

ESCOLA DE GUERRA NAVAL

CC (T) RAQUEL MAXIMINO

**MINERAÇÃO DE DADOS NA GESTÃO ORÇAMENTÁRIA:
Novas possibilidades para a Tomada de Decisão
na Marinha do Brasil**

Rio de Janeiro

2024

CC (T) RAQUEL MAXIMINO

**MINERAÇÃO DE DADOS NA GESTÃO ORÇAMENTÁRIA:
Novas possibilidades para a Tomada de Decisão
na Marinha do Brasil**

Monografia apresentada à Escola de
Guerra Naval, como requisito parcial
para a conclusão do Curso Superior.

Orientador: CMG (Ref-FN) Ítalo de
Melo Pinto

Rio de Janeiro
Escola de Guerra Naval
2024

DECLARAÇÃO DA NÃO EXISTÊNCIA DE APROPRIAÇÃO INTELECTUAL IRREGULAR

Declaro que este trabalho acadêmico: a) corresponde ao resultado de investigação por mim desenvolvida, enquanto discente da Escola de Guerra Naval (EGN); b) é um trabalho original, ou seja, que não foi por mim anteriormente utilizado para fins acadêmicos ou quaisquer outros; c) é inédito, isto é, não foi ainda objeto de publicação; e d) é de minha integral e exclusiva autoria.

Declaro também que tenho ciência de que a utilização de ideias ou palavras de autoria de outrem, sem a devida identificação da fonte, e o uso de recursos de inteligência artificial no processo de escrita constituem grave falta ética, moral, legal e disciplinar. Ademais, assumo o compromisso de que este trabalho possa, a qualquer tempo, ser analisado para verificação de sua originalidade e ineditismo, por meio de ferramentas de detecção de similaridades ou por profissionais qualificados.

Os direitos morais e patrimoniais deste trabalho acadêmico, nos termos da Lei 9.610/1998, pertencem ao seu Autor, sendo vedado o uso comercial sem prévia autorização. É permitida a transcrição parcial de textos do trabalho, ou mencioná-los, para comentários e citações, desde que seja feita a referência bibliográfica completa.

Os conceitos e ideias expressas neste trabalho acadêmico são de responsabilidade do Autor e não retratam qualquer orientação institucional da EGN ou da Marinha do Brasil.

Assinatura digital gov.br

DEDICATÓRIA

Dedico este trabalho à minha família, especialmente ao meu esposo Eduardo e ao meu filho Enzo, meus grandes companheiros de jornada. Sempre presentes, ofereceram-me amor, apoio e inspiração em cada passo desse caminho.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por Sua mão sempre me conduzir e me fortalecer, mesmo diante dos obstáculos.

Aos meus pais, Jailton e Zenaide, por toda a confiança, amor, abdicação e incentivo, cujos exemplos me guiaram para uma vida de caráter e dedicação.

À minha amada família, meu esposo Eduardo e meu filho Enzo, por entenderem minhas ausências e por estarem sempre ao meu lado, me encorajando em cada etapa.

Aos meus amigos CASNAVIANOS, em especial à Divisão de Sistemas Informatizados (CASNAV-13), pelo apoio, incentivo, orientações e compreensão no decorrer deste curso.

À equipe do Curso Superior 2024 da Escola de Guerra Naval, pelo prestimoso auxílio fornecido em cada fase.

Por fim, agradeço imensamente ao meu orientador, Capitão de Mar e Guerra (Ref-FN) Ítalo de Melo Pinto, pelas orientações precisas, pelas indagações pertinentes, por me desafiar à reflexão, pelo tempo dispendido, pela paciência e confiança em mim depositada.

Gratidão.

Os que semeiam com lágrimas colherão
com gritos de alegria. Choram enquanto
lançam as sementes, mas cantam
quando voltam com a colheita.

Salmos 126:5-6

RESUMO

A complexidade das decisões orçamentárias em instituições públicas envolve diversas perspectivas, incluindo aspectos hierárquicos, políticas, riscos, incertezas e interesses das partes envolvidas. Embora a intuição sempre esteja presente, a eficiência na tomada de decisão depende da qualidade das informações disponíveis, da capacidade de avaliação e análise dos decisores, e da estrutura organizacional. No contexto da gestão orçamentária da Marinha do Brasil (MB), esses desafios são ainda mais pronunciados, especialmente em cenários de cortes e contingenciamentos. A MB possui diretivas de planejamento bem definidas e procedimentos automatizados que mantêm o histórico das metas orçamentárias planejadas em cada setor. No entanto, a complexidade dessas informações muitas vezes dificulta o entendimento por parte dos decisores, tornando a alocação de recursos um processo desafiador. Nesse cenário, as técnicas de Mineração de Dados (MD) surgem como uma solução promissora, capaz de identificar padrões e correlações ocultas nos dados orçamentários, fornecendo insights relevantes para decisões mais estratégicas e informadas. Este trabalho concentra-se em analisar a aplicabilidade dessas técnicas no contexto da alocação de recursos do Plano Diretor da Marinha do Brasil. Como resultados destacam-se a identificação das técnicas de MD mais utilizadas no setor financeiro e na gestão orçamentária, uma análise detalhada dos desafios específicos da alocação orçamentária na MB, e a avaliação das contribuições potenciais da Mineração de Dados para aprimorar a tomada de decisão na gestão orçamentária da MB.

Palavras-chave: Mineração de Dados, Gestão Orçamentária, Tomada de Decisão, Setor financeiro, Alocação de Recursos, Tomada de Decisão orientada a dados.

ABSTRACT

DATA MINING IN BUDGET MANAGEMENT: NEW POSSIBILITIES FOR DECISION MAKING IN THE BRAZILIAN NAVY

The complexity of budget decisions in public institutions involves various perspectives, including hierarchical aspects, politics, risks, uncertainties and the interests of the parties involved. Although intuition is always present, efficient decision-making depends on the quality of the information available, the decision-makers' capacity for evaluation and analysis, and the organizational structure. In the context of the Brazilian Navy's (MB) budget management, these challenges are even more pronounced, especially in scenarios of cuts and contingencies. The MB has well-defined planning directives and automated procedures that keep track of planned budget targets in each sector. However, the complexity of this information often makes it difficult for decision-makers to understand, making resource allocation a challenging process. In this scenario, Data Mining (DM) techniques have emerged as a promising solution, capable of identifying hidden patterns and correlations in budget data, providing relevant insights for more strategic and informed decisions. This work focuses on analysing the applicability of these techniques in the context of resource allocation in the Brazilian Navy's Master Plan. The results include the identification of the most commonly used DM techniques in the financial sector and in budget management, a detailed analysis of the specific challenges of budget allocation in the MB, and an assessment of the potential contributions of Data Mining to improving decision-making in MB budget management.

Keywords: Data Mining, Budget Management, Decision Making, Financial Sector, Resource Allocation, Data-Driven Decision Making.

LISTA DE ILUSTRAÇÕES E TABELAS

FIGURA 1 - Aplicações de Mineração de Dados em contabilidade por tópico contábil, objetivo de MD e tarefa de MD.	21
FIGURA 2 - Amostra de distribuição das Ações Internas Planejadas X Realizadas em 2023.....	33
TABELA 1 - Técnicas de Mineração de Dados mais aplicadas no Setor Financeiro.....	22
TABELA 2 - Regras de Associação geradas pelo algoritmo Apriori.....	34

LISTA DE ABREVIATURAS E SIGLAS

AI	Ação Interna
ALTCRED	Alteração de Crédito
CCSM	Centro de Comunicação Social da Marinha
COFAMAR	Conselho Financeiro e Administrativo da Marinha
COPLAN	Conselho do Plano Diretor
CTPD	Calendário de Trabalho do Plano Diretor
DDD	Data-Driven Decision Making
DGOM	Diretoria de Gestão Orçamentária da Marinha
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
GCM	Gabinete do Comandante da Marinha
LDO	Lei de Diretrizes Orçamentárias
LOA	Lei Orçamentária Anual
KNN	K-Nearest Neighbors
MB	Marinha do Brasil
MD	Mineração de Dados
ODG	Órgão de Direção Geral
ODS	Órgão de Direção Setorial
PA	Plano de Ação
PD	Plano Diretor
PEM	Plano Estratégico da Marinha
PPA	Plano Plurianual
RNAs	Redes Neurais Artificiais
SAD-ORC	Sistema de auxílio à decisão de Gestão Orçamentária
SECIRM	Secretaria da Comissão Interministerial para os Recursos do Mar
SIAFI	Sistema Integrado de Administração Financeira do Governo Federal
SICONV	Sistema de Gestão de Convênios e Contratos de Repasse
SIG	Sistemas de Informações Geográficas
SIOPS	Sistema de Informações sobre Orçamentos Públicos em Saúde

SIPLAD	Sistema de Acompanhamento do Plano Diretor
SISCPO	Sistema da Comissão de Promoção de Oficiais
SISPAG	Sistema de Pagamento da Marinha
SISPEM	Sistema de Planejamento Estratégico da Marinha
SPD	Sistema do Plano Diretor
SPOF	Sistema de Planejamento Orçamentário e Financeiro
SVM	Support Vector Machines
UG	Unidade Gestora

SUMÁRIO

1	INTRODUÇÃO.....	12
2	REFERENCIAL TEÓRICO.....	15
2.1	Tomada de Decisão e Data-Driven Decision Making (DDD).....	15
2.2	Ciência de Dados e Mineração de Dados.....	16
2.3	Gestão Orçamentária.....	18
3	MINERAÇÃO DE DADOS NO SETOR FINANCEIRO.....	19
3.1	Aplicações e Contribuições da MD no Setor Financeiro.....	20
3.2	Contribuições na Gestão Orçamentária	23
4	A ALOCAÇÃO ORÇAMENTÁRIA NA MB, OS DESAFIOS E AS POTENCIALIDADES DA MD.....	25
4.1	O processo de alocação orçamentária no Plano Diretor da MB.....	25
4.2	Os desafios da alocação orçamentária no Plano Diretor da MB.....	28
4.3	As potencialidades da Mineração de Dados para a alocação orçamentária da MB.....	29
5	MINERAÇÃO DE DADOS E SUA CONTRIBUIÇÃO PARA A TOMADA DE DECISÃO QUANTO À ALOCAÇÃO DE RECURSOS NA MB.....	32
5.1	Mineração de Dados aplicada ao Plano Diretor	32
5.2	A Mineração de Dados e suas contribuições no processo decisório.....	35
6	CONCLUSÃO.....	37
7	REFERÊNCIAS.....	39

