

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Um protocolo de *reporting* inteligente, padronizado
e rastreável para gestão de projetos

Karen Symone Pessoa da Silva

Monografia - MBA em Inteligência Artificial e Big Data

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Karen Symone Pessoa da Silva

Um protocolo de *reporting* inteligente, padronizado e rastreável para gestão de projetos

Monografia apresentada ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientador: Prof. Dr. Rafael Geraldeli Rossi

Versão revisada

São Carlos

2025

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

S586p Silva, Karen Symone Pessoa da
Um protocolo de reporting inteligente,
padronizado e rastreável para gestão de projetos /
Karen Symone Pessoa da Silva; orientador Rafael
Geraldelli Rossi. -- São Carlos, 2025.
81 p.

Trabalho de conclusão de curso (MBA em
Inteligência Artificial e Big Data) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2025.

1. Gestão de Projetos. 2. Governança. I. Rossi,
Rafael Geraldelli, orient. II. Título.

Karen Symone Pessôa da Silva

**An intelligent, standardized and auditable reporting
protocol for project management**

Monograph presented to the Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, as part of the requirements for obtaining the title of Specialist in Artificial Intelligence and Big Data.

Concentration area: Artificial Intelligence

Advisor: Prof. Dr. Rafael Geraldeli Rossi

Final version

São Carlos

2025

*Dedico este trabalho à minha mãe, por ser minha maior fonte de inspiração.
Por ter me ensinado o valor da educação como caminho de transformação,
pela força e coragem com que sempre conduziu a vida e por acreditar
no meu potencial em todos os momentos.*

AGRADECIMENTOS

Agradeço, primeiramente, à minha família, pelo incentivo constante e pelo apoio incondicional em todos os momentos desta jornada.

Ao meu namorado pela paciência, compreensão e presença ao longo de todo o percurso do curso, que tornaram este caminho mais leve e possível.

Expresso minha gratidão à Universidade de São Paulo (USP) pela oportunidade de realizar este MBA e pela bolsa concedida, fundamentais para a concretização deste trabalho.

Por fim, registro meus sinceros agradecimentos ao meu orientador, pela dedicação, pelas valiosas sugestões e pelo suporte durante todas as etapas do desenvolvimento deste TCC.

RESUMO

SILVA, K.S.P. **Um protocolo de *reporting* inteligente, padronizado e rastreável para gestão de projetos.** 2025. 79 p. Monografia (MBA em Inteligência Artificial e Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

Escritórios de Projetos (*Project Management Offices*, PMOs) enfrentam um cenário marcado por dispersão de dados, formatos heterogêneos e elevado custo de consolidação de relatórios. Apesar dos avanços em *frameworks* de governança e práticas ágeis, persiste uma lacuna na automação de relatórios executivos com padronização e rastreabilidade — fator que compromete a confiabilidade e a tempestividade das informações. Nesse contexto, o uso de Inteligência Artificial (IA) Generativa tem se mostrado promissor para a geração de resumos e relatórios a partir de conteúdos ou contextos específicos. Entretanto, fatores como o acesso integrado a diferentes fontes e a rastreabilidade das evidências precisam ser considerados para viabilizar soluções de automação de relatórios executivos de governança de projetos. Dado isso, este trabalho apresenta um projeto aplicado que propõe um protocolo corporativo de *reporting* rastreável e um protótipo mínimo viável (*Minimum Viable Product*, MVP) para automatizar relatórios executivos de governança de projetos, fundamentados em Inteligência Artificial (IA) Generativa e Protocolo de Contexto de Modelo (*Model Context Protocol*, MCP). A arquitetura combina Modelos de Linguagem de Grande Escala (*Large Language Models*, LLMs) com as primitivas do MCP — *resources* para exposição governada de dados com ponteiros canônicos, *tools* para cálculos e validações e *prompts* versionáveis — para gerar saída estruturada em *Markdown*, com segregação clara entre fatos e opinião técnica (Assistente Virtual de Governança) e indicadores objetivos como o *Status–Cronograma–Tendência* (*Status–Schedule–Trend*, SST). Além disso, a proposta inclui um modelo de referência implementável e um protocolo reproduzível voltado a PMOs de médio porte. O escopo contempla fontes operacionais simples (bases de dados, repositório de projetos e registros textuais) e registra metadados técnicos (versões, *templates* e parâmetros) para auditoria e reproduzibilidade. A avaliação segue princípios de engenharia de solução e critérios objetivos (completude de campos, consistência factual com as fontes e cobertura de citações). Os resultados obtidos através de uma prova de conceito (*Proof of Concept*, POC) indicam viabilidade para acelerar a produção e elevar a confiabilidade de relatórios executivos, atendendo à lacuna prática identificada.

Palavras-chave: Governança de projetos; PMO; Inteligência Artificial Generativa; Automação de relatórios; Escritório de Projetos; Auditabilidade; Protocolo de Contexto de Modelo; MCP.

ABSTRACT

SILVA, K.S.P. **An intelligent, standardized and auditable reporting protocol for project management**. 2025. 79 p. Monograph (MBA in Artificial Intelligence and Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

Project Management Offices (PMOs) face a scenario marked by data dispersion, heterogeneous formats, and high reporting consolidation costs. Despite advances in governance frameworks and agile practices, a gap remains in the automation of executive reports with standardization and traceability — a factor that compromises the reliability and timeliness of information. In this context, the use of Generative Artificial Intelligence (GenAI) has shown promise for generating summaries and reports from specific contents or contexts. However, factors such as integrated access to different data sources and the traceability of evidence must be considered to enable the automation of executive governance reports. Then, this applied research presents a corporate protocol for traceable reporting and a Minimum Viable Product (MVP) to automate executive project governance reports, based on GenAI and the Model Context Protocol (MCP). The proposed architecture combines Large Language Models (LLMs) with MCP primitives — *resources* for governed data exposure with canonical pointers, *tools* for calculations and validations, and versioned *prompts* — to generate structured outputs in *Markdown*, with a clear separation between factual content and technical opinion (Virtual Governance Assistant) and objective indicators such as the *Status–Schedule–Trend* (SST). In addition, the proposal includes an implementable reference model and a reproducible protocol designed for medium-sized PMOs. The scope covers simple operational sources (spreadsheets and textual records) and registers technical metadata (versions, templates, and parameters) to ensure auditability and reproducibility. Evaluation follows solution engineering principles and objective criteria (field completeness, factual consistency with sources, and citation coverage). Results from a Proof of Concept (POC) indicate the feasibility of accelerating report production and increasing the reliability of executive reporting, thus addressing the identified practical gap.

