

# Análise Integrativa de Metodologias de Gestão de Riscos em Projetos de Ciência de Dados

Sabrina D. C. Feitosa<sup>1</sup>

<sup>1</sup>Programa de Pós-Graduação Profissional em Engenharia Elétrica  
Universidade de Brasília (UnB)

Campus Universitário Darcy Ribeiro Asa Norte, Brasília-DF, CEP 70910-900

sabrina.feitosa@aluno.unb.br

**Abstract.** Data science initiatives frequently exhibit high failure rates, driven by technical constraints, organizational limitations and insufficient risk management practices. Challenges such as low data maturity, lack of governance, misalignment between technical and business teams, and the absence of structured mechanisms to address ethical and sociotechnical risks have been widely identified in the literature. In this context, the purpose of this study is to conduct a comparative analysis of the main risk management methodologies applied to data science projects, aiming to identify, classify, and synthesize their similarities, differences and existing gaps. An integrative literature review was performed using indexed databases and a structured protocol for selection and content analysis. The study examines widely adopted risk management standards—ISO 31000, PMBOK Risk Management and NIST RMF—as well as frameworks specific to data science workflows, such as CRISP-DM and the recently proposed DS EthiCo RMF, which incorporates ethical and sociotechnical dimensions into the project life cycle. The findings reveal that traditional approaches provide limited coverage of emerging risks, whereas contemporary models propose multidimensional structures capable of integrating ethical oversight, governance and continuous monitoring. As a contribution, this work offers theoretical support for the development of hybrid frameworks that balance technical efficiency, organizational alignment and responsible data practices, while highlighting research gaps that can guide future investigations.

**Keywords.** ethical governance; project lifecycle; sociotechnical risks.

**Resumo.** Projetos de ciência de dados têm apresentado elevados índices de insucesso, motivados tanto por limitações técnicas quanto por deficiências na gestão de riscos. A ausência de práticas estruturadas de governança, alinhamento entre equipes e consideração de riscos éticos, sociotécnicos e organizacionais tem sido apontada pela literatura como um dos principais fatores que comprometem resultados. Diante desse cenário, o objetivo deste trabalho é analisar comparativamente as principais metodologias de gestão de riscos aplicadas a projetos de ciência de dados, buscando identificar, classificar e sintetizar suas similaridades, diferenças e lacunas. Para atingir esse objetivo, realizou-se uma revisão integrativa da literatura em bases indexadas, fundamentada em procedimentos sistemáticos de busca, seleção e análise de conteúdo. A metodologia contemplou o exame de modelos amplamente utilizados, como ISO 31000,

*PMBOK Risk Management, NIST RMF e CRISP-DM, bem como a avaliação do framework DS EthiCo RMF, recentemente proposto para incorporar riscos éticos e sociotécnicos ao ciclo de vida da ciência de dados. Os resultados evindem que abordagens tradicionais tratam riscos de forma limitada, enquanto modelos contemporâneos propõem estruturas multidimensionais que ampliam o escopo de avaliação. Como contribuição, o estudo oferece subsídios para o desenvolvimento de frameworks híbridos que integrem governança, responsabilidade e eficiência técnica, além de indicar lacunas que podem orientar pesquisas futuras na área.*

**Palavras-chave.** governança de dados; frameworks de processo; avaliação de riscos

## 1. Introdução

A crescente adoção de soluções baseadas em análise de dados tem ampliado a demanda por processos capazes de lidar com incertezas, dependências técnicas e impactos organizacionais associados ao desenvolvimento de projetos de ciência de dados. Estudos recentes têm indicado que parcela significativa dessas iniciativas não alcança os resultados esperados, em razão de fatores como baixa maturidade organizacional, ausência de governança, resistência cultural e fragilidades na qualidade e disponibilidade dos dados. Esse cenário reforça a importância de compreender como metodologias de gestão de riscos podem contribuir para reduzir falhas e promover maior previsibilidade no ciclo de vida dos projetos.

A literatura apresenta diferentes perspectivas sobre o tema, desde modelos amplamente difundidos para gestão organizacional e de projetos, como ISO 31000, PMBOK e NIST RMF, até metodologias específicas para ciência de dados, como CRISP-DM. Mais recentemente, têm surgido abordagens que ampliam a visão tradicional ao incorporar dimensões sociotécnicas e éticas, a exemplo do DS EthiCo RMF. Entretanto, ainda se observam lacunas quanto à integração desses modelos e à adaptação às características multidisciplinares da área.