1 INTRODUÇÃO

A tomada de decisão nas instituições tem sido objeto de estudo ao longo dos anos, sob diferentes perspectivas. Seja hierárquica, um processo institucionalizado, baseada em políticas, riscos e incertezas, ou nos interesses de diferentes partes, é notório que a sua eficiência depende de um conjunto de aspectos distintos que necessitam ser considerados, indo muito além da mera intuição definida como reconhecimento de padrões armazenados na memória de cada indivíduo de acordo com Simon e Melon (1995). Aspectos como a qualidade das informações disponíveis e capacidade de avaliação e análise de seus decisores, as culturas e estruturas organizacionais, o tempo disponível, bem como a capacidade de lidar com conflitos de interesses, são exemplos que exercem forte influência sobre a tomada de decisão. Em se tratando de seres humanos, a intuição sempre estará presente em alguma parcela, entretanto ela deve ser complementada por um conjunto de análises sistemáticas e abordagens baseadas em evidências.

Com o advento da tecnologia, uma diversidade de ferramentas foi desenvolvida para apoiar a tomada de decisão em diferentes instituições, inclusive nas governamentais, visando a gestão eficiente dos seus processos. Para o controle e a transparência na execução de convênios e na gestão financeira, existem o SICONV (Sistema de Gestão de Convênios e Contratos de Repasse), o qual evoluiu para a plataforma Plataforma +Brasil em 2019, e o SIAFI (Sistema Integrado de Administração Financeira do Governo Federal), da Secretaria do Tesouro Nacional (SIAFI). No âmbito da saúde, utiliza-se o SIOPS (Sistema de Informações sobre Orçamentos Públicos em Saúde), o qual permite o monitoramento dos investimentos em saúde. Já em áreas estratégicas, como pesquisa científica, inovação e planejamento urbano, conta-se com o apoio da Plataforma Lattes, amplamente utilizada pelas instituições de pesquisa e agências de fomento, e do SIG (Sistemas de Informações Geográficas), utilizado pela EMPRAPA (Empresa Brasileira de Pesquisa Agropecuária).

De forma semelhante, a Marinha do Brasil (MB) desenvolveu iniciativas para apoiar a tomada de decisão buscando, primeiramente, otimizar os processos, e em seguida, automatizar e tratar a qualidade das informações por meio de sistemas de software, tais como SISCPO (Sistema da Comissão de Promoção de Oficiais), SISPAG (Sistema de Pagamento) e SIPLAD (Sistema de Acompanhamento do

Plano Diretor). Novas tecnologias surgem e a MB, prezando pela constante evolução, busca incorporá-las à sua realidade. Um exemplo muito recente é o SAD-ORC (Sistema de auxílio à decisão de gestão orçamentária) que permite a análise de decisão multicritério para indicar prioridade entre os projetos orçamentários. Entretanto, existem inúmeras abordagens, o que não esgota novas possibilidades, tão pouco invalida as existentes.

Nessa linha, as ferramentas e iniciativas modernas têm permitido a geração, armazenamento e disponibilidade de um grande volume de dados que representam informações valiosas sobre diferentes áreas das organizações. Isso reflete a tendência observada no mundo globalizado, onde a informação tornou-se um ativo crucial. Não é apenas a informação que importa, mas a interpretação e o valor agregado que essa informação proporciona. O verdadeiro diferencial competitivo é a capacidade de transformar dados brutos em insights estratégicos. No ambiente empresarial, tomar decisões baseadas nas percepções extraídas de dados históricos estimula o pensamento analítico e resulta em ações assertivas. O conhecimento gerado a partir da exploração de dados tem apoiado os tomadores de decisão de organizações de diferentes setores, fortalecendo o conceito de tomada de decisão orientada a dados ou *data-driven decision* (DDD). De forma semelhante, os órgãos públicos têm experimentado os benefícios do conhecimento baseado em exploração de dados, resultando na melhoria da gestão de seus processos internos. Nessa perspectiva, a Mineração de Dados (MD) é considerada uma abordagem promissora capaz de apoiar à tomada de decisão e sobre a qual este estudo se debruça.

No ambiente governamental, a restrição orçamentária é um fator relevante que influencia as decisões nas instituições públicas, tornando desafiadora a escolha de onde e como alocar recursos orçamentários quando necessidades específicas se encontram no mesmo patamar. Por outro lado, a MB possui diretivas de planejamento muito bem definidas e com procedimentos automatizados que, além de permitir o acompanhamento, mantém o histórico das metas orçamentárias planejadas em cada setor da MB. Apesar dessas informações, de certa forma, subsidiarem à tomada de decisão, sua complexidade dificulta o entendimento do decisor.

Nesse contexto, a Mineração de Dados pode ser aplicada para extrair *insights* valiosos a partir desse complexo conjunto de dados históricos. A identificação de

padrões, tendências e correlações ocultas nos dados orçamentários pode fornecer informações valiosas para melhorar a alocação de recursos, identificar áreas de maior deficiência ou oportunidades de melhoria, e até mesmo prever necessidades futuras. Adicionalmente, a transformação de informações complexas em visualizações claras que facilitem a compreensão do decisor é mais uma facilidade que a MD é capaz de proporcionar. Desta forma, o objeto de pesquisa deste estudo são as técnicas de mineração de dados, suas aplicações no contexto da gestão orçamentária dentro do processo de alocação de recursos na MB, limitando-se ao Plano Diretor da Marinha. O objetivo geral é analisar a aplicabilidade das técnicas de mineração de dados para apoiar a tomada de decisão no contexto da alocação de recursos orçamentários do Plano Diretor da Marinha do Brasil. Ao analisar a viabilidade e relevância dessas técnicas, será possível responder se as técnicas de mineração de dados podem ser aplicadas no contexto da alocação de recursos orçamentários do Plano Diretor da Marinha do Brasil, questão central deste estudo.

Inicialmente, a metodologia foi conduzida por uma pesquisa bibliográfica para identificar estudos relevantes e técnicas comuns na gestão orçamentária, fornecendo uma base conceitual sólida. Em seguida, foi realizada uma pesquisa descritiva para detalhar o processo de alocação de recursos no Plano Diretor da MB, destacando desafios específicos. Adicionalmente, uma análise comparativa foi realizada para identificar similaridades entre a gestão orçamentária geral e a da MB, destacando áreas específicas em que a mineração de dados pode ser aplicada. Por fim, foi realizada uma análise descritiva para explorar as contribuições potenciais da mineração de dados para a tomada de decisão na alocação de recursos, enfatizando seus benefícios para a eficiência e eficácia da gestão financeira na MB.

Para a condução deste estudo, apresenta-se, além desta introdução, mais cinco capítulos cujos objetivos estão organizados de forma que cada um corresponda a um capítulo distinto. O segundo capítulo descreve o referencial teórico que fundamenta os conceitos afetos à tomada de decisão, à mineração de dados e à gestão orçamentária. O terceiro capítulo analisa estudos relevantes com aplicação de técnicas de mineração de dados no âmbito do setor financeiro em geral, da gestão orçamentária, bem como suas contribuições. O quarto capítulo descreve o processo de alocação na MB, destacando os principais desafios e as potenciais técnicas para contribuição na alocação de recursos da MB. O quinto capítulo analisa as contribuições e benefícios do uso da Mineração de Dados para a

tomada de decisão na MB. Por último, o sexto capítulo apresenta a conclusão deste estudo.

2 REFERENCIAL TEÓRICO

O presente capítulo fundamenta os conceitos essenciais para a compreensão sobre o processo de tomada de decisão abordando os fatores que influenciam as decisões em contextos organizacionais, destacando a importância da informação precisa e oportuna. Em seguida, conceitua extração de conhecimento orientado à dados, descrevendo os métodos e as técnicas de mineração de dados mais aplicados. Por fim, contextualiza a gestão orçamentária na MB à luz das normas em vigor.

2.1 Tomada de Decisão e Data-Driven Decision Making (DDD)

A tomada de decisão é o processo de escolha exercida por indivíduos ou instituições entre possíveis opções, visando um determinado objetivo (Barnard e Simon, 1947). Segundo Barnard e Simon (1947), esse processo baseia-se no reconhecimento das limitações cognitivas dos tomadores de decisão e na deficiência das informações possíveis de processar, intitulado de racionalidade limitada. Além disso, envolve quatro fases: inteligência (identificação do problema), design (concepção de soluções), escolha (seleção da solução mais adequada) e revisão (avaliação dos resultados obtidos) que são executadas de forma estruturada e cíclica, permitindo adaptação e melhoria constante das decisões.

Diversos fatores influenciam significativamente o processo decisório nas organizações, tais como: a disponibilidade das informações, em que a quantidade e qualidade das informações disponíveis afetam as escolhas substancialmente, o ambiente organizacional, uma vez que as escolhas são moldadas pelas normas, cultura, políticas e procedimentos organizacionais, as preferências individuais, sendo as decisões influenciadas por motivações e prioridades individuais e as pressões temporais, em que a urgência pode afetar a qualidade da escolha (Barnard e Simon, 1947).

Diante da complexidade e limitações envolvidas no processo decisório, prover qualidade nas informações disponíveis ao decisor, baseando-se em dados é uma

tendência crescente em grandes empresas e no setor público. Essa prática, conhecida como "*data-driven decision making*" (DDD), oferece aos decisores uma visão mais clara e detalhada das operações e dos ambientes internos e externos, permitindo decisões mais estratégicas e eficazes, uma vez que baseia as decisões na análise dos dados e não meramente na intuição (Provost e Fawcett, 2013). Essa análise envolve o uso de dados quantitativos e qualitativos para nortear as escolhas organizacionais, de maneira objetiva e sobretudo informada.

