal (2018, p. 15), “para predições multiway, como a previsão de identificadores de palavras ou uma entre múltiplas classes, a saída Softmax é particularmente útil”. A função de ativação Softmax é eficaz na conversão das saídas da rede neural em probabilidades que somam 100%, essencial para classificar os dados de risco em níveis específicos. Como descrito: "a função Softmax converte previsões reais v1...vk em probabilidades de saída o1...ok" (AGGARWAL, 2018, p. 118). Por exemplo, ao determinar níveis de probabilidade e impacto de risco, queremos que cada um dos cinco níveis (muito baixa, baixa, média, alta e muito alta) tenha uma probabilidade associada. A Softmax assegura que essas probabilidades sejam normalizadas, somando sempre 100%, o que facilita a interpretação do modelo, pois a classe com maior probabilidade pode ser diretamente considerada como a previsão da rede. Essa propriedade é essencial para tarefas de classificação onde os níveis de saída são mutuamente exclusivos, como ocorre na categorização de riscos. A representação de redes neurais com função de ativação Softmax na camada de saída pode ser mais bem compreendida na figura 4 deste trabalho.

Figura 4 - Rede neural com função de ativação Softmax na camada de saída

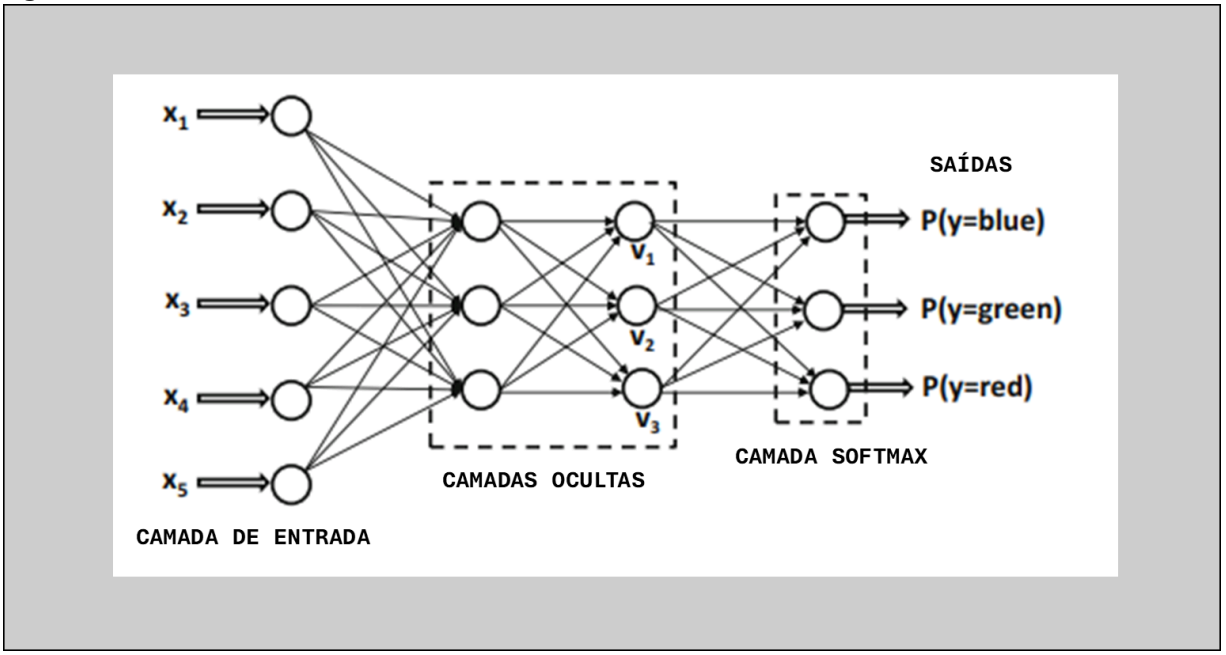

Fonte: Adaptado de AGGARWAL (2018, p. 14)