Diante dessas questões, o objetivo geral deste trabalho é analisar comparativamente as principais metodologias de gestão de riscos aplicadas a projetos de ciência de dados, de modo a sistematizar suas características, classificar seus elementos e identificar lacunas que possam orientar o aperfeiçoamento de frameworks. Os objetivos específicos incluem: (i) descrever os referenciais teóricos e metodologias predominantes; (ii) comparar estruturas, escopos e processos; e (iii) sintetizar limitações e oportunidades de evolução. A justificativa do estudo reside na necessidade crescente de modelos que contemplam dimensões técnicas, organizacionais e éticas de forma integrada. Ao final, o trabalho está organizado em referencial teórico, metodologia, resultados e conclusões.

## 2. Referencial Teórico

A alta taxa de insucesso em projetos de governança e análise de dados tem despertado atenção acadêmica e empresarial. Segundo previsão do [Group 2024], 80% dessas iniciativas falharão até 2027, principalmente por falta de maturidade organizacional e ausência de um senso de urgência para impulsionar mudanças estruturais.

Em [Gray and Shellshear 2023] reforçam essa perspectiva ao analisarem casos práticos de fracasso em projetos baseados em dados. Os autores identificam causas recorrentes, como imaturidade em gestão de dados, ausência de estratégia clara, baixa qualidade dos dados, resistência cultural à mudança e priorização de ferramentas em detrimento da estratégia. Esses fatores evidenciam a complexidade da implementação de soluções de ciência de dados sem uma base sólida de governança e gestão de riscos.

A literatura também destaca o papel da gestão de riscos como elemento essencial para o sucesso de projetos de ciência de dados. [Holtkemper et al. 2023] ressaltam que, além de aspectos como custo, tempo e recursos, o diferencial entre projetos bem-sucedidos e malsucedidos está na forma como os riscos são identificados e tratados. Os autores apontam ainda que modelos tradicionais de processo em ciência de dados, como o CRISP-DM, subestimam etapas pré e pós-projeto, sobretudo as relacionadas à gestão de riscos e à avaliação de resultados. Seu estudo mapeia os principais riscos e evidencia sobreposições com a engenharia de software, além de lacunas específicas de competências e desafios estruturais inerentes à área.

O framework CRISP-DM (Cross Industry Standard Process for Data Mining) 1.0 [Chapman 2000] é um processo não linear e iterativo para projetos de mineração de dados, dividido em seis fases principais:

- Business Understanding (compreensão do negócio, definição de objetivos e requisitos);
- Data Understanding (coleta inicial, descrição, exploração e verificação de qualidade dos dados);
- Data Preparation (seleção, limpeza, construção e formatação dos dados);
- Modeling (seleção de técnicas de modelagem, geração de modelos iniciais e avaliação);
- Evaluation (verificação se os modelos atendem aos objetivos de negócio e identificação de ações derivadas);
- Deployment (plano de implementação, monitoramento, manutenção e relatório final).

Complementarmente, [Varela and Domingues 2021] utilizaram o método Delphi para priorizar riscos específicos da ciência de dados, identificando preocupações adicionais às observadas em projetos de TI convencionais. [Lahiri and Saltz 2022] complementa essa visão apresentando lacunas operacionais observadas na identificação e mitigação de riscos em diferentes fases de projetos de ciência de dados.

[Lahiri and Saltz 2023] ampliam o debate ao argumentar que práticas correntes de gestão de projetos mantêm foco na eficiência e redução de custos, negligenciando a natureza sociotécnica e os riscos éticos associados aos sistemas baseados em dados. Os autores propõem o framework DS EthiCo RMF, um modelo adaptativo e humano-centrado que integra ética, governança e gestão de riscos ao longo de todo o ciclo de vida dos projetos. Essa abordagem visa reduzir o hiato entre práticas normativas e exigências do contexto real de aplicação.

No contexto de práticas organizacionais, estudos anteriores [Saltz et al. 2018] destacam que o sucesso de iniciativas em ciência de dados depende de instituições com forte cultura ética e de governança. Esses autores identificam como desafios críticos a

coordenação entre equipes técnicas e de negócios, a transparência nos processos analíticos e a conformidade regulatória.

Em pesquisas subsequentes, [Lahiri and Saltz 2024] observaram que a maioria das equipes de ciência de dados adapta frameworks ágeis e metodologias tradicionais, como Scrum ou CRISP-DM, sem segui-las integralmente, o que gera inconsistências na execução. As principais dificuldades observadas incluem lacunas culturais, incertezas de projeto e falta de supervisão ética. Os autores recomendam uma comunicação ativa com stakeholders, critérios claros de sucesso e adaptação dos métodos de gestão de TI às peculiaridades da ciência de dados.