2.2 Ciência de Dados e Mineração de Dados

O aumento na geração e disponibilidade de dados, bem como os avanços na tecnologia de ciência de dados, tem promovido a exploração de dados para extrair conhecimento, padrões e *insights* com aplicações em diversos setores, desde negócios e finanças até ciência e tecnologia (Tan, Steinbach e Kumar, 2016). No contexto dos negócios, a análise detalhada dos dados empresariais para identificar padrões, tendências e relações de causa e efeito pode otimizar processos e recursos (Provost e Fawcett, 2013). Assim, apesar de ter surgido na década de 1960, o conceito de Mineração de Dados ganhou popularidade apenas na década de 1990 (Han, Pei e Tong, 2022) e, desde então, tem sido um recurso valioso para apoiar a tomada de decisão, pois tem ajudado a descobrir padrões e relacionamentos entre os dados. Tan, Steinbach e Kumar (2016) o descrevem como o processo de descoberta automática de informações úteis em grandes bases de dados que, para além de permitir a descoberta de novos padrões, fornece recursos para prever o resultado de uma observação futura.

Embora os termos ciência de dados e mineração de dados por vezes sejam tratados como sinônimos, (Provost e Fawcett, 2013) descreve o primeiro como um conjunto de princípios fundamentais que direcionam a extração do conhecimento proveniente de dados e o segundo como a própria extração do conhecimento por intermédio de técnicas que satisfazem esses princípios. Adicionalmente, a ciência de dados tem sido adotada nas diversas esferas por sua capacidade de melhorar a tomada de decisão e, conseqüentemente, por representar vantagem competitiva. Assim, a ciência de dados tem apoiado a tomada de decisão orientada a dados, aplicando-se técnicas de mineração de dados para identificar padrões e tendências ocultas, melhorar a precisão das previsões, otimizar a alocação de recursos,

contribuindo com a DDD para reduzir a influência de vieses pessoais e aumentar a transparência e a responsabilidade no processo decisório.

As tarefas de mineração de dados podem ser categorizadas em dois tipos principais: preditivas e descritivas. As tarefas preditivas envolvem prever o valor de um atributo com base em outros atributos. Em contraste, as tarefas descritivas se concentram em derivar padrões das relações entre os dados, como correlações, tendências, clusters, trajetórias e anomalias (Tan, Steinbach e Kumar, 2016). Adicionalmente, existem alguns autores (Evans, 2013, Sharda Ramesh et al, 2020) que reconhecem as tarefas que buscam prever a melhor solução para um problema específico como prescritivas. Existem diversas tarefas de mineração de dados para atender objetivos distintos (Provost e Fawcett, 2013), dentre as mais utilizadas estão a classificação que prevê a qual classe um indivíduo pertence, estimativa ou regressão que prevê o quanto algo acontecerá, agrupamento ou clusterização que agrupa indivíduos similares, associação que descobre correlações frequentes, previsão que busca um valor numérico futuro, otimização que busca a melhor solução com alguns recursos. Cada tarefa pode ser aplicada por meio de técnicas (algoritmos) de mineração de dados como algoritmos de redes neurais artificiais (RNAs), árvores de decisão, regras de associação, máquinas de vetores de suporte, K-vizinho mais próximos ou *K-Nearest Neighbors* (KNN), *Naive Bayes*, algoritmos de genética, entre outros (Amani e Fadlala, 2017).

Neste trabalho específico, o foco está na mineração de padrões frequentes, associações e correlações. Padrões frequentes são conjuntos de itens que ocorrem frequentemente nos dados, enquanto padrões sequenciais são subsequências de itens frequentes (Han, Pei e Tong, 2022). Regras de associação são usadas para encontrar padrões que correlacionam fortemente atributos com diferentes valores (Witten et al., 2017). Para mensurar tanto a frequência com que um padrão pode ocorrer quanto a força das correlações, utiliza-se medidas como confiança e suporte para avaliar o grau de certeza e a utilidade dessas regras. Suporte é a quantidade de resultados corretamente previstos, enquanto confiança é a quantidade de resultados corretamente previstos entre todos os casos em que uma determinada regra é empregada (Witten et al., 2017). Outra medida importante é o lift, que avalia até que ponto a ocorrência de um conjunto de itens aumenta a ocorrência de outro (Han, Pei e Tong, 2022). Para regras de correlação, a medida de lift é aplicada como um complemento para filtrar associações enganosas entre conjuntos de itens (Han,

Pei e Tong, 2022).

2.3 Gestão Orçamentária

A estrutura do orçamento brasileiro baseia-se em três leis principais: a Lei do Plano Plurianual - PPA, a Lei de Diretrizes Orçamentárias - LDO e a Lei Orçamentária Anual -LOA (Brasil, 1988). O PPA regulamenta as diretrizes, objetivos e metas para as despesas de capital e a despesas afetas aos programas de duração continuada, vigorando por um período de quatro anos, conforme artigo 165, § 1º (Brasil, 1988). A LDO define as metas e prioridades da administração pública federal, em conformidade com o PPA, bem como estabelece as diretrizes de política fiscal que orientarão a elaboração da LOA, de acordo com o artigo 165, § 2º, Brasil, 1988). Já a LOA, prevista no artigo 165, § 5º, prevê a receita e fixa a despesa anual da Administração Pública (Brasil, 1988).

Além dessas leis, outras legislações complementam o arcabouço orçamentário brasileiro, como a Lei nº 4320 de 1964, que institui normas gerais de direito financeiro (Brasil, 1964); a Lei Complementar nº 101 de 2000, conhecida como Lei de Responsabilidade Fiscal (Brasil, 2000); a Lei nº 10.180 de 2001, que organiza os sistemas de planejamento e orçamento federais (Brasil, 2001); e a Lei Complementar nº 200 de 2023, que institui um regime fiscal sustentável (Brasil, 2023a). Essas leis normatizam os ciclos orçamentários, cuja intenção é garantir a execução ordenada e responsável do orçamento ano após ano.

A Emenda Constitucional nº 95/2016, conhecida como a "emenda do teto de gastos", representa uma mudança significativa já que limita o crescimento das despesas primárias à inflação do ano anterior, buscando controlar o aumento das despesas públicas para o ano seguinte (Brasil, 2016). Na prática, o aumento de orçamento acima da inflação para um ministério, acarreta na redução de orçamento de outro ministério (Vellez Bruno, 2024). Esse é mais um exemplo das mudanças frequentes sofridas pela legislação orçamentária brasileira que influencia a forma de distribuição dos recursos no governo federal. No entanto, essa problemática envolve o sistema orçamentário brasileiro e afeta, substancialmente, a capacidade de planejamento do setor público e a possibilidade de executar programas públicos com qualidade (Mendes, 2009). Isso se reflete em todas as esferas do governo, incluindo as Forças Armadas, que, apesar de fazerem parte do orçamento público federal, não

geram receitas para o Estado e precisam equilibrar os gastos militares com os recursos destinados ao Orçamento de Defesa (Do Nascimento, 2021). Como um efeito em cadeia, essa dificuldade também se manifesta no planejamento orçamentário da Marinha do Brasil, materializado pelo Plano Diretor (PD).

O Plano Diretor (PD), instituído pelo Aviso Ministerial nº 1.923 em 25 de setembro de 1963, é um instrumento contínuo de planejamento, execução e controle, essencial para a gestão orçamentária e financeira nos diferentes níveis administrativos. Seu objetivo principal é ajustar os recursos disponíveis às necessidades da Marinha do Brasil (Brasil, 2024a). Seus propósitos são diversos e abrangem várias áreas cruciais da gestão da Marinha do Brasil (MB). Primeiramente, o PD visa contribuir para que a MB cumpra sua missão constitucional, garantindo que todos os recursos e esforços estejam direcionados para aquele objetivo principal. Além disso, o PD busca alinhar os processos e meios com as metas estabelecidas no Plano Estratégico da Marinha (PEM), assegurando que todas as atividades sejam compatíveis com os objetivos estratégicos da organização (Brasil, 2020).

Cabe ressaltar que a sistemática envolvida no PD é automatizada por meio do Sistema de Acompanhamento do Plano Diretor (SIPLAD). O SIPLAD é uma ferramenta destinada a apoiar o planejamento, a execução, o controle, a avaliação e o acompanhamento das atividades relacionadas ao orçamento na MB, por intermédio do registro, armazenamento e gerenciamento dessas informações. O SIPLAD também contribui para a harmonização do Sistema de Planejamento Diretor (SPD) com o Sistema de Planejamento Orçamentário e Financeiro (SPOF) e com o Sistema de Planejamento Estratégico da Marinha (SISPEM).

Em suma, este capítulo aponta, como mais relevante, a importância das decisões baseadas em dados, aumentando suas eficácias e suas objetividades nas organizações; a essencialidade da ciência de dados e da mineração de dados como ferramentas para extrair conhecimento a partir de grandes volumes aplicando técnicas como classificação, *clustering* e regras de associação para melhorar a tomada de decisões, e, por fim, contextualiza a gestão orçamentária na MB.

3 MINERAÇÃO DE DADOS NO SETOR FINANCEIRO

Tendo sido fundamentados os conceitos essenciais para a compreensão sobre o processo de tomada de decisão, este capítulo aborda estudos relevantes com aplicação de técnicas de mineração de dados no âmbito financeiro. Com isso, identifica-se as técnicas comumente empregadas no setor financeiro em geral, na gestão orçamentária e suas contribuições. Nesse sentido, o capítulo responde as seguintes questões:

- Quais as aplicações e contribuições da mineração de dados no setor financeiro?
- Quais contribuições a MD oferece para a gestão orçamentária?