Em relação ao caso concreto de determinação de probabilidade e impacto de riscos em projetos na MB, para melhor elucidação, o quadro 1 deste trabalho elenca exemplos de atributos que podem influenciar a probabilidade de ocorrência de um risco, bem como os que podem influenciar o nível de impacto:

Quadro 1 - Exemplos de atributos de probabilidade e impacto de riscos de projeto

Probabilidade	**Impacto**
P1 - Complexidade técnica do projeto	I1 - Custo do projeto
P2 - Experiência da equipe com projetos similares	I2 - Criticidade do meio operativo adquirido
P3 - Condições econômicas	I3 - Prazo do projeto
P4 - Condições políticas	I4 - Dependência de tecnologia
P5 - Fornecimento de insumos e componentes	I5 - Reputação e consequências políticas
P6 - Cronograma de projeto	I6 - Disponibilidade de soluções alternativas
P7 - Histórico de riscos	I7 - Impacto ambiental e regulatório

Fonte: Elaborado pelo autor (2024).

Os valores de cada atributo podem ser julgados com base na experiência dos profissionais da equipe envolvida no projeto. Tais valores podem assumir um nível dentro de uma escala de números inteiros entre 1 e 5, sendo 1 para uma menor influência entre o atributo e o resultado da probabilidade ou impacto, e 5 para uma maior influência. A tabela 2 deste trabalho elenca os possíveis valores assumidos pelos atributos.

Tabela 2 - Exemplos de valores assumidos pelos atributos

Valor	Nível de influência
1	Muito baixa
2	Baixa
3	Média
4	Alta
5	Muito alta

Fonte: Elaborado pelo autor (2024).

Para esclarecer, considera-se um exemplo hipotético de risco em um projeto de aquisição naval “atraso na entrega de sistemas eletrônicos críticos”, o qual pode impactar significativamente o sucesso do projeto. Nesse cenário, a probabilidade de ocorrência é elevada devido à alta complexidade técnica do projeto (valor 5), à experiência limitada da equipe em projetos similares (valor 3) e à inconsistência no fornecimento de componentes (valor 5). Além disso, o impacto potencial desse atraso é igualmente crítico, visto que o sistema eletrônico é essencial para o funcionamento do meio naval e este possui alta criticidade (valor 5), com grande dependência tecnológica e poucas alternativas de substituição (valores 5 e 3, respectivamente). Esses valores, dentre outros atribuídos aos demais atributos, alimentam a camada de entrada da RNA com função de ativação Softmax na camada de saída conforme demonstram as figuras 5 e 6 deste trabalho.