Keywords: Project governance; Generative Artificial Intelligence; Report automation; Project Management Office; PMO; Model Context Protocol; MCP; Auditability.

LISTA DE FIGURAS

Figura 1 – Impacto percebido da <i>GenAI</i> em fatores de desempenho de projetos: comparação entre <i>Explorers</i> e <i>Trailblazers</i>	20
Figura 2 – Arquitetura conceitual do Model Context Protocol (MCP).	31
Figura 3 – Arquitetura do Assistente Virtual de Governança com MCP (visão lógica por camadas).	52
Figura 4 – Fases do CRISP-DM e seu caráter iterativo.	53
Figura 5 – Evidencia da saída da etapa 1 de carregamento dos dados	63
Figura 6 – Evidência da saída da etapa 2 de mapeamento de evidências (amostra)	64
Figura 7 – Evidência de amostra da saída da etapa 2 de cálculo do indicador de status	64

LISTA DE TABELAS

Tabela 1 – Síntese dos benefícios reportados por diferentes fontes sobre o uso de IA na gestão de projetos.	33
Tabela 2 – Matriz comparativa de soluções para assistência à governança de projetos	46
Tabela 3 – Prévia de casos de uso orientados pelo <i>benchmarking</i>	47
Tabela 4 – Mapeamento das abas do <i>corpus</i> e suas chaves primárias	79

SUMÁRIO

1	INTRODUÇÃO	19
1.1	Contextualização	20
1.2	Problema	22
1.3	Objetivos	22
1.3.1	Objetivo Geral	23
1.3.2	Objetivos Específicos	23
1.4	Organização do Texto	24
2	REFERENCIAL TEÓRICO E REVISÃO BIBLIOGRÁFICA	25
2.1	Governança de Projetos e Seus Desafios	25
2.2	Aplicabilidade da Inteligência Artificial na Governança de Projetos	26
2.3	Modelos de Linguagem de Grande Escala (LLMs) como Ferramenta para Automação	27
2.3.1	Fundamentos dos Modelos de Linguagem	27
2.3.2	LLMs como Ferramentas para Automação	29
2.3.3	<i>Model Context Protocol</i> (MCP): Fundamentos e Arquitetura	30
2.4	Estudos Recentes e Impactos da IA na Gestão de Projetos	32
2.5	Estratégias para Potencializar o Uso de LLMs na Governança de Projetos	33
2.5.1	Personalização de Modelos de IA	33
2.5.2	Integração com Ferramentas de Gerenciamento	34
2.5.3	Análise Preditiva e Gestão de Riscos	34
2.5.4	Automação de Comunicação e Assistência Virtual	34
2.6	Lacunas e Posicionamento deste Estudo	35
3	PANORAMA DE MERCADO, INVESTIMENTOS E RESULTADOS ESPERADOS	37
3.1	Business Model Canvas	37
3.1.1	Proposta de Valor	38
3.1.2	Segmentos de Clientes	38
3.1.3	Canais	39
3.1.4	Relacionamento com Clientes	39
3.1.5	Fontes de Receita	39
3.1.6	Recursos Principais	40
3.1.7	Atividades-Chave	40
3.1.8	Parcerias Principais	40

3.1.9	Estrutura de Custos	41
3.2	Benchmarking Tecnológico	41
3.2.1	Método e Critérios de Comparação	41
3.2.2	Matriz Comparativa “Estado da Prática” versus Proposta	42
3.2.3	Implicações para Adoção em PMEs	42
3.2.4	Síntese e Ligação com o MVP	42
3.3	Análise SWOT – Implantação de IA em Governança de Projetos . .	43
3.3.1	Forças	43
3.3.2	Fraquezas	44
3.3.3	Oportunidades	44
3.3.4	Ameaças	45
4	ASSISTENTE VIRTUAL DE GOVERNANÇA COM MCP	49
4.1	<i>Traceable Governance Reporting Protocol (TGRP)</i>	49
4.2	Arquitetura	50
4.3	Metodologia de Construção	52
4.3.1	Entendimento do Negócio	52
4.3.2	Entendimento e Preparação dos Dados	54
4.3.3	Modelagem	55
4.3.4	Avaliação	56
4.3.5	Implantação	56
4.4	MVP	57
4.4.1	Dados Utilizados no MVP	57
4.4.2	Configuração da LLM e Mecanismo de Inferência	58
4.4.3	Exemplos de Execução	62
4.4.4	Avaliação dos Resultados	67
5	CONCLUSÃO	69
	REFERÊNCIAS	73
	APÊNDICES	77
	APÊNDICE A – ESTRUTURA RELACIONAL DO CORPUS PRO- TÓTIPO	79

1 INTRODUÇÃO

A governança de projetos tem assumido papel central nas organizações contemporâneas, constituindo-se como um dos pilares para assegurar que iniciativas estratégicas sejam conduzidas de forma eficiente, transparente e alinhada aos objetivos institucionais. Embora metodologias amplamente difundidas, como o Project Management Body of Knowledge (PMBOK) *Guide* (Project Management Institute, 2021), PRINCE2 e práticas ágeis como Scrum e Kanban ofereçam diretrizes consistentes para a condução de projetos, observa-se que a realidade prática ainda está permeada de lacunas. Relatórios do Project Management Institute apontam que apenas 73,8% dos projetos alcançam os resultados inicialmente definidos (Project Management Institute, 2023), e que falhas de comunicação e falta de alinhamento estratégico permanecem entre os principais motivos de insucesso.