3.1 Aplicações e Contribuições da MD no Setor Financeiro

A mineração de dados tem sido amplamente utilizada no setor financeiro em áreas como pontuação de crédito e negociação, detecção de fraudes e gerenciamento da força de trabalho. Walmart e Amazon, são exemplos de empresas que adotaram a mineração de dados em todos os seus negócios, desde o marketing até o gerenciamento da cadeia de suprimentos (Provost e Fawcett, 2013).

Amani e Fadlala (2017) realizaram uma revisão da literatura em 209 artigos relevantes para identificar as aplicações das técnicas de mineração de dados na contabilidade, destacando os objetivos, áreas de aplicação e técnicas mais comuns, conforme a Figura 1. No que tange aos objetivos, esse estudo identificou que 82% das aplicações focavam na mineração de dados preditiva, 11% na descritiva e 7% na prescritiva. Isso demonstra que grande parte das aplicações está voltada para a previsão, possivelmente pelo valor estratégico que perspectivas futuras agregam à tomada de decisão.

Na Figura 1, fica evidente que entre os domínios de aplicação da contabilidade, a maioria se concentra na garantia e conformidade, representando 65% do total. Em seguida, as aplicações em contabilidade gerencial correspondem a 25%, enquanto as aplicações em contabilidade financeira ficam com 10%. Quanto às técnicas de MD, a classificação, utilizada em 67% das aplicações de mineração de dados na contabilidade, é a mais empregada. A estimativa vem em segundo lugar, representando 11% das aplicações, seguida pelo agrupamento, que corresponde a 6% (Amani e Fadlala, 2017).

Figura 1 – Aplicações de Mineração de Dados em contabilidade por tópico contábil, objetivo e tarefa de MD



Fonte: AMANI E FADLALA (2017)

Segundo Shahana (2023), nos últimos sete anos, 2015 a 2022, houve um crescimento significativo das pesquisas sobre detecção de fraudes em demonstrações financeiras, um dos procedimentos constantes no domínio da garantia e conformidade. A alta representatividade da adoção de MD nesse domínio (65%) revela que a prospecção preditiva, empregada em 92% dos casos, tem melhorado procedimentos de controle interno, detecção de fraudes, compreensão de relatórios de auditoria e conformidade fiscal (Amani e Fadlala, 2017). Adicionalmente, a predominância da classificação (87%) nesse domínio evidencia a importância da discriminação entre classes para se identificar, por exemplo, empresas fraudulentas e empresas não fraudulentas (Shahana, 2023). Nesse contexto, as técnicas de classificação mais adotadas ainda são as Redes Neurais Artificiais (RNAs), as Árvores de Decisão, Máquinas de Vetores de Suporte ou *Support Vector Machines* (SVM), *K-Nearest Neighbors* (KNN) e Floresta Aleatória (*Random Forest*).

A Tabela 1, apresenta as técnicas mais utilizadas segundo Amani e Fadlala (2017), bem como suas aplicações, contribuições, domínio de utilização e tarefa de mineração. No domínio da Contabilidade Gerencial, identifica-se o emprego de algoritmos de clusterização, visando o agrupamento por padrões de desempenho e por áreas que necessitam de melhorias, bem como a adoção de algoritmos de análise de sensibilidade para identificar fatores que influenciam os resultados operacionais. Já no domínio da Contabilidade Financeira, percebe-se o uso de algoritmos de análise de regressão para previsão de receitas e despesas, análise de rentabilidade e desempenho financeiro, além de regras de associação para identificação de padrões desconhecidos para reconhecimento de anomalias ou oportunidades de melhorias. Cabe ressaltar que Redes Neurais Artificiais (RNAs) e Árvores de Decisão são técnicas empregadas nos três domínios da contabilidade (Tabela 1).

Tabela 1 - Técnicas de Mineração de Dados mais aplicadas no Setor Financeiro

Técnica de Mineração de Dados	Aplicação	Contribuição	Domínio de Utilização	Tarefa de Mineração de Dados
Redes Neurais Artificiais (RNAs)	Deteção de fraudes, previsão de receitas e despesas, otimização de recursos.	Melhoram a precisão na detecção de fraudes, previsões financeiras e otimização de recursos.	Contabilidade Financeira, Gerencial, Garantia e Conformidade	Classificação, Regressão
Árvores de Decisão	Classificação de transações, análise de dados financeiros, suporte à tomada de decisões gerenciais.	Facilitam a interpretação e explicação das decisões, identificam fraudes e fatores críticos.	Contabilidade Financeira, Gerencial, Garantia e Conformidade	Classificação
Máquinas de Vetores de Suporte (SVM)	Separação de classes de dados, detecção de fraudes em conjuntos de dados complexos.	Fornecem alta precisão na classificação e detecção de fraudes em dados altamente dimensionais.	Garantia e Conformidade	Classificação
K-Nearest Neighbors (KNN)	Classificação de novas transações com base em proximidade de transações anteriores.	Eficaz na detecção de fraudes em tempo real, comparando novas transações com exemplos históricos.	Garantia e Conformidade	Classificação
Floresta Aleatória (Random Forest)	Combinação de múltiplas árvores de decisão para aumentar a precisão da classificação.	Melhora a precisão e a capacidade de generalização do modelo, menos suscetível ao overfitting.	Garantia e Conformidade	Classificação
Algoritmos de Agrupamento (Clustering)	Segmentação de dados em grupos homogêneos, análise detalhada de segmentos de negócio.	Facilita a identificação de padrões de desempenho e áreas que necessitam de melhorias.	Contabilidade Gerencial	Agrupamento
Regras de Associação	Descoberta de relações entre itens das demonstrações financeiras.	Identificam padrões ocultos que podem indicar anomalias ou oportunidades de melhoria.	Contabilidade Financeira	Associação
Análise de Regressão	Previsão de valores futuros com base em dados históricos.	Útil para previsão de receitas e despesas, análise de rentabilidade e avaliação de desempenho financeiro.	Contabilidade Financeira	Regressão
Análise de Sensibilidade	Avaliação de como diferentes variáveis afetam o desempenho financeiro.	Ajuda a identificar os principais fatores que influenciam os resultados operacionais.	Contabilidade Gerencial	Análise de Sensibilidade

Fonte: AMANI E FADLALA (2017)

3.2 Contribuições na Gestão Orçamentária

A aplicação de técnicas de MD na Gestão Orçamentária, um subdomínio da Contabilidade Gerencial (Amani e Fadlala, 2017), oferece uma nova perspectiva sobre a avaliação de desempenho orçamentário baseada, tradicionalmente, em métodos quantitativos, incapazes de capturar a complexidade dos ambientes financeiros modernos (Liu, 2022). Como existem vários fatores que influenciam a prevenção de riscos financeiros, um dos princípios para a gestão orçamentária estratégica, o emprego das técnicas de MD tem contribuído, significativamente, pois permite a análise de múltiplos fatores e a identificação de tendências ocultas nesse cenário multifacetado (Liu, 2022).

Valle-Cruz, Fernandez-Cortez e Gil-Garcia (2022), propõem uma abordagem híbrida entre algoritmos de RNA e algoritmos genéticos multiobjetivos para encontrar indicadores que podem melhorar as condições de inflação e diminuir as desigualdades no cenário de alocação de despesas públicas. No entanto, não conseguiram encontrar uma solução eficaz devido à complexidade inerente ao problema orçamentário, em que qualquer ajuste na dotação do orçamento público pode afetar os resultados esperados.

Para otimizar a previsão e o planejamento de orçamentos empresariais, M Ye et al (2020) investigam o uso do algoritmo *Apriori*, propondo um modelo que utiliza dados financeiros históricos para identificar padrões e prever orçamentos futuros, aumentando a precisão e eficiência do planejamento orçamentário. Além dos resultados demonstrarem a eficácia do modelo proposto em relação aos métodos tradicionais, ao permitir decisões financeiras mais informadas, ele também automatiza o processo, reduzindo a necessidade de intervenção manual e minimizando erros.

Segundo Liu (2022), gerenciar orçamentos de forma eficaz é uma necessidade das empresas para garantir seu crescimento e sustentabilidade. Assim, ele propõe um método de avaliação abrangente do desempenho orçamentário financeiro empresarial, empregando técnicas de mineração de dados para melhorar a precisão e a eficiência da avaliação. Para isso, foram executados vários algoritmos de MD por meio de um framework, um sistema estruturado para avaliar o desempenho orçamentário financeiro das empresas utilizando técnicas de mineração de dados. As técnicas de agrupamento e da classificação permitiram a

identificação de padrões de alocação orçamentária bem-sucedidos e ineficientes. Três principais categorias de desempenho orçamentário foram reveladas por intermédio do agrupamento: alto desempenho, médio desempenho e baixo desempenho, permitindo que as empresas fossem agrupadas em relação ao quanto elas atingem ou não os seus objetivos. Adicionalmente, a avaliação detalhada do desempenho financeiro forneceu *insights* sobre como as empresas podem melhorar suas práticas orçamentárias.

No geral, as principais contribuições da MD na Gestão Orçamentária conforme os estudos relatados, incluindo Amani e Fadlala (2017) envolvem:

- **Previsão Orçamentária:** permitindo melhor planejamento dos recursos e das despesas futuras, por meio de previsões mais precisas;
- **Identificação de Padrões de despesas e receitas:** permitindo a identificação de padrões em dados financeiros capazes de influenciar decisões orçamentárias futuras, por meio de algoritmos de redes neurais e árvores de decisão;
- **Análise de Desempenho:** permitindo o reconhecimento de áreas de ineficiência e potencial para economias, visando uma análise mais detalhada do desempenho orçamentário;
- **Otimização de Custos:** minimizando custos e maximizando a eficiência operacional por meio do emprego de algoritmos genéticos e SVM.

Quanto às técnicas empregadas nesse subdomínio, permanecem as mesmas empregadas no setor financeiro em geral, principalmente as relacionadas às tarefas de classificação. Isso demonstra uma tendência nas informações financeiras que favorece a classificação binária: fraude/ sem fraude, falência/sem falência. Entretanto, há outras técnicas que oferecem potencial para contribuir no âmbito financeiro, mas ainda pouco exploradas, tais como as regras de associação de acordo com Amani e Fadlala (2017).