O DS EthiCo RMF [Lahiri and Saltz 2024], é então proposto como um framework integrado para gerenciar riscos em projetos de ciência de dados, combinando princípios de gestão de riscos (inspirados em ISO 31000 e PMBOK), ética e governança, com foco em riscos sociotécnicos, éticos e organizacionais que frameworks tradicionais não abordam adequadamente.

### **Estrutura Principal do DS EthiCo RMF:**

O framework é estruturado em cinco dimensões interconectadas:

- Riscos Técnicos (qualidade de dados, modelagem, escalabilidade);
- 
- Riscos Éticos (viés, privacidade, transparência, impacto social);
- 
- Riscos Organizacionais (recursos, governança, conformidade);
- 
- Riscos de Projeto (escopo, cronograma, stakeholders);
- 
- Monitoramento e Adaptação Contínua (avaliação iterativa e ajustes ao longo do ciclo de vida do projeto).

### **Processo e Aplicação:**

O processo segue um ciclo iterativo adaptado ao ciclo de vida de data science (similar a CRISP-DM), incluindo identificação de riscos multidimensional, análise qualitativa/quantitativa, priorização, planejamento de respostas éticas e monitoramento com métricas específicas para cada dimensão. Ele enfatiza governança centrada no humano, integração ética desde a concepção do projeto e ferramentas para auditoria contínua, visando mitigar falhas comuns identificadas na revisão sistemática de literatura.

O framework foi desenvolvido a partir de uma análise de 48 estudos, destacando gaps em abordagens existentes como NIST RMF, e é apresentado como modelo adaptativo para organizações e pesquisadores em data science.

Os principais padrões apresentam abordagens distintas para a gestão de riscos, com diferenças relevantes em escopo, estrutura e aplicação. São referências de risco:

- ISO 31000 [for Standardization 2018];
- PMBOK Risk Management (do PMI) [Project Management Institute 2021];
- NIST RMF [Joint Task Force and National Institute of Standards and Technology 2020].

### **Princípios e Objetivos Gerais:**

**ISO 31000:** Foca em princípios universais para gestão de riscos, aplicáveis a qualquer organização, setor ou tipo de risco, visando criar e proteger valor, integrar riscos à cultura organizacional e aprimorar a tomada de decisão.

**PMBOK Risk Management:** Estrutura voltada para projetos, enfatiza a identificação, análise, planejamento de respostas e monitoramento de riscos durante o ciclo de vida de um projeto, buscando objetivos específicos (escopo, tempo, custo, qualidade) e gestão pró-ativa dos impactos.

**NIST RMF:** Modelo baseado em etapas estruturadas (frequentemente utilizado em contextos de segurança da informação e TI), orientado à proteção de ativos digitais e à conformidade legal, com foco especial em análise, tratamento, controle e monitoramento contínuo de riscos de cibersegurança.

### **Estrutura e Processos:**

**Tabela 1. Comparação entre ISO 31000, PMBOK Risk Management e NIST RMF**

Aspecto	ISO 31000	PMBOK	NIST RMF
Objetivo	Gestão organizacional abrangente	Projetos (tempo, custo, escopo)	Segurança da informação
Escopo	Todos os riscos/setores	Riscos de projetos	Cibersegurança/governo
Etapas principais	Princípios + Processo (5 etapas)	6 processos sequenciais	6 passos cíclicos
Abordagem	Integrativa/cultural	Processual/projetos	Técnica/conformidade
Aplicação	Qualquer organização	Projetos TI/engenharia	TI/governamental

### **Abordagem Metodológica:**

**ISO 31000:** Procura alinhar a gestão de riscos com a governança corporativa, exigindo envolvimento de todos os níveis organizacionais. Destaca a comunicação e a cultura como elementos-chave.

**PMBOK:** Abordagem voltada para projetos, priorizando o envolvimento dos stakeholders, priorização dos riscos, planos de resposta e acompanhamento estruturado em fases.

**NIST RMF:** Estrutura cílica e documental, enfatizando controles de segurança, auditoria, e adaptação a ameaças emergentes, com monitoramento contínuo e forte foco em conformidade regulatória.

**Resumo das Diferenças** ISO 31000 abrange gestão de riscos organizacional e estratégica, PMBOK detalha a aplicação em projetos com processos específicos, e NIST RMF segue etapas bem definidas para gestão de riscos em ambientes digitais e governamentais, com alta exigência de compliance.