Um dos maiores gargalos nesse processo está relacionado à produção de relatórios de status. Em muitas organizações, essa atividade ainda é executada de forma manual e fragmentada, consumindo tempo das equipes e aumentando a possibilidade de inconsistências. A ausência de padronização e a dispersão das informações em múltiplas ferramentas corporativas dificultam a consolidação de dados e comprometem a confiabilidade dos relatórios apresentados aos *stakeholders*. A consequência imediata é a redução da capacidade das organizações em antecipar riscos, reagir a mudanças de contexto e garantir a transparência necessária em ambientes altamente competitivos e dinâmicos.

Técnicas de Inteligência Artificial (IA) vêm sendo aplicadas nos últimos anos para apoiar atividades de gestão e governança de projetos. Entre os avanços mais recentes destacam-se os Modelos de Linguagem de Grande Escala (LLMs, *Large Language Models*), considerados estado da arte em processamento de linguagem natural, e as arquiteturas de Inteligência Artificial Generativa (GenAI, *Generative Artificial Intelligence*), que se caracterizam pela capacidade de criar novos conteúdos, como textos, imagens ou código. Exemplos representativos incluem o *Generative Pre-trained Transformer* (GPT), da OpenAI, e o Gemini, do Google.


É pertinente assinalar que, apesar dos avanços notáveis, os modelos de IA Generativa mais robustos são intrinsecamente treinados em conjuntos de dados estáticos e de natureza geral. Consequentemente, estas arquiteturas não dispõem de acesso a informações em tempo real, nem a sistemas internos ou externos, tampouco possuem a capacidade inerente de executar ações. Para mitigar essa limitação, foi concebido o Protocolo de Contexto de Modelo (*Model Context Protocol*, MCP). Este protocolo estabelece uma metodologia padronizada para que os modelos de IA Generativa possam acessar diversos tipos de sistemas, seja para a obtenção de dados ou para a execução de ações específicas (Anthropic, 2024). A implementação do MCP, por exemplo, viabiliza o acesso a informações oriundas

de sistemas, as quais podem ser utilizadas como contexto para que a IA Generativa realize tarefas complexas como análise, correção, processamento ou a geração de relatórios.

Esses desenvolvimentos ampliaram de forma significativa as possibilidades de aplicação e a facilidade de desenvolvimento de soluções baseadas em IA (Felicetti *et al.*, 2024; Shoushtari; Daghighi; Ghafourian, 2024). Estudos indicam que organizações que incorporam IA em processos de gestão podem alcançar reduções de até 30% nos custos operacionais, com ganhos expressivos em agilidade e produtividade (McKinsey & Company, 2023). Projeções da Gartner também reforçam esse cenário ao estimar que, até 2030, cerca de 80% das tarefas rotineiras de monitoramento e controle de projetos poderão ser parcial ou totalmente automatizadas por soluções de IA (Gartner, 2019).

Evidências recentes do *GenAI Adoption Report* (Project Management Institute, 2024a) corroboram esse panorama ao mostrar que empresas classificadas como *Trailblazers* obtêm ganhos expressivos em cronograma (91%), escopo (87%), qualidade (85%) e custo (85%), em contraste com menos de 45% em empresas iniciantes (*Explorers*). Esses dados estão sintetizados na Figura 1, na qual é evidenciado o impacto da GenAI na eficiência e no desempenho global dos projetos.

Figura 1 – Impacto percebido da *GenAI* em fatores de desempenho de projetos: comparação entre *Explorers* e *Trailblazers*.



Fonte: Adaptado de Project Management Institute (Project Management Institute, 2024a).

1.1 Contextualização

A governança de projetos consolidou-se como mecanismo essencial para conectar a execução de iniciativas aos objetivos estratégicos das organizações. Em portfólios extensos,

com equipes distribuídas e prazos comprimidos, o processo decisório depende de informações tempestivas, comparáveis e auditáveis, materializadas no relatório executivo de status, artefato crítico para comitês diretivos avaliarem situação, desvios, riscos e decisões requeridas em cada ciclo (Project Management Institute, 2024b). A literatura gerencial e técnica aponta que, sem padrões claros de conteúdo e trilhas de evidência, a “tradução” entre realidade operacional e nível executivo permanece frágil, favorecendo assimetrias de informação (Felicetti *et al.*, 2024; Shoushtari; Daghighi; Ghafourian, 2024).

Historicamente, Escritórios de Projetos (*Project Management Offices*, PMOs) buscaram mitigar essa fragilidade com métodos e *templates*. Persistem, porém, três vetores estruturais que pressionam o *reporting*: (i) dispersão de dados em múltiplas ferramentas; (ii) heterogeneidade de formatos/qualidade (campos faltantes, versões concorrentes, atualizações assíncronas); e (iii) alto custo de coordenação para consolidar e padronizar o material para a alta gestão — fatores que conduzem a inconsistências e atrasos que corroem a confiança dos *stakeholders* (Felicetti *et al.*, 2024; Project Management Institute, 2024b).

A pressão competitiva por previsibilidade e agilidade elevou o patamar de exigência: não bastam quadros de situação; esperam-se narrativas explicáveis, com priorização de riscos/decisões e comparabilidade longitudinal entre ciclos (Project Management Institute, 2024b; Accenture, 2024a). Paralelamente, a dataficação dos processos ampliou o volume e a variedade de fontes (histórico de atividades, marcos, orçamento, alocação, RAID (Riscos, suposições, problemas e decisões) e atas). Sem regras explícitas sobre o que entra, com que granularidade e com qual vínculo de origem, a abundância de dados não se converte, por si só, em melhor governança (Felicetti *et al.*, 2024; Shoushtari; Daghighi; Ghafourian, 2024).