Figura 5 - Representação dos atributos de probabilidade alimentando a RNA

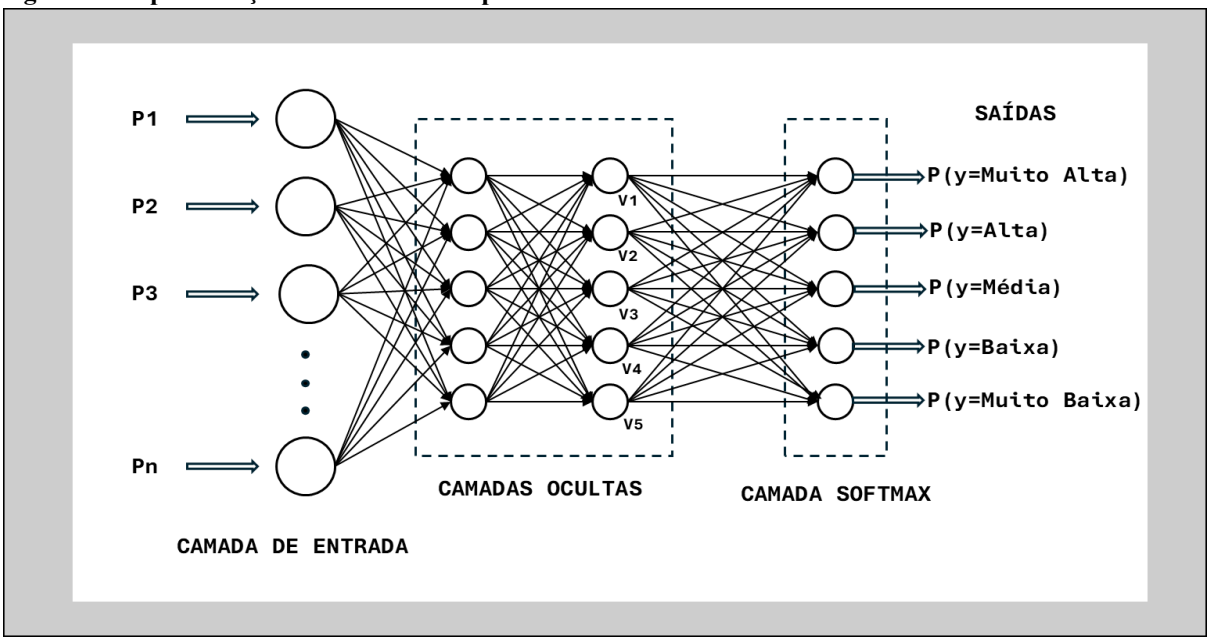

Fonte: Adaptado de AGGARWAL (2018, p. 14)

Figura 6 - Representação dos atributos de impacto alimentando a RNA

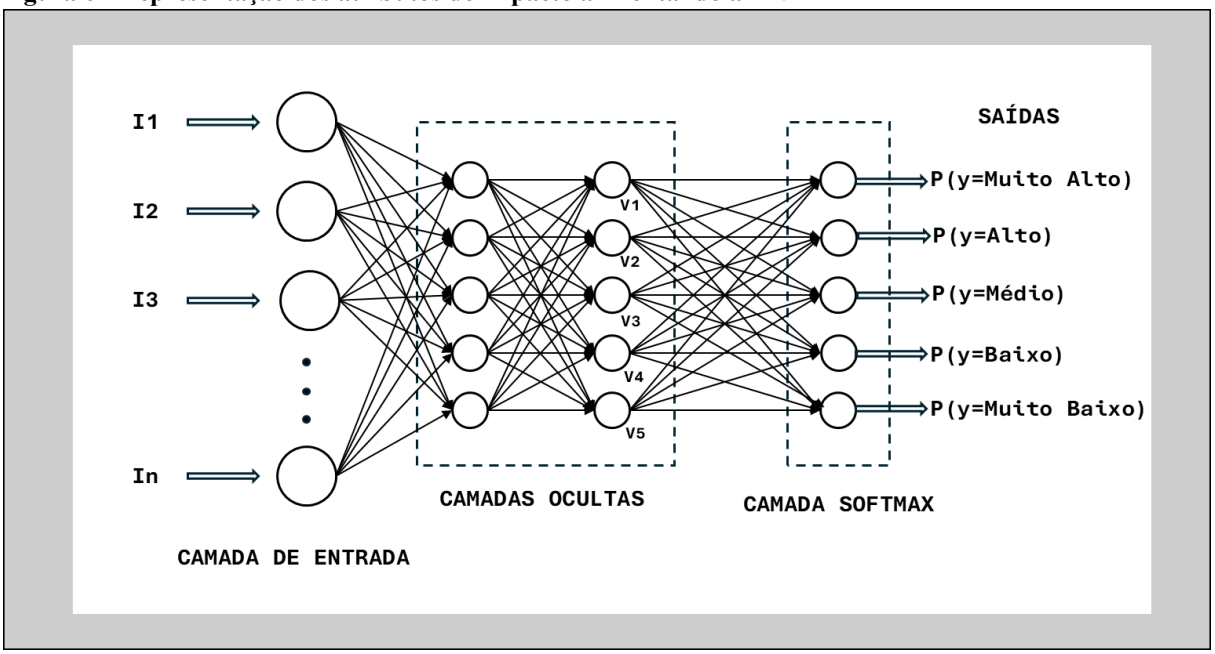

Fonte: Adaptado de AGGARWAL (2018, p. 14)