Esse capítulo conclui que, quanto às aplicações e contribuições da MD no setor financeiro, destaca-se seu uso em áreas como pontuação de crédito, detecção de fraudes e gestão orçamentária; que a literatura relata a predominância de técnicas preditivas, com ênfase na classificação, especialmente em contabilidade, onde Redes Neurais Artificiais (RNAs) e Árvores de Decisão são amplamente usadas para garantir conformidade e otimizar recursos; e que, na gestão orçamentária, a MD oferece avanços significativos, como previsões orçamentárias

mais precisas, identificação de padrões de despesas e receitas, análise de desempenho e otimização de custos. Constata-se ainda, que técnicas como algoritmos genéticos, *Apriori*, e frameworks de MD foram aplicadas para melhorar a eficiência e a precisão na alocação orçamentária, destacando o potencial da MD em suportar decisões financeiras mais informadas e eficazes

4 A ALOCAÇÃO ORÇAMENTÁRIA NA MB, OS DESAFIOS E AS POTENCIALIDADES DA MD

Em face de uma compreensão mais ampla das aplicações e contribuições da Mineração de Dados no setor financeiro em geral e na gestão orçamentária, o presente capítulo discute o processo de alocação orçamentária no Plano Diretor da MB, evidenciando os desafios enfrentados para distribuí-los entre os diversos órgãos envolvidos. Também reconhece em que pontos desse processo a MD representa uma ferramenta em potencial. Diante disso, responde-se às seguintes questões:

- Em que medida é realizada a alocação orçamentária no Plano Diretor da MB?
- Quais são os desafios para realizar a alocação orçamentária na MB?
- Em que pontos da alocação de recursos da MB as técnicas de mineração identificadas podem ser aplicadas?

4.1 O processo de alocação orçamentária no Plano Diretor da MB

O processo de alocação orçamentária no Plano Diretor da MB necessita adaptar-se ao contexto de restrições fiscais e assegurar que as prioridades estratégicas sejam atendidas de forma eficaz e continuada. Para isso, está estruturado em três ciclos distintos: Planejamento, Execução e Controle (Brasil, 2024a).

O ciclo de Planejamento resulta na montagem do Plano de Ação (PA), em que são coletadas as demandas orçamentárias dos diversos setores da MB, as quais são apresentadas ao Conselho do Plano Diretor (COPLAN). Nesse conselho, a Alta Administração Naval delibera, prioriza e adequa as necessidades da Força a um espaço orçamentário que se torna mais restrito a cada ano. Geralmente, isso ocorre de janeiro até a finalização do PA, após a 3ª Reunião do COPLAN, em cumprimento

ao Calendário de Trabalho do Plano Diretor (CTPD). Sempre que julgar necessário, o Gabinete do Comandante da Marinha (GCM) coordena uma Reunião de Diretrizes com os Órgãos de Direção Setorial (ODS), o Centro de Comunicação Social da Marinha (CCSM) e a Secretaria da Comissão Interministerial para os Recursos do Mar (SECIRM), visando orientar o envio e a coleta de subsídios necessários ao planejamento. Em seguida, os ODS, SECIRM e CCSM realizam as Reuniões de Priorização para apresentar os critérios empregados para priorizar as metas orçamentárias contempladas em cada cenário, as metas relevantes que não puderam ser atendidas, bem como as dificuldades encontradas durante a montagem do PA. O foco dessas reuniões são as metas que possam ser concluídas no ano corrente. Cabe ressaltar que diversos colegiados consultivos na MB influenciam o processo orçamentário, especialmente no que tange a decisões de dispêndio plurianual. Todas essas decisões devem ser submetidas ao COPLAN para avaliação de viabilidade orçamentária antes de serem aprovadas. (Brasil, 2024a, Brasil, 2024b).

O ciclo de Execução tem foco na execução físico-financeira das ações internas (AI) que receberam dotações de crédito no exercício corrente. Ele se inicia após a aprovação da Lei Orçamentária Anual – LOA (Brasil, 2023b, Brasil, 2023c) pelo Congresso Nacional e sua sanção pelo Presidente da República. Após isso, edita-se o Decreto de Programação Orçamentária e Financeira para a montagem final do PA a ser executado. Prontamente, a DGOM realiza o provisionamento dos créditos autorizados, possibilitando que as Unidades Gestoras (UG) comecem a executar as AI contempladas com recursos, sem necessidade de novas autorizações. Se porventura a LOA ou o Decreto de Programação Orçamentária e Financeira não forem aprovados no prazo regulamentar, a liberação fracionada de recursos pode ser autorizada, desde que prevista na Lei de Diretrizes Orçamentárias (LDO). Esse procedimento visa garantir que as UG disponham de um mínimo de crédito para executar suas despesas básicas enquanto aguardam a publicação definitiva da LOA e do Decreto, e a consequente liberação integral do Plano de Ação (PA). Durante a execução, podem surgir imprevistos que impossibilitem a execução físico-financeira conforme planejado. Nesses casos, o SPD permite ajustes no PA por intermédio do instrumento ALTICRED, solicitado pelas UG ou por outros gestores responsáveis, a fim de garantir que os objetivos planejados sejam atingidos, ou,

quando necessário, modificados para se adaptar às novas circunstâncias (Brasil, 2024a).

O Ciclo de Controle envolve atividades destinadas a monitorar a execução das metas da MB, permitindo a correção de desvios em tempo hábil para otimizar o uso dos recursos ao longo do ano. Esse controle é realizado em diferentes níveis hierárquicos considerando a estrutura do SPD, começando com os Gerentes de Meta, que acompanham as ações internas (AI) sob sua responsabilidade. Eles podem ser auxiliados por Gerentes Adjuntos e, no nível setorial, pelos Órgãos de Direção Setorial (ODS), que também supervisionam o cumprimento das metas. O acompanhamento físico-financeiro é essencial para identificar discrepâncias entre o planejado e o executado, podendo ser realizado sob duas óticas: financeira, que analisa valores monetários, e física, que verifica os resultados obtidos com a execução das AI. As ações pertencentes a agregadores importantes, como "Metas Prioritárias da Marinha" e "Programas Especiais" (Brasil, 2020), são monitoradas no Sistema Integrado de Planejamento e Administração (SIPLAD), em que são inseridos relatórios trimestrais pelos Gerentes de Meta, com dados sobre a execução prevista e realizada. No mais alto nível de controle, o Conselho Financeiro e Administrativo da Marinha (COFAMAR) avalia trimestralmente a execução físico-financeira das AI e emite pareceres críticos com base nas informações fornecidas pelos Gerentes de Meta e ODS. Esses pareceres ajudam a identificar possíveis anormalidades e a planejar reprogramações ou outras medidas corretivas necessárias. O processo culmina com uma análise abrangente da execução das ações, permitindo ajustes que garantam a eficiência e eficácia na administração financeira da MB (Brasil, 2024a).

O planejamento, execução e controle são ciclos distintos, porém interrelacionados no processo de gestão. O Ciclo de Planejamento define as metas e aloca os recursos necessários para o exercício financeiro, estabelecendo um Plano de Ação (PA) detalhado. O Ciclo de Execução envolve a aplicação físico-financeira das ações planejadas, com ajustes possíveis durante o processo para garantir a realização das metas. O Ciclo de Controle, por sua vez, monitora a execução em relação ao planejamento, identificando desvios e permitindo ações corretivas para otimizar o uso dos recursos. Embora separados, esses ciclos trabalham em conjunto para garantir a eficácia na gestão dos recursos e a consecução das metas estabelecidas.

4.2 Os desafios da alocação orçamentária no Plano Diretor da MB

Nos últimos anos, a regular escassez de recursos orçamentários tem afetado negativamente o pleno atendimento das metas subsidiadas pelos setores, exigindo a criteriosa priorização das demandas orçamentárias para adequar o processo de alocação de recursos à realidade da MB, em atendimento às principais metas dos ODS (Brasil, 2024a). Nesse sentido, o processo de alocação orçamentária na MB enfrenta vários desafios, incluindo:

- **Restrições Orçamentárias e Contingenciamento:** O principal desafio é a limitação de recursos financeiros, que exige cortes e contingenciamentos ao longo da execução da Lei Orçamentária Anual (LOA). Isso pode resultar na insuficiência de recursos para metas discricionárias, dificultando o cumprimento de todas as demandas.
- **Priorização das Metas:** A necessidade de priorizar metas dentro de um orçamento restrito é um desafio complexo. Os ODS precisam identificar quais demandas são mais críticas, o que pode gerar conflitos internos sobre a alocação de recursos, especialmente quando todas as metas são consideradas importantes para a operação da Força.
- **Coleta e Qualidade de Dados:** O processo de coleta de informações e subsídios dos diversos órgãos e unidades da MB depende da precisão e qualidade desses dados. Qualquer falha ou falta de clareza nas informações pode comprometer a tomada de decisões e a distribuição eficaz dos recursos.
- **Coordenação entre Órgãos:** A necessidade de coordenação eficiente entre o Órgão de Direção Geral (ODG), os Órgãos de Direção Setorial (ODS) e outros setores da MB, para garantir que as decisões e priorizações estejam alinhadas, é um desafio contínuo. A falta de alinhamento pode levar a decisões subótimas ou a um uso ineficaz dos recursos.
- **Impacto de Decisões Plurianuais:** Decisões que envolvem compromissos financeiros de longo prazo precisam ser cuidadosamente avaliadas para garantir que não comprometam a viabilidade financeira em exercícios futuros. O impacto de decisões plurianuais é difícil de prever, o que pode levar a riscos orçamentários.

- **Adaptação às Mudanças Econômicas:** A conjuntura econômica adversa pode exigir ajustes constantes no planejamento e na alocação de recursos, o que exige flexibilidade e capacidade de resposta rápida por parte da MB.