Do ponto de vista tecnológico, estudos setoriais destacam que a adoção de IA em processos de gestão tem gerado ganhos relevantes de produtividade e eficácia, com organizações redesenhando fluxos de trabalho para capturar valor (McKinsey & Company, 2023). Em gestão de projetos, projeções amplamente divulgadas estimam que uma parcela substancial das atividades de acompanhamento e controle poderá ser automatizada por IA até 2030 — movimento que, se bem governado, pode reduzir esforço manual sem abrir mão de transparência, explicabilidade e trilhas de auditoria no artefato de reporte (Gartner, 2019).

Em síntese, o contexto que motiva este estudo combina: (i) demanda crescente por qualidade da informação (clareza, comparabilidade e verificação de origem) no relatório executivo; (ii) custos e fragilidades de fluxos manuais e fragmentados; e (iii) oportunidades abertas por IA para melhorar padronização e rastreabilidade do *reporting*, sob princípios de *accountability* e conformidade.

1.2 Problema

Apesar da evolução dos *frameworks* de governança de projetos, como o PMBOK *Guide* (PMI, 2021) e da disseminação de práticas ágeis, um desafio persiste de forma recorrente: a ausência de automação e padronização na elaboração de relatórios de status. Em muitas organizações, essa atividade continua a ser realizada manualmente, de forma fragmentada, sujeita a inconsistências e a elevado esforço operacional. Esse cenário não apenas compromete a transparência e a rastreabilidade das informações, como também dificulta a antecipação de riscos e a tomada de decisão tempestiva pelos *stakeholders* estratégicos.

No contexto dos PMOs, os relatórios executivos são peças críticas de comunicação, mas sua elaboração consome tempo significativo e está exposta ao risco de desalinhamento entre o status declarado e as evidências que o sustentam. Isso favorece a subjetividade na interpretação e na comunicação, podendo refletir percepções individuais e não critérios objetivos. Essa lacuna decorre de fatores como heterogeneidade de formatos, ausência de integração entre sistemas, atrasos na atualização de registros e inexperiência de equipes operacionais. O resultado é a fragilização de princípios básicos de governança, como confiabilidade, auditabilidade e tempestividade, essenciais para ambientes corporativos dinâmicos e competitivos.

A literatura recente sobre a aplicação de Inteligência Artificial em gestão de projetos mostra avanços relevantes, como o uso de algoritmos de aprendizado de máquina para previsão de prazos e custos (Pal *et al.*, 2023), integração de IA a métodos ágeis (Zadeh; Khoulenjani; Safaei, 2024) e estudos sobre impactos organizacionais da GenAI (Felicetti *et al.*, 2024). Ainda assim, observa-se que tais pesquisas concentram-se em eficiência operacional, suporte à decisão ou otimização de processos, enquanto permanecem incipientes as soluções voltadas à automação de relatórios em governança de projetos.

O uso de IA Generativa tem se mostrado promissor para a geração de resumos e relatórios a partir de conteúdos ou contextos específicos. Entretanto, fatores como o acesso integrado a diferentes fontes e a rastreabilidade das evidências precisam ser considerados para viabilizar soluções de automação de relatórios executivos de governança de projetos.

1.3 Objetivos

Os objetivos desta pesquisa explicitam o propósito e a direção do estudo, traduzindo o problema em questão em um conjunto de entregáveis e resultados verificáveis no contexto de governança de projetos. Nesta seção, apresenta-se a formulação do objetivo geral e dos respectivos objetivos específicos que orientam o desenvolvimento desse trabalho.

1.3.1 Objetivo Geral

Desenvolver e formalizar um protocolo de *reporting* rastreável (*Traceable Governance Reporting Protocol*, TGRP) para relatórios executivos de governança de projetos em formato narrativo, compatível com a orquestração por LLMs via MCP e com saída estruturada interoperável. O TGRP se fundamenta em quatro pilares:

- (i) padronização do conteúdo;
- (ii) rastreabilidade de evidências por citações com ponteiros canônicos;
- (iii) segregação entre fatos e opinião técnica;
- (iv) critérios de conformidade, auditabilidade e interoperabilidade.

1.3.2 Objetivos Específicos

Os objetivos específicos a seguir decompõem o objetivo geral em frentes de trabalho, organizadas em ordem lógica de execução. Cada objetivo descreve o que será entregue e com quais características, servindo como mapa de implementação e base para avaliação posterior.

1) Protótipo mínimo viável (*Minimum Viable Product*, MVP) para validação do TGRP.

- a) Implementar um pipeline baseado em LLMs integrados via MCP para gerar automaticamente as seções previstas no TGRP;
- b) Produzir sumário executivo ancorado em evidências, indicando lacunas informacionais quando houver;
- c) Reportar variações de prazo a partir da integração entre *milestones*, atividades e histórico;
- d) Reportar variações de custo (orçamento), com desvios planejado versus realizado;
- e) Reportar variações de recursos, cruzando plano de alocação, disponibilidade e custo/hora;
- f) Elencar *Top-5 riscos* com justificativas; incluir riscos sugeridos quando houver indícios objetivos;
- g) Consolidar problemas e decisões pendentes (RAID/atas);
- h) Calcular o *Status-Schedule-Trend* (SST) por regra objetiva, sempre justificado por notas;
- i) Emitir parecer do *Assistente Virtual de Governança* em bloco próprio, com diagnóstico e recomendações baseados em sinais objetivos.

2) Projetar Esquema de dados e renderização dos resultados.

- a) Definir a saída estruturada (p.ex., *Markdown*) apta à renderização para *PowerPoint* (PPT) ou *Portable Document Format* (PDF) e integrações.

3) Viabilizar auditoria e reprodutibilidade.

- a) Registrar trilha de auditoria (enunciado → ID de evidência → ponteiro) e metadados técnicos (versão de modelo, *template*, parâmetros).