No campo metodológico, [Iñigo Martinez et al. 2021] apontam que os desafios da ciência de dados derivam de questões organizacionais e sociotécnicas, incluindo baixa maturidade de processos e papéis ambíguos nas equipes. Após revisar 19 metodologias disponíveis, observam a escassez de abordagens integradas que contemplam gestão de

projetos, equipes e dados de forma conjunta. Por isso, propõem um framework conceitual voltado ao desenvolvimento de metodologias mais abrangentes e adaptáveis.

Corroborando essas conclusões, [Saltz and Krasteva 2022] identificam que as falhas em projetos de big data decorrem da ausência de processos estruturados e de coordenação entre equipes multidisciplinares. Apesar de o CRISP-DM continuar como o framework mais utilizado, os autores defendem a necessidade de novos modelos orientados à maturidade processual e à governança de dados.

Finalmente, [Christozov et al. 2018] destacam que a capacitação das equipes e a infraestrutura organizacional de ciência de dados — ou Data Science Business Infrastructure (DSBI) — funcionam como habilitadores da gestão de riscos, fortalecendo a capacidade de prevenção e resposta a falhas.

### **3. Metodologia**

A presente pesquisa caracteriza-se como uma revisão bibliográfica sistemática integrativa, classificada como uma pesquisa de natureza aplicada, cujo objetivo principal é a síntese do conhecimento existente para fornecer uma percepção prática no contexto da gestão de riscos em projetos de data science. O objetivo da pesquisa é exploratório e descritivo, pois busca explorar, resumir e esclarecer conceitos e descobertas provenientes de estudos diversos, apresentando uma compreensão abrangente do tema. A forma da pesquisa é predominantemente qualitativa.

Quanto aos procedimentos técnicos, a revisão integrativa baseia-se principalmente em uma pesquisa bibliográfica, que envolve a busca organizada e seleção criteriosa da literatura científica disponível. No que se refere aos instrumentos de coleta de dados, a pesquisa utiliza processos sistemáticos de busca bibliográfica e protocolos de extração de dados, sem a utilização de instrumentos diretos de coleta de dados, como questionários ou experimentos.

A análise dos dados obtidos na revisão integrativa é realizada por meio da análise de conteúdo, que permite a categorização temática e a síntese das informações provenientes de múltiplos estudos. Além disso, pode-se utilizar a análise comparativa para confrontar diferentes abordagens ou achados, bem como a análise estatística descritiva quando dados quantitativos extraídos da literatura são agregados e sintetizados. Para um estudo que propõe realizar uma revisão integrativa sobre a gestão de riscos em projetos de data science, utilizando fontes como relatórios técnicos, livros, artigos científicos e anais de conferências, esses aspectos metodológicos orientam a construção de uma síntese rigorosa e baseada em evidências, capaz de subsidiar práticas futuras e orientar pesquisas subsequentes.

Segundo [Toronto and Remington 2020], o termo revisão integrativa é frequentemente usado como sinônimo de revisão sistemática; no entanto, existem diferenças distintas entre eles. As principais diferenças são seu propósito e abrangência, tipos de literatura incluídos e tempo e recursos necessários para sua execução. A revisão integrativa analisa de forma mais ampla um fenômeno de interesse do que a revisão sistemática e permite pesquisas diversas, que podem conter literatura teórica e metodológica para atender ao objetivo da revisão. Essa abordagem apoia uma ampla gama de investigações, como definição de conceitos, revisão de teorias ou análise de questões metodológicas. Semelhante à revisão sistemática, ela utiliza um processo sistemático para identificar, analisar,

avaliar e sintetizar todos os estudos selecionados, mas não inclui métodos de síntese estatística.

Na fase de planejamento, realizou-se a busca de artigos nas bases de dados Scopus e Web of Science. Os termos de busca utilizados foram "Risk Management" AND "Data Science Projects", aplicados tanto em títulos de artigos quanto em palavras-chave e assuntos relacionados. Foram excluídos do resultado da pesquisa os artigos cujo conteúdo estivesse voltado a áreas de conhecimento distintas da Ciência da Computação. A seleção preliminar dos artigos encontrados foi feita a partir da leitura dos resumos. Na fase de execução, os artigos selecionados serão analisados por meio de um estudo comparativo e classificatório, agrupando-os conforme o tipo de artigo, como revisão de literatura, estudo de caso, pesquisa ou survey. Também será realizada uma classificação baseada no tipo de metodologias ou frameworks de gestão de riscos adotados, caso tenham sido utilizados, ou na ausência de adoção de qualquer metodologia específica. Será conduzida uma análise qualitativa subjetiva dos resultados e das conclusões obtidas nos artigos selecionados. Em seguida, será feita uma análise das lacunas identificadas nos estudos, com o objetivo de apontar oportunidades para pesquisas futuras. Inicialmente, foram encontrados 21 artigos que atendiam aos critérios de pesquisa, dos quais 9 foram selecionados após análise subjetiva dos resumos.