Os desafios citados requerem uma gestão cuidadosa e uma abordagem estratégica para garantir que a Força continue operando de maneira eficaz dentro dos limites orçamentários impostos. A próxima seção aborda como a Mineração de Dados é capaz superar tais desafios.

4.3 As potencialidades da Mineração de Dados para a alocação orçamentária da MB

No setor público, as técnicas de mineração de dados (MD) também têm sido aplicadas como ferramentas indispensáveis para dar suporte em diferentes áreas. Na auditoria e fiscalização governamental, elas têm contribuído na detecção de falhas no emprego dos recursos públicos (Silva, Santos e Teles, 2010). Na execução orçamentária e financeira das despesas públicas, elas têm subsidiado o processo de planejamento ao enquadrar um maior volume de empenhos dentro dos principais objetos (Nogueira et al, 2022). Na alocação das despesas públicas, elas têm permitido uma análise comparativa da eficiência na distribuição alocativa das despesas (Davis, 2019).

Na alocação orçamentária na Marinha do Brasil, as técnicas de MD também representam potencialidades para contribuir no enfrentamento dos desafios impostos pelos agravamentos dos cortes e contingenciamentos. Dentre os potenciais contribuições, ressaltam-se as seguintes:

- **Melhoria na Qualidade e Precisão dos Dados:** Algoritmos de estimativa ou previsão, como o *K-Nearest Neighbors* (KNN), para preenchimento de valores ausentes, e algoritmos de detecção de anomalias, como *Isolation Forest*, para identificar anomalias ou outliers em um conjunto de dados, podem ser usados para identificar e corrigir inconsistências nos dados coletados das diferentes unidades e órgãos da MB, superando os desafios na coleta e qualidade dos dados ao garantir informações precisas para subsidiar os tomadores de decisão. Ao melhorar a qualidade e a precisão das informações, assegura-se que as decisões orçamentárias sejam

baseadas em dados confiáveis e relevantes, reduzindo o risco de alocação inadequada de recursos.

- **Apoio na Priorização de Metas:** Com a Mineração de Dados, como apresentado no Capítulo 2, é possível analisar grandes volumes de dados históricos para identificar quais metas têm o maior impacto em termos de desempenho e cumprimento das missões da MB. Algoritmos de agrupamento ou clusterização, como *K-Means* ou *DBSCAN* que agrupam dados não rotulados em clusters (ou grupos) com base em características semelhantes, podem ser aplicados para agrupar metas similares, facilitando a identificação de prioridades. Além deles, algoritmos de classificação, como Árvore de Decisão e *Random Forest* que classificam dados em diferentes categorias ou classes, podem ser empregados para classificar metas com base em critérios como impacto estratégico, urgência, retorno sobre o investimento, ou outros parâmetros que refletem as prioridades da MB. Dessa forma, é possível simplificar a tomada de decisão em relação à priorização de metas na alocação de recursos em um ambiente de restrição fiscal.
- **Previsão de Cenários Futuros:** A análise preditiva, uma técnica de mineração de dados, pode ser utilizada para prever cenários econômicos futuros e seus possíveis impactos no orçamento. Essa capacidade de antecipação ajuda a planejar contingências e ajustar alocações de recursos com maior antecedência e precisão para adaptar-se às mudanças econômicas. Modelos de regressão linear ou regressão logística podem ser aplicados para prever tendências com base em dados históricos. Redes neurais e *Support Vector Machines* (SVM) são algoritmos que podem ser adaptados para tarefas de regressão ou previsão pois são muito eficazes em prever resultados numéricos. Eles são úteis para modelagem preditiva em cenários complexos e podem ajudar a prever o comportamento de variáveis econômicas ou orçamentárias, auxiliando no planejamento preventivo e na antecipação de ajustes orçamentários.
- **Identificação de Ineficiências e Redução de Custos:** Por intermédio da análise de dados operacionais e financeiros, a MD pode revelar áreas em que os recursos estão sendo subutilizados ou desperdiçados. Essa

identificação permite a redistribuição eficiente de recursos, contribuindo para uma utilização mais racional e econômica do orçamento disponível. Algoritmos de regras de associação, como *Apriori* ou *Eclat* que identificam padrões frequentes em conjuntos de dados, podem ser utilizados para identificar padrões recorrentes de consumo e alocação de recursos que não são imediatamente evidentes, revelando ineficiências, como gastos repetitivos ou padrões de alocação inadequada, sugerindo onde cortes ou ajustes podem ser feitos para aumentar a eficiência na utilização dos recursos.

- **Facilitação da Coordenação entre Órgãos:** Os algoritmos de classificação, como *Naive Bayes* e *Support Vector Machine* (SVM) que também transformam e organizam grandes volumes de informações textuais, podem ser aplicados para analisar relatórios e comunicações, identificando temas comuns e ajudando a melhorar a coordenação entre diferentes setores. Assim, é possível identificar pontos de convergência e divergência entre diferentes órgãos da MB, facilitando uma melhor coordenação e alinhamento entre as partes envolvidas no processo de planejamento orçamentário. Isso ajuda a garantir que as decisões sejam mais coesas e alinhadas com os objetivos gerais da organização.
- **Monitoramento e Ajuste Contínuo:** Algoritmos de padrões sequenciais, como *PrefixSpan* que descobre padrões frequentes numa sequência de eventos, podem ser aplicados no acompanhamento de eventos financeiros ou operacionais ao longo do tempo. No cenário da gestão orçamentária, o monitoramento contínuo das execuções orçamentárias tem muita utilidade, já que podem revelar sequências de eventos que indicam necessidade de ajustes ou adaptação às mudanças econômicas.
- **Apoio na Avaliação de Decisões Plurianuais:** Tarefas de regressão ou estimativa podem ser utilizadas para prever o impacto de decisões orçamentárias de longo prazo, auxiliando a MB a mitigar riscos associados a compromissos plurianuais a partir de uma análise baseada em dados históricos e tendências. Como a técnica de Regressão Linear Múltipla modela a relação entre uma variável dependente e múltiplas variáveis independentes, pode ser aplicada para identificar como diferentes fatores influenciam o resultado orçamentário. Já as Árvores de Decisão que

produzem previsões ou estimativas próximas dos valores reais, podem ser usadas para estimar o impacto de diferentes decisões orçamentárias com base em condições específicas e características dos dados históricos.

Portanto, ficam assim explicitadas algumas das potencialidades da Mineração de Dados para aperfeiçoar o processo de alocação orçamentária da MB de forma eficiente e proativa, auxiliando a mitigar os desafios associados às restrições fiscais, à priorização de metas e à coordenação entre diferentes órgãos.

Ao encerrar este capítulo, ficam patentes que, no processo de alocação orçamentária da MB, há sérios desafios enfrentados, como restrições financeiras, a necessidade de priorização de metas, a coleta e a qualidade dos dados, e a coordenação entre os diversos órgãos envolvidos. Entretanto, a MD pode ser uma ferramenta valiosa para amenizar esses desafios, melhorando a precisão das informações, apoiando a priorização de metas, prevendo cenários futuros, identificando ineficiências, e facilitando a coordenação entre as partes envolvidas, resultando em uma alocação mais eficaz e estratégica dos recursos orçamentários. Essas conclusões ficam provadas com os exemplos de recursos tecnológicos já existentes e citados no presente capítulo.

5 MINERAÇÃO DE DADOS E SUA CONTRIBUIÇÃO PARA A TOMADA DE DECISÃO QUANTO À ALOCAÇÃO DE RECURSOS NA MB

Tendo em consideração os desafios da alocação de recursos na MB e as potencialidades da Mineração de Dados para superá-los, o capítulo corrente analisa as possíveis contribuições ao se aplicar a mineração de dados no escopo do Plano Diretor, destacando seus benefícios para a tomada de decisão na MB, em resposta à seguinte questão:

- Quais as contribuições dessas técnicas em potencial para apoiar a tomada de decisão no contexto da alocação de recursos na MB?


5.1 Mineração de Dados aplicada ao Plano Diretor

O Plano Diretor da MB, conforme mencionado no item 2.3, regulamenta todo o processo de planejamento, execução e controle da gestão orçamentária e financeira nos diversos níveis administrativos, no intuito de ajustar os recursos

disponíveis às necessidades da Força (Brasil, 2024a). Para apoiar todo esse processo, o PD conta com o SIPLAD, ferramenta que provê o registro, armazenamento e gerenciamento das informações geradas durante o acompanhamento das atividades da gestão orçamentária. Nesse sentido, o escopo deste estudo são os dados históricos do Plano Diretor da MB, referentes às ações internas planejadas e realizadas, numa janela temporal de um ano, gerados no ano de 2023. Para facilitar o entendimento das análises das possíveis contribuições da MD foi utilizada uma amostra de 10% (47 registros) desse escopo.

A Figura 2 sintetiza a distribuição de uma pequena amostra aleatória das ações internas (AI) cujos recursos financeiros foram planejados e realizados no ano de 2023, em quatro grupos: Planejado = Realizado (*Plan. = Realiz.*), Planejado > Realizado (*Plan. > Realiz.*), Planejado < Realizado (*Plan. < Realiz.*) e Não realizado. O primeiro grupo, *Plan. = Realiz.*, apresenta apenas uma AI com recurso planejado em conformidade com o realizado. O segundo grupo, *Plan. > Realiz.*, demonstra que 29 ações internas com recurso planejado acima do que foi, efetivamente, realizado. O terceiro grupo, *Plan. < Realiz.*, representa as AI com recurso planejado abaixo do que foi realizado, ou seja, o planejamento dessas AI foi subestimado. Por último, o grupo *Não Realizado*, envolve as ações internas que tiveram recurso planejado, mas não foi executado. Observa-se então, que há uma grande disparidade entre o que se planeja e o que se executa, pelos diversos motivos já mencionados, como contingenciamentos, questões políticas, entre outros.