1.4 Organização do Texto

Este trabalho foi organizado da seguinte forma: o **Capítulo 1** contextualiza o tema, explicita o problema, os objetivos e o escopo do estudo. O **Capítulo 2** sintetiza conceitos, modelos e estudos correlatos que fundamentam a proposta, delimitando lacunas e oportunidades identificadas na literatura. O **Capítulo 3** descreve a metodologia adotada, baseada no modelo CRISP-DM, detalhando as etapas de planejamento, entendimento e preparação dos dados, modelagem, avaliação e critérios de verificação. O **Capítulo 4** expõe a solução proposta, incluindo a arquitetura e o fluxo do protótipo (MVP), bem como a documentação da aplicação e os principais achados e resultados obtidos. Por fim, o **Capítulo 5** apresenta as conclusões do trabalho, resumindo suas contribuições e limitações, além de indicar desdobramentos práticos e possíveis implementações futuras.

2 REFERENCIAL TEÓRICO E REVISÃO BIBLIOGRÁFICA

O referencial teórico tem como objetivo apresentar os conceitos, fundamentos e estudos que sustentam a proposta desenvolvida neste trabalho. A revisão da literatura contempla, inicialmente, as bases da governança de projetos e os desafios enfrentados pelos PMOs, com destaque para as dificuldades relacionadas à consolidação e padronização de relatórios gerenciais. Em seguida, discute-se a aplicabilidade da Inteligência Artificial na governança de projetos, com foco na automação e na melhoria da comunicação entre *stakeholders*. Na sequência, são explorados os LLMs como ferramentas para automação, seus fundamentos técnicos e usos práticos. Também são apresentados estudos recentes sobre os impactos da IA na gestão de projetos e, por fim, estratégias que potencializam a utilização dos LLMs no contexto da governança, incluindo personalização, integração com ferramentas de gerenciamento, análise preditiva e automação da comunicação.

2.1 Governança de Projetos e Seus Desafios

A governança de projetos é um dos pilares fundamentais para assegurar que as organizações consigam alinhar suas iniciativas estratégicas aos objetivos institucionais. Segundo o Project Management Institute (Project Management Institute, 2021), a governança envolve estruturas, processos e mecanismos que garantem a integridade da gestão e a entrega de valor. Em linhas gerais, trata-se de um sistema que assegura transparência, responsabilidade e eficiência em todas as etapas do ciclo de vida dos projetos. Nesse contexto, os relatórios de status assumem papel central, pois permitem que gestores e *stakeholders* acompanhem de maneira clara o desempenho em termos de prazos, custos, escopo e qualidade. (Kerzner, 2025) complementa essa visão ao afirmar que a maturidade em gestão de projetos depende não apenas da adoção de *frameworks*, mas também da capacidade de padronizar processos de comunicação e integrar informações em relatórios confiáveis. Da mesma forma, o PRINCE2 (AXELOS Limited, 2017) reforça a necessidade de relatórios estruturados e a definição clara de papéis e responsabilidades para assegurar uma governança eficaz. No entanto, embora existam metodologias amplamente difundidas, o *Pulse of the Profession 2024* (Project Management Institute, 2024b) revelou que apenas 73,8% dos projetos alcançam seus objetivos iniciais, e falhas de comunicação continuam entre as principais causas de insucesso, um dado consistente em diversos relatórios anuais do PMI. Esses dados evidenciam que os relatórios continuam sendo um dos maiores desafios para os PMOs, uma vez que a falta de padronização e a fragmentação das informações comprometem a tomada de decisão estratégica.

2.2 Aplicabilidade da Inteligência Artificial na Governança de Projetos

A Inteligência Artificial (IA) tem se consolidado como uma ferramenta de transformação em diversos setores da economia, e sua aplicação na governança de projetos desponta como uma das tendências mais relevantes. Russell, Russell e Norvig (2020) definem IA como o campo da ciência da computação voltado ao desenvolvimento de sistemas capazes de executar tarefas que, de outra forma, exigiriam inteligência humana. No contexto de projetos, isso significa a possibilidade de automatizar relatórios, analisar grandes volumes de dados históricos e prever cenários de risco com maior precisão. Além de agilizar processos, a IA pode aumentar a confiabilidade das informações, reduzir erros humanos e liberar gestores para atividades de caráter mais estratégico.

Estudos recentes demonstram que os benefícios da IA já estão sendo sentidos pelas organizações. A Accenture (2024a) aponta que 74% das empresas que implementaram soluções de IA em seus processos de governança relataram ganhos expressivos em produtividade. A Gartner (2019), por sua vez, projeta que até 2030, 80% das tarefas rotineiras de monitoramento e controle em projetos serão parcial ou totalmente automatizadas por soluções de IA. Esses dados confirmam que a aplicação da IA não é apenas uma tendência futura, mas uma realidade em construção, com potencial para revolucionar a forma como relatórios são produzidos e utilizados na governança de projetos. Contudo, é importante reconhecer que a adoção da IA deve vir acompanhada de mecanismos robustos de governança de dados, a fim de mitigar riscos relacionados a viés, privacidade e confiabilidade das informações.

Exemplos do uso de IA na governança de projetos podem ser observados em aplicações para a previsão de prazo e custos de projetos, e análise de relatórios para a identificação de risco. Por exemplo, em ForouzeshNejad, Arabikhan e Ahelerooff (2024), técnicas de aprendizado supervisionado (como XGBoost) combinadas à otimização por *Simulated Annealing* foram utilizadas para estimar tempo e custo de projetos, obtendo ganhos de acurácia preditiva frente a abordagens tradicionais e oferecendo insumos objetivos para baseline, contingência e priorização de frentes no processo de governança. Já em Gao *et al.* (2024), métodos de Processamento de Linguagem Natural com contexto de múltiplas sentenças (*multi-sentence context-aware*) têm sido empregados para extrair e rotular sentenças de risco. Nessa abordagem, a sentença-alvo é classificada à luz das sentenças vizinhas (anteriores e/ou posteriores), uma vez que a configuração de risco costuma estar distribuída no texto — por exemplo, uma sentença descreve o evento incerto e outra explicita seu impacto em custo e/ou cronograma. Modelos como o *Multi-sentence Context-aware Risk Identification* (MCRI) reportam ganhos de desempenho ao incorporar esse contexto, acelerando a triagem, ampliando a visibilidade de riscos recorrentes e fornecendo insumos estruturados para o registro RAID e para a pauta de decisões — sem substituir o relatório executivo, mas alimentando-o com evidências textuais citáveis.