#### **4. Resultados e Discussão**

Os resultados obtidos a partir da revisão integrativa permitem identificar um conjunto consistente de padrões relacionados às causas de insucesso em projetos de ciência de dados. A literatura aponta que tais iniciativas falham não apenas por limitações técnicas, mas principalmente por fatores organizacionais, culturais e sociotécnicos. [Gray and Shellshear 2023] enfatizam que deficiências na qualidade dos dados, ausência de estratégia e falta de governança são elementos recorrentes que comprometem o desempenho desses projetos. Esses achados convergem com [Saltz et al. 2018], que destacam a necessidade de coordenação entre equipes multidisciplinares, bem como a importância de processos estruturados que favoreçam visibilidade, rastreabilidade e alinhamento entre áreas de negócio e equipes técnicas.

Essa perspectiva é reforçada por [IñigoMartinez et al. 2021], que evidenciam a baixa maturidade organizacional e a indefinição de papéis como fatores que dificultam a aplicação efetiva de metodologias consolidadas. Há, portanto, convergência entre os autores quanto ao diagnóstico: os riscos que comprometem projetos de ciência de dados são majoritariamente não técnicos e demandam abordagens integradas de gestão.

Outro ponto de convergência refere-se às limitações do CRISP-DM. Embora amplamente utilizado, o framework não contempla explicitamente etapas relacionadas à identificação e mitigação de riscos organizacionais ou éticos. [Holtkemper et al. 2023] observam que o modelo cobre apenas parte do ciclo de vida dos projetos, negligenciando atividades essenciais antes e depois da execução técnica. [Saltz and Krasteva 2022] e [Lahiri and Saltz 2024] também destacam fragilidades na aplicação prática do CRISP-DM, especialmente quando considerações regulatórias, culturais ou de responsabilização algorítmica tornam-se relevantes. Dessa forma, há consenso entre diversos autores de que o CRISP-DM, embora robusto operacionalmente, é insuficiente para lidar com a complexidade atual dos sistemas baseados em dados.

Por outro lado, a literatura apresenta divergências quanto ao nível de prescrição desejável em metodologias de gestão de riscos. Enquanto normas como ISO 31000 e PM-BOK propõem abordagens amplas e adaptáveis a múltiplos contextos, o NIST RMF adota estrutura mais prescritiva, orientada à conformidade e à segurança da informação. Essas diferenças impactam diretamente a aplicabilidade dos modelos em projetos de ciência de dados, que muitas vezes exigem flexibilidade metodológica para lidar com incertezas experimentais. [Chapman 2000], ao descrever o CRISP-DM, enfatiza processos iterativos e adaptáveis, enquanto outras abordagens priorizam controle rigoroso, documentação e rastreamento formal. A divergência revela a tensão entre a natureza exploratória dos projetos e a demanda crescente por governança e responsabilidade.

A análise dos estudos também evidenciou diferenças significativas na forma como riscos éticos e sociotécnicos são tratados. Apesar de autores como [Gray and Shellshear 2023] reconhecerem a relevância desses aspectos, apenas o DS EthiCo RMF, proposto por [Lahiri and Saltz 2024], apresenta uma abordagem sistematizada para incorporá-los ao ciclo de vida dos projetos. Essa proposta inclui etapas específicas para análise de viés, transparência, impactos sociais e monitoramento contínuo, preenchendo lacunas não abordadas pelos frameworks tradicionais. Assim, observa-se uma evolução conceitual entre estudos que apenas descrevem os problemas e modelos que buscam oferecer soluções operacionais.

Além disso, os estudos de caso encontrados demonstram a aplicação predominante do CRISP-DM em áreas como manufatura, educação, transporte e meio ambiente. Embora reforcem a robustez técnica do modelo, nenhum desses estudos discute riscos éticos, questões de governança ou impactos organizacionais. Isso confirma a lacuna identificada nos estudos teóricos e ressalta a urgência de metodologias capazes de integrar múltiplas dimensões de risco.

De forma geral, a análise comparativa evidencia que, embora existam convergências nas críticas aos modelos atuais e no reconhecimento da necessidade de abordagens mais abrangentes, há divergências quanto ao grau de formalização dos processos e à extensão do escopo dos frameworks. Esses resultados reforçam a conclusão de que a área de ciência de dados demanda modelos híbridos, capazes de combinar eficiência técnica, governança estruturada e mecanismos de responsabilidade ética, atendendo simultaneamente às características experimentais e às exigências sociais e regulatórias das soluções baseadas em dados.