Figura 2- Amostra de distribuição das Ações Internas Planejadas X Realizadas em 2023



Para um especialista em MD, é de fácil percepção a geração de regras de associação a partir deste escopo, aplicando-se o algoritmo *Apriori*, com *suporte* mínimo de 2%, a fim de extrair as correlações presentes a partir de 8 ocorrências, e *confiança* acima de 70%. Nessa linha, a Tabela 2 mostra, como resultado, 10 regras de associação encontradas em 29 ocorrências e com *confiança* de 100% (*confiança* = 1.00), indicando que todas são 100% precisas dentro do conjunto de dados. Entretanto, a Regra 6 se destaca com a correlação mais forte por apresentar o maior *lift* (1.38), indicando que a consequência é 38% mais provável de ocorrer quando o antecedente (*Plan. > Realiz*) acontece. Enquanto a *confiança* mede o grau de certeza do consequente ocorrer quando o antecedente ocorre, o *lift* mede a importância da regra em comparação com a ocorrência aleatória do consequente, ou seja, quanto maior o *lift*, mais forte é a associação.

Tabela 2 – Regras de Associação geradas pelo algoritmo *Apriori*

Regra	Antecedente (A)	Consequente (B)	Suporte A -> B	Confiança	Lift
1	Plan > Realiz	Plan = Realiz	29	1.00	1.02
2	Plan > Realiz	Plan < Realiz	29	1.00	1.34
3	Plan > Realiz	Não realizado	29	1.00	1.12
4	Plan > Realiz & Plan < Realiz	Plan = Realiz	29	1.00	1.02
5	Plan = Realiz & Plan > Realiz	Plan < Realiz	29	1.00	1.34
6	Plan > Realiz	Plan = Realiz & Plan < Realiz	29	1.00	1.38
7	Plan > Realiz & Não realizado	Plan = Realiz	29	1.00	1.02
8	Plan = Realiz & Plan > Realiz	Não realizado	29	1.00	1.12
9	Plan > Realiz	Plan = Realiz & Não realizado	29	1.00	1.15
10	Plan > Realiz & Não realizado	Plan < Realiz	29	1.00	1.34

Portanto, a Regra 6, *Plan.>Realiz => Plan.=Realiz & Plan.<Realiz*, indica que todas as vezes que o antecedente *Plan.>Realiz* ocorre, o consequente *Plan.=Realiz & Plan.<Realiz* também ocorre. Isso significa que para as 29 ocorrências em que o recurso planejado foi maior do que o realizado (*Plan. > Realiz.*), a superestimação no planejamento geralmente leva à situação em que o recurso planejado nunca foi igual ao realizado (*Plan.=Realiz*), resultando, frequentemente, numa situação em que o planejamento foi menor do que o realizado (*Plan < Realiz*). Isso indica que a superestimação no planejamento tende a ser compensada por um planejamento que acaba por ser menor do que o realizado, destacando uma influência no planejamento subsequente em função de um planejamento desequilibrado num ciclo anterior.

A tendência identificada reflete um dos muitos padrões ocultos entre variáveis relacionadas ao planejamento e à execução dos recursos financeiros em ações internas (AI) que as tarefas de associação são capazes de oferecer. Além disso, a aplicação dessas tarefas a um conjunto de dados com mais atributos como tipos de AI, setores responsáveis e período, permitiriam identificar padrões frequentes entre características das AI que apresentam diferenças significativas entre o que foi planejado e o que foi realizado.

5.2 A Mineração de Dados e suas contribuições no processo decisório

Como visto, a Mineração de Dados possui potencial para fornecer valiosas contribuições para a tomada de decisão no contexto da alocação de recursos da MB, permitindo a descoberta de padrões, tendências e previsões que podem orientar os decisores de maneira informada e assertiva. Em cenários complexos e com grandes volumes de dados, como o planejamento de recursos na MB, a MD pode oferecer relevantes contribuições para ajustar o planejamento com base em dados históricos e padrões previsíveis, conforme a seguir:

- **Identificação de Padrões Relevantes:** A MD ajuda a encontrar padrões escondidos nos dados históricos, como a relação entre o planejamento e a execução de ações internas, revelando padrões de alocação de recursos que se repetem, como determinadas ações internas, frequentemente, superestimadas ou subestimadas, demonstrando onde o planejamento pode ser ajustado.
- **Otimização do Planejamento:** Ao identificar correlações baseadas em características comuns em AI semelhantes, é possível prever a probabilidade de uma AI ser sub ou superestimada e estimar como os recursos podem ser alocados no futuro, ajudando a antecipar necessidades e ajustar o planejamento. Assim, a MD possibilita melhorar a alocação de recursos, ajustando o planejamento de maneira mais realista e alinhada com as capacidades e necessidades da organização.
- **Identificação de Ações de Risco:** Estratégias de mitigação de riscos no planejamento podem ser criadas a partir de associações sobre discrepâncias na execução, já que permitem compreender quais fatores externos, como contingenciamentos ou questões políticas, estão

impactando a eficácia do planejamento. Além disso, regras que mostram discrepâncias significativas entre o planejado e o realizado podem indicar problemas no processo de alocação ou execução, permitindo que ações corretivas sejam tomadas.

- **Priorização das Ações Internas:** Baseando-se nos padrões e previsões de subexecução ou superexecução recorrentes descobertos, a MD permite priorizar quais ações internas requerem mais atenção ou ajustes. Assim, é possível focar nos pontos críticos que mais impactam o sucesso da execução das ações, além de promover a melhoria contínua na alocação e execução de recursos.
- **Melhoria da Comunicação e Justificação:** A visualização dos padrões identificados promove melhor comunicação das necessidades e mudanças propostas, facilitando o entendimento entre diferentes partes envolvidas. Ademais, fornece uma base objetiva para justificar decisões de alocação de recursos e mudanças no planejamento, subsidiando discussões com stakeholders e relatórios de desempenho.

Tais contribuições representam benefícios substanciais para a tomada de decisão no contexto da alocação de recursos ao permitir que gestores identifiquem padrões ocultos, façam previsões mais precisas e agrupem ações com características semelhantes, otimizando o uso de recursos. Com as técnicas como regras de associação, classificação, clusterização e padrões sequenciais, é possível ajustar o planejamento, priorizar intervenções e antecipar problemas, baseando as decisões em dados concretos. Isso resulta em uma maior eficiência, redução de erros e respostas mais rápidas a mudanças, garantindo uma alocação de recursos mais eficaz e alinhada às necessidades da organização, que é o farol desta pesquisa.

Concluindo este capítulo, observa-se que as contribuições exemplificadas e evidenciadas são algumas das muitas possibilidades que a mineração de dados pode oferecer à tomada de decisão no contexto da alocação de recursos, identificando padrões e ações de risco, otimizando o planejamento, priorizando ações e facilitando a comunicação e decisões justificadas. As diferentes técnicas mencionadas proporcionam maneiras distintas e complementares de alcançar esses benefícios, tornando o processo decisório mais baseado em evidências e melhor

orientado para o sucesso. Cada técnica traz uma abordagem única que, ao ser aplicada em conjunto, pode aumentar a eficácia na gestão e alocação de recursos.

6 CONCLUSÃO

A análise desenvolvida ao longo deste estudo demonstra as potencialidades da Mineração de Dados (MD) na tomada de decisões orçamentárias, em especial dentro do contexto governamental. A restrição orçamentária, uma constante nas instituições públicas, torna o processo de alocação de recursos um desafio crítico. No caso da Marinha do Brasil (MB), a complexidade dos dados e a multiplicidade de setores envolvidos requerem ferramentas avançadas que auxiliem na racionalização das decisões. A mineração de dados surge como uma solução poderosa para enfrentar essas dificuldades, ao extrair conhecimento e *insights* valiosos oriundos de dados históricos.

Ficou bem caracterizado que as técnicas de MD, como a classificação, clusterização, estimativa, regras de associação, entre outras, oferecem meios inovadores para identificar padrões ocultos, prever cenários futuros e otimizar a alocação de recursos. Sua aplicação no processo de gestão orçamentária da MB não apenas melhora a precisão nas previsões, mas também proporciona uma compreensão mais clara dos dados, facilitando a priorização de metas e a identificação de áreas críticas. Além disso, ao transformar dados complexos em visualizações claras e acessíveis, a MD facilita o entendimento e a comunicação dos resultados, um aspecto fundamental em ambientes de decisão complexos.

A integração da MD no processo de alocação de recursos da MB possibilita a criação de uma base de dados rica e informada que suporta decisões mais estratégicas e alinhadas com as diretrizes estabelecidas no Plano Diretor da Marinha (PD). A automação do processo, por intermédio do Sistema de Acompanhamento do Plano Diretor (SIPLAD), já proporciona avanços significativos, mas a incorporação de técnicas de MD, como explicitada nesta pesquisa, amplia ainda mais essa capacidade, fornecendo um suporte preditivo e analítico que ajuda a superar as limitações da racionalidade humana.

Além disso, este estudo destaca como a MD pode atuar na otimização de custos, detectando ineficiências e melhorando o desempenho orçamentário ao longo do tempo. O uso de algoritmos preditivos, como as Redes Neurais Artificiais e

Árvores de Decisão, revela um potencial promissor para melhorar a precisão das previsões financeiras e garantir conformidade com as diretrizes orçamentárias. Esses avanços já são evidenciados em áreas como a pontuação de crédito e a detecção de fraudes, mas sua expansão para a gestão orçamentária na MB também oferece perspectivas promissoras.

Em meio aos benefícios citados, demonstrou-se que a MD também contribui para a coordenação entre diferentes setores e órgãos, facilitando a comunicação entre as partes envolvidas no processo orçamentário. Ao fornecer dados objetivos e análises detalhadas, a MD pode minimizar conflitos de interesses e aumentar a transparência das decisões, o que é fundamental para o bom funcionamento das instituições públicas. A priorização de metas baseada em evidências, associada à previsão de cenários futuros, torna o processo decisório mais robusto e preparado para enfrentar as incertezas do ambiente financeiro.