Em síntese, a aplicabilidade da IA na governança de projetos é mais efetiva quando as soluções reduzem esforço manual e elevam a qualidade da informação do artefato de governança — em especial, quando preservam vínculo claro com a origem dos dados, regras explícitas para cálculo/rotulagem e princípios de conformidade (proteção de dados e prestação de contas). Os exemplos apresentados reforçam essa direção ao mostrar ganhos práticos sem abrir mão de explicabilidade e rastreabilidade.

2.3 Modelos de Linguagem de Grande Escala (LLMs) como Ferramenta para Automação

Nesta seção, são apresentados os fundamentos conceituais dos LLMs, sua evolução arquitetural e as aplicações potenciais no apoio à governança de projetos. Também são analisados padrões emergentes que ampliam a utilidade prática desses modelos, como o Retrieval-Augmented Generation (RAG), voltado à recuperação de evidências, e o MCP, concebido para padronizar a interação entre LLMs, dados e ferramentas externas. O objetivo é oferecer uma compreensão integrada desses conceitos, estabelecendo a base teórica necessária para compreender a modelagem proposta nos capítulos seguintes.

2.3.1 Fundamentos dos Modelos de Linguagem

Um modelo de linguagem pode ser definido, em termos probabilísticos, como um sistema que calcula a probabilidade de uma palavra ocorrer dado o contexto das palavras anteriores, ou palavras próximas, permitindo prever a próxima palavra em uma sequência ou uma palavra central dadas as palavras próximas (Jurafsky; Martin, 2025). Essa formulação básica sustenta aplicações como corretores ortográficos, tradutores automáticos e, em estágios mais avançados, sistemas de processamento e geração de linguagem natural. O treinamento desses modelos exige o uso de corpora — grandes coleções de textos — que funcionam como base de dados para aprendizado. Esses corpora podem ser compostos por notícias, artigos científicos, páginas da web ou transcrições de diálogos. Quanto mais amplos e diversos, maior a cobertura de vocabulário e estilos linguísticos, permitindo ao modelo aprender padrões gerais da língua e diferentes formas de expressão.

Os primeiros avanços relevantes aconteceram com os modelos Word2Vec (Mikolov *et al.*, 2013) e GloVe (Pennington; Socher; Manning, 2014). Essas abordagens representavam palavras como vetores em um espaço contínuo, possibilitando capturar relações semânticas (como “rei – homem + mulher $\approx$ rainha”). Contudo, ainda eram limitadas para lidar com relações que dependiam de partes mais distantes de um texto, além de serem independentes de contexto. Por exemplo, há um único vetor para representar a palavra “banco”, seja em contexto de sistema bancário, seja em contexto de mobília.

O salto qualitativo aconteceu em 2017, com a introdução da arquitetura *Transformer* (Vaswani *et al.*, 2017). Diferentemente das Redes Neurais Recorrentes (RNNs) e das

LSTMs (Long Short-Term Memory), que processavam palavras de forma sequencial, os *Transformers* utilizam o mecanismo de atenção (*attention mechanism*) para analisar todas as palavras de uma sequência em paralelo, atribuindo pesos de relevância entre cada par de *tokens*. Isso permitiu capturar dependências de longo alcance no texto, ou seja, relações entre termos que não estão próximos entre si. Por exemplo, em “O João pegou o livro. Ele foi para a biblioteca”, o modelo precisa conectar “ele” a “João”, ainda que apareçam em frases distintas. Esse recurso aumentou tanto a eficiência do treinamento quanto a qualidade da interpretação semântica. Vale ressaltar que nos *transformers*, também são aprendidas as representações vetoriais das palavras, porém, aqui, dependentes de contexto, ou seja, uma palavra pode ter uma representação diferente a depender das palavras ao redor.

A partir do *Transformer*, consolidaram-se três linhas arquiteturais principais no Processamento de Linguagem Natural (*Natural Language Processing*, NLP):

- **Encoder-only:** essa configuração utiliza apenas a parte de codificação do *Transformer*. O *encoder* lê todo o texto de entrada de forma bidirecional, isto é, considera tanto as palavras anteriores quanto as posteriores para calcular representações contextuais (*embeddings*). O resultado é um vetor denso que capta o significado do texto como um todo, sendo usado em tarefas de compreensão e análise semântica. Exemplos práticos incluem classificação de sentimentos (positivo/negativo), detecção de spam, busca semântica (recuperar documentos relevantes) e resposta a perguntas factuais curtas. O modelo mais conhecido dessa família é o *BERT* (*Bidirectional Encoder Representations from Transformers*) (Devlin *et al.* (2019)), que se tornou referência para tarefas de NLP baseadas em interpretação de texto.
- **Decoder-only:** essa arquitetura utiliza apenas a parte de decodificação do *Transformer*. Muitos modelos que utilizam essa arquitetura aplicam uma abordagem autorregressiva, isto é, a cada passo, o modelo prevê a próxima palavra com base nas palavras anteriores. Isso a torna ideal para tarefas de geração de linguagem natural, como redação de textos, criação de diálogos, composição de código ou elaboração de resumos. Exemplos de aplicações incluem *chatbots*, assistentes virtuais, sistemas de apoio à redação e modelos de geração de código. Dentro dessa categoria estão os *GPTs* (*Generative Pre-trained Transformers*) (Radford *et al.* (2018); Bubeck *et al.* (2023)), bem como modelos recentes como *Gemini* (Google DeepMind), *Claude* (Anthropic, 2024) e *LLaMA* (Meta, 2023).
- **Encoder-decoder:** aqui, o *encoder* processa o texto de entrada e o transforma em uma representação vetorial, que em seguida é passada ao *decoder*, responsável por gerar a sequência de saída. Essa arquitetura é voltada para transformação de textos, em que um tipo de sequência é convertido em outro. Aplicações clássicas incluem

tradução automática (de um idioma a outro), sumarização de documentos longos e resposta a perguntas complexas. O modelo mais emblemático é o *T5 (Text-to-Text Transfer Transformer)* (Raffel *et al.* (2020)), cuja inovação foi propor que todas as tarefas de NLP fossem formuladas como “texto de entrada $\rightarrow$ texto de saída”. Por exemplo, a tarefa de tradução pode ser representada como “Traduza do inglês para o português: *The book is on the table*”, enquanto uma tarefa de classificação pode ser formulada como “Esse texto é positivo ou negativo?”. Essa abordagem unificada facilitou o reuso do modelo em múltiplas tarefas.