A Tabela 2 apresenta uma comparação detalhada entre o CRISP-DM e o DS EthiCo RMF, revelando diferenças fundamentais em escopo, estrutura e abordagem. Enquanto o CRISP-DM (2000) estabelece um processo técnico-operacional padronizado para mineração de dados industriais, focando em seis fases iterativas orientadas ao valor de negócio, o DS EthiCo RMF (2024) emerge como resposta aos gaps identificados na literatura, integrando cinco dimensões de riscos multidimensionais (técnicos, éticos, organizacionais, de projeto e monitoramento contínuo).

Essa evolução reflete a maturidade da data science, passando de uma visão puramente técnica para uma governança centrada no humano e ética proativa. O CRISP-DM trata riscos implícitos (qualidade de dados, falha de modelagem), enquanto o DS EthiCo RMF os explicitiza e mitiga explicitamente, incluindo viés algorítmico, privacidade e im-

pactos sociotécnicos. A maior complexidade do DS EhtiCo RMF demanda maturidade organizacional avançada, mas oferece métricas multidimensionais e auditoria contínua, essenciais para conformidade regulatória moderna.

Os resultados sugerem que a integração do DS EhtiCo RMF ao CRISP-DM pode criar abordagens híbridas mais robustas para projetos de data science no setor público brasileiro, alinhando eficiência técnica com responsabilidade ética e governança.

**Tabela 2. Comparação detalhada entre CRISP-DM e DS EhtiCo RMF**

Aspecto	CRISP-DM (2000)	DS EhtiCo RMF (2024)
<b>Foco</b>	Processo padrão para mineração de dados industriais. Ênfase técnica e geração de valor de negócio	Gestão integrada de riscos em data science. Aborda riscos sociotécnicos, éticos e organizacionais
<b>Escopo</b>	Ciclo completo de projetos DM (da compreensão do negócio à implantação)	Riscos multidimensionais ao longo do ciclo de vida de data science
<b>Estrutura</b>	6 fases não-lineares e iterativas	5 dimensões interconectadas + monitoramento adaptativo contínuo
<b>Fases/Dimensões</b>	1. Business Understanding; 2. Data Understanding; 3. Data Preparation; 4. Modeling; 5. Evaluation; 6. Deployment	1. Riscos Técnicos; 2. Riscos Éticos; 3. Riscos Organizacionais; 4. Riscos de Projeto; 5. Monitoramento Contínuo
<b>Iteratividade</b>	Iterações entre fases conforme necessário	Ciclo adaptativo com avaliação contínua e ajustes dinâmicos
<b>Abordagem</b>	Orientada ao negócio + técnica. Foco em resultados mensuráveis	Centrada no humano + ética + governança. Mitigação proativa de riscos
<b>Riscos considerados</b>	Riscos implícitos (qualidade de dados, falha de modelagem)	Explícitos: viés, privacidade, transparência, impacto social, conformidade, recursos
<b>Governança</b>	Governança de projeto básica	Governança ética integrada com auditoria contínua
<b>Métricas</b>	Métricas de performance de modelo e ROI	Métricas multidimensionais (técnica, ética, organizacional)
<b>Aplicação típica</b>	Empresas industriais, consultorias DM	Organizações data science com preocupações éticas/regulatórias
<b>Limitações identificadas</b>	Não aborda riscos éticos/sociotécnicos explicitamente	Mais complexo, requer maturidade organizacional avançada

Na pesquisa bibliográfica, foram encontrados diversos estudos de caso aplicando CRISP-DM em contextos industriais, educacionais e ambientais. Nenhum estudo de caso específico foi identificado para DS EhtiCo RMF, pois é um framework recente (2024) ainda em fase propositiva.