4.2. Discussão dos resultados

Na discussão dos resultados obtidos, a escolha da RNA com a função de ativação Softmax na camada de saída para a avaliação de riscos em projetos da MB no contexto da DGEPMARINST N° 10-01 se justifica pela complexidade do problema e a necessidade de uma classificação precisa em cinco categorias de risco (muito baixa, baixa, média, alta e muito alta). O modelo de RNA com função Softmax possibilita a conversão das saídas da rede em uma distribuição de probabilidades entre as classes, o que facilita a interpretação e permite uma categorização clara dos riscos. Essa abordagem não apenas promove uma saída intuitiva, na qual a probabilidade de cada nível de risco é comparada, mas também favorece a identificação direta da categoria mais provável, conferindo maior confiança às decisões baseadas em IA.

A escolha pela RNA com função de ativação Softmax na camada de saída também se apoia em critérios de aprendizado, linearidade e classificação abordados no trabalho. Como discutido, o aprendizado supervisionado se mostra ideal para situações em que há rótulos predefinidos, como os níveis de risco categóricos, permitindo ao modelo associar dados de entrada a uma classe de saída específica com base em exemplos históricos. A natureza não linear das RNAs, ao contrário de modelos lineares que têm limitações em relações complexas, facilita o reconhecimento de padrões intrincados e interdependências entre os fatores de risco. Além disso, o uso de Softmax atende ao requisito de classificação qualitativa, uma vez que problemas com saídas categóricas, como este, requerem um modelo que possa lidar eficientemente com múltiplas classes exclusivas.

5 CONSIDERAÇÕES FINAIS

Este trabalho teve como principal objetivo investigar a aplicabilidade de modelos de IA na gestão de riscos de projetos no contexto da MB. Embora o foco tenha sido a análise da adequação desses modelos para o caso específico da DGePM, é importante ressaltar que o escopo deste estudo não incluiu a implementação prática de qualquer modelo de IA. Em vez disso, o estudo se concentrou na análise conceitual e na avaliação teórica do potencial uso de

IA para aprimorar a gestão de riscos, particularmente na fase de determinação de probabilidade e impacto, conforme aplicado na análise qualitativa de riscos.

Com base nas análises conduzidas, conclui-se que a aplicação de IA pode trazer benefícios significativos para a gestão de riscos de projetos na MB, especialmente ao reduzir a subjetividade presente na determinação de probabilidade e impacto de eventos de risco. Entretanto, a abordagem sugerida neste estudo abrange apenas uma pequena fase do processo de gestão de riscos, deixando outras etapas da análise e resposta a riscos ainda não exploradas quanto ao potencial de automação e melhoria com IA.

Recomenda-se que futuros estudos explorem a implementação prática dos modelos de IA analisados, permitindo uma validação empírica dos conceitos discutidos. Além disso, investigações futuras poderiam considerar a aplicação de IA nas demais fases da gestão de riscos, incluindo o monitoramento contínuo e a resposta a riscos, bem como em outras áreas de desempenho do gerenciamento de projetos. Essas iniciativas podem não apenas solidificar o entendimento da IA na gestão de projetos da MB, mas também contribuir para um gerenciamento mais assertivo, alinhado aos objetivos estratégicos da instituição.

REFERÊNCIAS

ABNT - Associação Brasileira De Normas Técnicas. **ABNT NBR ISO 31000**: Gestão de riscos: Diretrizes. Rio de Janeiro: ABNT, 2018.

ABNT - Associação Brasileira De Normas Técnicas. **ABNT NBR ISO/IEC 31010**: Gestão de riscos: Técnicas para o processo de avaliação de riscos. Rio de Janeiro: ABNT, 2012.