Com o aumento exponencial do poder computacional e a disponibilidade de grandes bases de dados, esses modelos escalaram para bilhões e até trilhões de parâmetros, originando os atuais LLMs. Além de gerar texto coerente, esses modelos passaram a exibir capacidades emergentes, como raciocínio lógico, interpretação de instruções complexas e até geração de código (Bubeck *et al.*, 2023). Tais avanços ampliaram o campo de aplicação da IA para além da automação simples, abrindo espaço para funções de apoio estratégico. Em síntese, os Modelos de Linguagem de Grande Escala representam a evolução natural da área de NLP, desde embeddings distribuídos até arquiteturas *Transformer* e suas variantes (*encoder*, *decoder* e *encoder-decoder*). Esse percurso explica por que os LLMs se tornaram centrais tanto para a pesquisa acadêmica quanto para aplicações corporativas contemporâneas.

2.3.2 LLMs como Ferramentas para Automação

A aplicação de LLMs em ambientes corporativos tem se mostrado promissora, especialmente em tarefas que envolvem análise e geração de texto (Chiarello *et al.*, 2024). Esses modelos podem apoiar a elaboração de relatórios de status, sumarizar atas de reuniões, padronizar comunicações e até gerar recomendações automáticas para gestores. Organizações como Microsoft e Google já vêm implementando assistentes baseados em LLMs em suas plataformas de produtividade, conhecidos como *copilots*, que auxiliam no dia a dia de profissionais em diversas áreas. No contexto específico da governança de projetos, os LLMs podem desempenhar um papel estratégico. A integração com arquiteturas de *Retrieval-Augmented Generation* (RAG) permite que os modelos acessem bases internas de dados de projetos, como cronogramas, riscos e indicadores financeiros, para gerar relatórios confiáveis e alinhados à realidade da organização. Além das arquiteturas de RAG, surgem padrões de integração que organizam o acesso do LLM a dados e ferramentas corporativas. O MCP padroniza essa interação (dados como “recursos”, funções como “ferramentas” e “*prompts*” versionáveis), oferecendo uma “porta única” para o agente acessar contexto e executar ações com governança e auditabilidade, sem substituir o RAG — que pode operar como um dos serviços expostos via MCP.

2.3.3 *Model Context Protocol* (MCP): Fundamentos e Arquitetura

O MCP é um padrão aberto que organiza a interação entre LLMs e sistemas externos, como arquivos, bancos de dados e APIs, oferecendo uma camada de abstração que promove interoperabilidade, modularidade e governança do contexto. Sua principal finalidade é reduzir a fragmentação das integrações proprietárias, ao estabelecer um contrato universal para acesso a dados e execução de operações independente de quem forneça o modelo ou a ferramenta (Anthropic, 2024).


A arquitetura do MCP segue um paradigma cliente/servidor, projetado para permitir que aplicações de inteligência artificial interajam de maneira padronizada e eficiente com serviços externos que fornecem dados ou funcionalidades. O modelo define uma clara separação de responsabilidades, dividindo o sistema em três participantes-chave, cada um com uma função distinta e especializada. Os componentes fundamentais da arquitetura MCP são:

- **Host MCP:** Este é o componente central da arquitetura e representa a própria aplicação de inteligência artificial (por exemplo, um agente de IA, um assistente virtual ou uma IDE com IA integrada). Sua principal responsabilidade é coordenar e gerenciar a operação de um ou mais clientes MCP. O *Host MCP* atua como a interface principal para o usuário e o orquestrador das tarefas que exigem acesso a recursos externos.
- **Cliente MCP:** É um módulo ou componente interno do Host MCP. Ele é responsável por estabelecer e manter uma conexão dedicada e individual com um servidor MCP específico. Sua função é atuar como uma ponte, obtendo o "contexto", ou seja, os dados e funcionalidades externas, que o *Host MCP* precisa para operar. Cada cliente mantém uma conexão unívoca com seu respectivo servidor, garantindo a comunicação direta e segura.
- **Servidor MCP:** É um programa ou serviço externo que expõe um conjunto de dados ou funcionalidades específicas. Ele atua como um conector, dando acesso a recursos que residem fora do ambiente da aplicação de IA, como bancos de dados, APIs de terceiros ou serviços de automação. Sua especialidade é lidar com a complexidade do mundo externo, fornecendo o "poder" necessário para o *Host MCP*.

A operação da arquitetura MCP se baseia em um processo de especialização de funções: o Servidor MCP lida com a tarefa complexa de acessar ou executar algo no mundo externo, enquanto o *Host MCP* se concentra em integrar e utilizar esse poder no modelo de IA. A comunicação entre o cliente e o servidor é bidirecional e segura, utilizando chamadas de procedimento remoto (*Remote Procedure Call*, RPC) padronizadas. Esse formato estruturado garante que todos os participantes "falem a mesma língua",

independentemente da linguagem de programação ou plataforma utilizada. Esse arranjo pode ser visualizado na Figura 2, que ilustra a relação entre host, clientes e servidores MCP em conexões um-para-um.

Figura 2 – Arquitetura conceitual do Model Context Protocol (MCP).



Fonte: Elaborado a partir de Model Context Protocol (Anthropic, 2024). Elaboração própria.