A análise da tabela de síntese dos estudos de caso que aplicam o CRISP-DM permite observar padrões consistentes no uso prático do framework em diferentes domínios. Os estudos identificados abrangem áreas como manufatura, meio ambiente, transporte, educação e gestão pública, demonstrando a versatilidade do modelo e sua capacidade de adaptação a múltiplos cenários. Em todos os casos, nota-se que as etapas fundamentais

**Tabela 3. Resumo dos estudos de caso de aplicação do CRISP-DM**

Estudo	Ano	Domínio	Resumo do Caso
Lens Coating Machines [IEEE 2023]	2023	Manufatura	Monitoramento de condição em máquinas de revestimento de lentes usando LSTM, DT e SVM
Human-Wildlife Conflicts [Taylor 2022]	2022	Meio Ambiente	Análise de hotspots de conflitos humanos-animais selvagens na Índia
Eco-Driving Project [Springer 2025]	2025	Transporte	Otimização de consumo de combustível em transporte público dinamarquês
Student Performance [MDPI 2024]	2024	Educação	Predição de desempenho acadêmico em e-learning
Water Quality Puebla [IJCOPI 2024]	2024	Meio Ambiente	Classificação de contaminação de água usando DT e KNN
Drilling KPIs [SPE 2025]	2025	Petróleo	Predição de indicadores de performance de perfuração (SVM, RF)

do CRISP-DM — compreensão do negócio, compreensão dos dados, preparação, modelagem, avaliação e implantação — são seguidas de forma relativamente uniforme, o que reforça a maturidade operacional do framework e sua consolidação como referência metodológica.

Entretanto, a comparação entre os estudos evidencia que a aplicação do CRISP-DM tende a concentrar-se nos aspectos estritamente técnicos do processo analítico. Em nenhum dos casos avaliados foram encontrados procedimentos estruturados de gestão de riscos, seja em relação à qualidade dos dados, seja em relação a impactos organizacionais, limitações operacionais ou implicações éticas do uso dos modelos. Além disso, a etapa de implantação frequentemente aparece de forma superficial, limitada à apresentação dos resultados e sem aprofundamento nas estratégias de monitoramento contínuo, documentação, controle de versão ou avaliação pós-implementação. Esse padrão confirma as limitações apontadas pela literatura teórica, segundo a qual o CRISP-DM não aborda etapas críticas do ciclo de vida da ciência de dados que se tornaram relevantes nos últimos anos.

Outro ponto observado a partir da tabela é que, embora os estudos demonstrem resultados positivos em seus respectivos contextos, raramente discutem desafios enfrentados ao longo do projeto, tais como conflitos entre equipes, restrições de infraestrutura, dificuldades de integração com sistemas legados ou barreiras culturais. Esse silêncio metodológico sugere que a aplicação do CRISP-DM nos estudos de caso tende a privilegiar a narrativa de sucesso, deixando de registrar elementos fundamentais para a compreensão dos riscos enfrentados e das medidas adotadas para mitigá-los. Consequentemente, as

experiências documentadas não fornecem subsídios suficientes para avaliar a gestão de riscos de forma abrangente.

A síntese também revela que os estudos de caso apresentam foco predominante nas etapas intermediárias do CRISP-DM — especialmente compreensão e preparação dos dados —, enquanto atividades estratégicas, como definição de objetivos de negócio e análise de impacto da solução, recebem menor detalhamento. Essa assimetria reforça a necessidade identificada na literatura de integrar frameworks de governança e gestão de riscos ao processo técnico, de modo a garantir que iniciativas de ciência de dados não se limitem à modelagem estatística, mas contemplam valor organizacional, sustentabilidade e responsabilidade.

Portanto, a tabela de estudos de caso demonstra simultaneamente a robustez e a limitação do CRISP-DM: por um lado, confirma sua aplicabilidade ampla e sua estrutura operacional consistente; por outro, expõe lacunas relacionadas à ausência de mecanismos formais de análise de riscos e à pouca ênfase em aspectos organizacionais e éticos. Esses achados reforçam a pertinência de frameworks complementares — como o DS EthiCo RMF — que buscam preencher essas lacunas por meio da incorporação de dimensões sociotécnicas e mecanismos de monitoramento contínuo ao ciclo de vida dos projetos.

## 5. Conclusões

O objetivo deste estudo foi analisar comparativamente metodologias de gestão de riscos aplicadas a projetos de ciência de dados, considerando limitações observadas em abordagens tradicionais e demandas emergentes associadas a riscos sociotécnicos e éticos. A partir da revisão integrativa realizada, verificou-se que modelos amplamente utilizados, como ISO 31000, PMBOK, NIST RMF e CRISP-DM, fornecem estruturas relevantes, porém não abordam de forma explícita aspectos como viés algorítmico, privacidade, maturidade organizacional e impactos sociais. Em contraste, frameworks mais recentes, como o DS EthiCo RMF, ampliam o escopo de análise ao incorporar tais dimensões e propor mecanismos contínuos de monitoramento e adaptação.