Em suma, o estudo reafirma que a Mineração de Dados tem o potencial de transformar o processo de alocação de recursos na Marinha do Brasil, tornando-o mais eficiente, estratégico e alinhado com as demandas futuras. Ao fornecer uma visão clara e detalhada dos dados, a MD se posiciona como uma ferramenta promissora para apoiar decisões complexas, facilitando a comunicação, a justificativa das escolhas e a gestão eficaz dos recursos. As técnicas de MD não apenas podem otimizar o processo orçamentário, mas também podem contribuir significativamente para a modernização e automação da administração pública, promovendo uma governança mais inteligente e adaptativa.

Destarte, pelas conclusões apresentadas, a questão central da pesquisa houve-se por respondida em virtude da viabilidade e relevância das técnicas de Mineração de Dados e, principalmente, pela sua aplicabilidade no contexto da alocação de recursos orçamentários do Plano Diretor da Marinha do Brasil, assim como plenamente cumprido o objetivo geral da pesquisa de analisar a aplicabilidade das técnicas de mineração de dados para apoiar a tomada de decisão no contexto da alocação de recursos orçamentários do Plano Diretor da Marinha do Brasil.

REFERÊNCIAS

AMANI, FA, FADLALLA, AM. **Data mining applications in accounting: A review of the literature and organizing framework.** International Journal of Accounting Information Systems. 2017. 32-58. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1467089515300488>. Acesso em: 14 de jun 2024.

BARNARD, C, SIMON, HA. **Administrative behavior. A study of decision-making processes in administrative organization.** New York: Free Press. 1947. Disponível em: https://www.academia.edu/34589107/ADMINISTRATIVE_BEHAVIOR_A_Study_of_Decision_Making_Processes_in_Administrative_Organization. Acesso em: 24 mar 2024.

BRASIL(1964). **Lei nº 4.320, de 17 de março de 1964:** Estatui Normas Gerais de Direito Financeiro para elaboração e controle dos orçamentos e balanços da União, dos Estados, dos Municípios e do DF. Diário Oficial da União. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/l4320.htm. Acesso em: 26 mai 2024.

BRASIL (1988). **Constituição da República Federativa do Brasil.** Organizado por Cláudio Brandão de Oliveira. Rio de Janeiro, RJ: Roma Victor, 2002. Disponível em: https://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm. Acesso em: 26 mai 2024.

BRASIL (2000). **Lei Complementar nº 101, de 4 de maio de 2000:** Estabelece normas de finanças públicas voltadas para a responsabilidade na gestão fiscal e dá outras providências(Lei de Responsabilidade Fiscal). Disponível em: https://www.planalto.gov.br/ccivil_03/leis/lcp/lcp101.htm. Acesso em: 26 mai 2024.

BRASIL(2001). **Lei nº 10.180, de 17 de março de 1964:** Organiza e disciplina os Sistemas de Planejamento e de Orçamento Federal, de Administração Financeira Federal, de Contabilidade Federal e de Controle Interno do Poder Executivo Federal, e dá outras providências. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/leis_2001/l10180.htm?origin=instituicao. Acesso em: 26 mai 2024.

BRASIL(2016). **Emenda Constitucional nº 95, de 15 de dezembro de 2016, de 17 de março de 1964:** Altera o Ato das Disposições Constitucionais Transitórias, para instituir o Novo Regime Fiscal, e dá outras providências. Disponível em: https://www.planalto.gov.br/ccivil_03/constituicao/emendas/emc/emc95.htm?ref=correiosabia.com.br. Acesso em: 26 mai 2024.

BRASIL (2020). Marinha do Brasil. **Plano Estratégico da Marinha – PEM 2040.** Brasília, DF: Estado-Maior da Armada, 2020. Disponível em: <https://www.marinha.mil.br/pem2040> . Acesso em: 10 mai 2024.

BRASIL(2023a). **Lei Complementar nº 200, de 30 de agosto de 2023**. Institui regime fiscal sustentável para garantir a estabilidade macroeconômica do País e criar as condições adequadas ao crescimento socioeconômico. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/lcp/Lcp200.htm Acesso em: 10 mai 2024.

BRASIL(2023b). Ministério do Planejamento e Orçamento. Secretaria de Orçamento Federal. **Orçamento cidadão: apresentação do projeto de lei orçamentária anual de 2024**. Disponível em: https://www.camara.leg.br/internet/comissao/index/mista/orca/orcamento/OR2024/proposta/Orcamento_cidadao.pdf Acesso em: 10 mai 2024.

BRASIL (2023c). **Lei nº 14.791, de 29 de dezembro de 2023**. Dispõe sobre as diretrizes para a elaboração e a execução da Lei Orçamentária de 2024 e dá outras providências. Diário Oficial da União. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2023-2026/2023/lei/L14791.htm Acesso em: 10 mai 2024.

BRASIL (2024a). Secretaria Geral da Marinha. **SGM-401: Normas para a Gestão do Plano Diretor**. 3ª Revisão, Brasília, DF, 2024. Disponível em: <https://www.sgm.mb/PUB/Normas/SGM-401-Rev2-MOD.03.aao>. Acesso em: 01 abril 2024.

BRASIL (2024b). Estado Maior da Armada. **Circular 01/2024: Diretrizes gerais para a montagem do Plano de Ação (PA) 2024**. Disponível em: <https://www.ema.mb/sites/default/arquivos/circular/Circ-01-2024-EMA-Diretrizes-gerais-para-Montagem-PA-2025.zip>. Acesso em: 01 abril 2024.

DAVIS, Paula Guelman. **Análise comparativa da eficiência alocativa das despesas públicas dos municípios brasileiros utilizando técnicas de mineração de dados**. (Dissertação de Mestrado) - Pós-Graduação e Pesquisas em Administração da Universidade Federal de Minas Gerais (UFMG), Minas Gerais, 2019. Disponível em: <https://repositorio.ufmg.br/bitstream/1843/31718/1/Disserta%C3%A7%C3%A3o%20vFINAL%20P%C3%93S%20BANCA%20COM%20FOLHA%20DE%20APROV%20E%20FICHA%20CAT%20-%20Paula%20Guelman%20Davis.pdf>. Acesso em: 10 fevereiro 2024.

DO NASCIMENTO, Vinícius Damasceno. **Gastos militares no brasil: o processo decisório de alocação orçamentária (2000-2018)**. Revista Brasileira de Estudos Estratégicos 12.24, 2021. Disponível em: <http://www.rest.uff.br/index.php/rest/article/view/226>. Acesso em: 01 abril 2024.

HAN, Jiawei; PEI, Jian; TONG, Hanghang. **Data mining: concepts and techniques**. [S.l.]: Morgan kaufmann, 2022. Disponível em: https://books.google.com.br/books/about/Data_Mining_Concepts_and_Techniques.html?id=pQws07tdpjoC&redir_esc=y. Acesso em: 15 mar 2024.

LIU, Jianli. **Comprehensive Evaluation Method of Enterprise Financial Budget Performance Based on Data Mining**. In 2022 14th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA), pp. 1019-1025. IEEE, 2022. Disponível em: <https://ieeexplore.ieee.org/document/9723896>. Acesso em: 15 mar 2024.

MENDES, M. J. **Sistema orçamentário brasileiro: planejamento, equilíbrio fiscal e qualidade do gasto público**. Cadernos de Finanças Públicas, (9), 57-102, 2009. Disponível em: <https://repositorio.enap.gov.br/bitstream/1/3858/1/Caderno%209.pdf#page=58>. Acesso em: 11 abr 2024.

NOGUEIRA, Alexandre Martins et al. **Ciência de Dados em Políticas Públicas: uma experiência de formação**. Brasília: Enap, Especialização em Ciência de Dados aplicada a Políticas Públicas, 2022. 269 p. : il. Disponível em: <https://repositorio.enap.gov.br/handle/1/7472>. Acesso em: 22 jun 2024.

PROVOST, Foster; FAWCETT, Tom. **Data Science for Business: What you need to know about data mining and data-analytic thinking**. [S.l.]: O'Reilly Media, 2013. Disponível em: https://www.researchgate.net/publication/256438799_Data_Science_for_Business. Acesso em: 22 jun 2024.

SIMON, HA, MELON C. **Explaining the Ineffable: AI on the Topics of Intuition, Insight and Inspiration**. Departments of Computer Science and Psychology, IJCAI (1), 1995. 939-49. Disponível em: http://iiif.library.cmu.edu/file/Simon_box00021_fld01477_bdl0001_doc0001/Simon_box00021_fld01477_bdl0001_doc0001.pdf. Acesso em: 11 mar 2024.

SHAHANA, T, LAVANYA, V, BHAT, AR. **State of the art in financial statement fraud detection: A systematic review**. Technological Forecasting and Social Change. 2023;192:122527 Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0040162523002123>. Acesso em: 13 jun 2024.

SILVA, André B, SANTOS, Cleverton, TELES, Íuri Batista. **Mineração de Dados em Órgãos de Auditoria e/ou Fiscalização**. Departamento de Sistemas de Informação – Universidade Federal de Sergipe (UFS), 2010.

TAN, Pang-Ning; STEINBACH, Michael; KUMAR, Vipin. **Introduction to data mining**. [S. l.]: Pearson Education India, 2016.

VALLE-CRUZ, D, FERNANDEZ-CORTEZ, V, GIL-GARCIA, JR. **From E-budgeting to smart budgeting: Exploring the potential of artificial intelligence in government decision-making for resource allocation**. Government Information Quarterly. 2022 39(2):101644.

VELLEZ, Bruno Charlier Lassance. **A importância do Poder Legislativo para o orçamento da Marinha do Brasil: Uma análise do nível de influência orçamentária e suas implicações para a capacidade operacional da Instituição**.

(Dissertação de Mestrado) - Mestrado em Economia e Negócios na Escola de Economia e Gestão da Universidade do Minho, Braga, Portugal, 2024.

WITTEN, Ian H; FRANK, Eibe; HALL, Mark A; PAL, Christopher J; **Data Mining: Practical machine learning tools and techniques**. In: MORGAN KAUFMANN. DATA Mining. [S.l.: s.n.], 2017. v. 4, p. 11–79.