AGGARWAL, Charu C. **Neural Networks and Deep Learning**: A Textbook. Cham: Springer, 2018.

BELHARET, Adel; BHARATHAN, Urmila; DZINGINA, Benjamin; MADHAVAN, Neha; MATHUR, Charul; TOTI, Yves-Daniel B. **Report on the Impact of Artificial Intelligence on Project Management**. SSRN Electronic Journal, 2020. Disponível em: https://ssrn.com/abstract=3660689. Acesso em: 19 out. 2024.

BENGIO, Y.; COURVILLE, A.; GOODFELLOW, I. **Deep Learning**. Cambridge: MIT Press, 2017.

BRASIL. Marinha do Brasil. **Plano Estratégico da Marinha (PEM 2040)**. Marinha do Brasil. Estado-Maior da Armada. Brasília: 2020. Disponível em: https://www.marinha.mil.br/sites/all/modules/pub_pem_2040/book.html. Acesso em: 03 jul. 2024

BRASIL. Marinha do Brasil. **DGEPMARINST N° 10-01**: Gerenciamento de Projetos de Obtenção de Meios de Superfície. Marinha do Brasil. Diretoria de Gestão de Programas da Marinha. Rio de Janeiro: 2024.

DAIBERT, M. S.; BRAGA, J. L.; OLIVEIRA, A. P.; ROCHA, M. N. **Monitoramento de Riscos em Projetos de Software**: Uma Abordagem Baseada em Dinâmica de Sistemas e Redes Neurais Artificiais. Viçosa: Departamento de Informática, Universidade Federal de Viçosa, 2009. Disponível em: https://www.academia.edu/download/61384970/CLEI2009-RNA-Riscos-Software-Project-Final20191130-92268-1o4lkrw.pdf. Acesso em: 19 out. 2024.

GIL, Antonio Carlos. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 2017.

JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor; TIBSHIRANI, Robert. **An Introduction to Statistical Learning**: with Applications in R. New York: Springer, 2013.

KOSHIYAMA, Adriano; FIROOZYE, Nick; TRELEAVEN, Philip. **Algorithms in Future Capital Markets**. SSRN Electronic Journal, 2020. Disponível em: https://ssrn.com/abstract=3527511. Acesso em: 19 out. 2024.

MARCONI, Marina de Andrade; LAKATOS, Eva Maria. **Fundamentos de metodologia científica**. São Paulo: Atlas, 2017.

PINKOWSKI, Márcio Luiz. **Aplicação da inteligência artificial na gestão de projetos:** aderência, impacto e grau de desenvolvimento. Dissertação (Mestrado) - Universidade Nove de Julho, São Paulo, 2023. Disponível em: http://bibliotecatede.uninove.br/handle/tede/3210. Acesso em: 15 out. 2024.

PMI. **A Guide to the Project Management Body of Knowledge:** PMBOK Guide. 6. ed. Newtown Square: Project Management Institute, 2017.

PMI. **Padrão de gerenciamento de projetos e Guia do conhecimento em gerenciamento de projetos:** Guia PMBOK. 7. ed. Newtown Square: Project Management Institute, 2021.

PRODANOV, C. C.; FREITAS, E. C. **Metodologia do trabalho científico**: métodos e técnicas da pesquisa e do trabalho acadêmico. Novo Hamburgo: Feevale, 2013.

SILVA, Andréa Ferreira da; ALMEIDA, Aléssio Tony Cavalcanti de; RAMALHO, Hilton Martins de Brito. **Predição do risco de reprovação no ensino superior usando algoritmos de machine learning**. João Pessoa: Universidade Federal da Paraíba, 2016. Disponível em: https://periodicos.ufpb.br/ojs2/index.php/tpa/article/download/51124/30935/141044. Acesso em: 20 out. 2024.

VERGARA, Sylvia Constant. **Projetos e relatórios de pesquisa em administração**. São Paulo: Atlas, 2004.