Os objetivos específicos foram atendidos: foram descritos os principais referenciais teóricos, comparadas as estruturas dos frameworks analisados e identificadas lacunas relacionadas à ausência de modelos integrados que conciliem eficiência técnica, governança e responsabilidade ética. Como contribuição, o trabalho oferece uma síntese estruturada das metodologias existentes, apontando elementos que podem fundamentar o desenvolvimento de frameworks híbridos para projetos de ciência de dados.

Entre as limitações do estudo, destaca-se a dependência de literatura disponível em bases indexadas e a ausência de validação empírica dos modelos analisados. Além disso, o framework DS EthiCo RMF ainda carece de estudos aplicados, o que restringe a avaliação prática de sua eficácia. Como trabalhos futuros, recomenda-se a realização de estudos de caso, a elaboração de instrumentos de avaliação de maturidade em gestão de riscos e a investigação de modelos de governança aplicáveis a diferentes contextos organizacionais.

## Referências

Chapman, P. (2000). Crisp-dm 1.0: Step-by-step data mining guide. In *SPSS Inc. EUA.*

- Christozov, D., Rasheva-Yordanova, K., and Toleva-Stoimenova, S. (2018). Risks management in data science training. In *Proceedings of Regional International Conference on Applied Protection and ITS Trends*, page 7–10, Zlatibor.
- for Standardization, I. O. (2018). Iso 31000:2018 — risk management — guidelines. Technical report, International Organization for Standardization. Available at: <https://www.iso.org/iso-31000-risk-management.html>.
- Gray, D. and Shellshear, E. (2023). *Why data science projects fail: The harsh realities of implementing AI and analytics without the hype*. Chapman and Hall/CRC Data Science Series, 1st edition.
- Group, G. (2024). The gartner predictions for 2024: Data and analytics. Technical report, Gartner Group.
- Holtkemper, M., Potanin, M., Oberst, A., and Beecks, C. (2023). Risk identification of data science projects: A literature review. *LWDA: Learning, Knowledge, Data, Analysis*, pages 1–13.
- IEEE, A. (2023). Application of crisp-dm and dmme to a case study of condition monitoring of lens coating machines. *IEEE Conference*.
- IJCOPi, A. (2024). Prediction of water quality through dissolved oxygen saturation using data mining: A case study of puebla mexico. *International Journal of Computing and Optimization in the Intelligent Systems*.
- IñigoMartinez, ElisabethViles, and Olaizola, I. (2021). Data science methodologies: Current challenges and future approaches. *Big Data Research*.
- Joint Task Force and National Institute of Standards and Technology (2020). Risk management framework for information systems and organizations: A system life cycle approach for security and privacy. Technical Report SP 800-37 Revision 2, NIST. Available at: <https://doi.org/10.6028/NIST.SP.800-37r2>.
- Lahiri, S. and Saltz, J. (2024). The need for a risk management framework for data science projects: a systematic literature review. *International Journal of Information Systems and Project Management*, page 41–57.
- Lahiri, S. and Saltz, J. S. (2022). The risk management process for data science: Gaps in current practices. In *Proceedings of the 55th Hawaii International Conference on System Sciences*.
- Lahiri, S. and Saltz, J. S. (2023). Evaluating data science project agility by exploring process frameworks used by data science teams. In *Hawaii International Conference on System Sciences*.
- MDPI, A. (2024). A case study on the data mining-based prediction of students' performance for effective and sustainable e-learning. *Sustainability*, 16(23):10442.
- Project Management Institute (2021). *A Guide to the Project Management Body of Knowledge (PMBOK Guide)*. Project Management Institute, Newtown Square, PA, USA, 7th edition edition.
- Saltz, J., Goul, M., Armour, F., and Sharda, R. (2018). Key management and governance challenges when executing data science or analytics projects. In *Twenty-Fourth Americas Conference on Information Systems*, New Orleans.

- Saltz, J. S. and Krasteva, I. (2022). Current approaches for executing big data science projects—a systematic literature review. *PeerJ Computer Science*.
- SPE, A. (2025). Application of machine learning for comprehensive predictive modelling of drilling key performance indicators. *SPE OnePetro*.
- Springer, A. (2025). Datapro - a standardized data understanding and processing procedure: A case study of an eco-driving project. *Lecture Notes in Computer Science*.
- Taylor, A. (2022). Application of crisp-dm methodology for managing human-wildlife conflicts: an empirical case study in india. *Journal of Environmental Planning and Management*.
- Toronto, C. E. and Remington, R. (2020). *A Step-by-Step Guide to Conducting an Integrative Review*. Springer, 1st edition.
- Varela, C. and Domingues, L. (2021). Risks of data science projects: A delphi study. In *Procedia Computer Science* 196, page 982–989.