Um dos conceitos elementos fundamentais do MCP são as Primitivas que são o conjunto de capacidades que um Servidor MCP expõe a um Cliente MCP e vice-versa. Em termos didáticos, elas são os blocos de construção que definem o que a aplicação de Inteligência Artificial (Host MCP) pode efetivamente solicitar e manipular no mundo externo. As primitivas são classificadas em três categorias distintas:

- ***Tools (Ferramentas)***: São definidas como as ações ou funções que o Servidor MCP pode executar em nome da aplicação de IA. Elas representam a capacidade de execução e intervenção no ambiente externo. O Host MCP solicita ao modelo que utilize uma Tool específica. O Cliente MCP envia a requisição ao Servidor MCP, que processa a ação (como por exemplo uma chamada de API, enviar uma mensagem ou executar um script) e retorna o resultado padronizado para o Cliente MCP.
- ***Resources (Recursos)***: É dedicada à consulta de contexto e dados. *Resources* representam as estruturas de informação disponibilizadas pelo Servidor MCP, que podem ter origem em dados estáticos (como o conteúdo de arquivos e documentos) ou dados dinâmicos, gerados em tempo real através de consultas a bancos de dados ou APIs externas.
- ***Prompts (Instruções)***: Definem *templates* de instrução ou fluxos de trabalho reutilizáveis que o Servidor MCP expõe ao Cliente. Eles encapsulam uma sequência predefinida de ações ou um formato específico de saída.

Essa padronização da comunicação e a divisão clara de papéis reduzem drasticamente a complexidade de desenvolvimento e de integração, permitindo que qualquer aplicação que siga o protocolo se conecte a qualquer serviço MCP compatível de forma fluida.

2.4 Estudos Recentes e Impactos da IA na Gestão de Projetos

Nos últimos anos, a aplicação da Inteligência Artificial na gestão de projetos tem ganhado destaque em relatórios de institutos de pesquisa, consultorias e publicações acadêmicas. O *GenAI Adoption Report* (Project Management Institute, 2024a) é um marco nesse sentido, por apresentar evidências de como organizações em diferentes estágios de adoção da *GenAI* percebem seus impactos nos projetos. As empresas classificadas como *Trailblazers*, aquelas que utilizam intensivamente a IA, reportaram melhorias significativas em indicadores clássicos de desempenho: 91% relataram ganhos em cronograma, 87% em escopo, 85% em qualidade e 85% em custo. Em contrapartida, empresas *Explorers*, em estágio inicial de adoção, apresentaram resultados inferiores a 45% nesses mesmos aspectos. Além disso, os *Trailblazers* destacaram ganhos expressivos em fatores humanos, como produtividade (93%), criatividade (84%), colaboração (83%) e eficácia (88%).

Outras fontes confirmam e complementam essas estatísticas. A McKinsey & Company (2023) indica que a adoção de IA em processos de gestão pode reduzir custos operacionais em até 30% e ampliar substancialmente a agilidade organizacional. A Accenture (2024a) aponta que 74% das organizações que implementaram IA em governança relataram ganhos expressivos em produtividade. A Gartner (2019) projeta que até 2030, cerca de 80% das tarefas rotineiras de monitoramento e controle em projetos serão parcial ou totalmente automatizadas por IA, transformando a forma como os escritórios de projetos operam. Já a Harvard Business Review (2023) destaca que a *GenAI* não apenas melhora indicadores de desempenho, mas também promove maior criatividade e colaboração entre equipes, contribuindo para uma gestão mais inovadora e colaborativa. Na Tabela 1 é apresentado um resumo dos benefícios do uso de IA nas empresas segundo as fontes utilizadas neste trabalho.

A diversidade de fontes mostra que há um consenso emergente entre academia, institutos de pesquisa e mercado: a IA, e em particular a *GenAI*, está redefinindo a forma como os projetos são planejados, monitorados e executados. Ao mesmo tempo, os dados ressaltam que os maiores ganhos não se limitam a eficiência operacional, mas também abrangem dimensões humanas, como criatividade, colaboração e engajamento das equipes. Para este trabalho, esses estudos oferecem evidências sólidas de que a adoção de LLMs para automação de relatórios pode gerar impactos reais e relevantes na governança de projetos.

Tabela 1 – Síntese dos benefícios reportados por diferentes fontes sobre o uso de IA na gestão de projetos.

Fonte		Benefícios Reportados	Observações
Project Management Institute (2024a) – <i>GenAI Adoption Report</i>		Melhorias em cronograma (91%), escopo (87%), custo (85%), qualidade (85%); ganhos em produtividade (93%).	Pesquisa global com profissionais de projetos.
McKinsey & Company (2023)		Redução de até 30% nos custos operacionais; ganhos em agilidade.	Relatório sobre impacto da IA em negócios.
Accenture (2024a)		74% das organizações reportaram aumento de produtividade.	Estudo sobre governança e IA.
Gartner (2019)		Até 80% das tarefas de PM serão automatizadas até 2030.	Projeção de tendências globais.
Harvard Business Review (2023)		GenAI estimula criatividade e colaboração em equipes de projetos.	Evidências qualitativas de aplicação prática.

Fonte: elaborado pela autora.

2.5 Estratégias para Potencializar o Uso de LLMs na Governança de Projetos

A aplicação de LLMs na governança de projetos pode ser maximizada por meio de estratégias específicas que ampliem a confiabilidade, a usabilidade e o impacto organizacional. Entre as principais práticas, destacam-se a personalização dos modelos, a integração com ferramentas de gerenciamento, o uso de análise preditiva para gestão de riscos e a automação da comunicação com *stakeholders*. Neste trabalho, tais estratégias são viabilizadas por uma arquitetura baseada no MCP, que padroniza como o LLM acessa os recursos (dados), aciona ferramentas (funções) e utiliza prompts versionados com trilhas de auditoria e neutralidade tecnológica. Diferentemente de abordagens baseadas exclusivamente em recuperação de trecho, o MCP provê uma “porta única” governável para dados e operações, podendo incluir, quando conveniente, serviços de recuperação como mais um servidor MCP.

2.5.1 Personalização de Modelos de IA

A personalização consiste em adaptar os LLMs ao contexto específico da organização, utilizando dados históricos e documentos internos. Essa estratégia permite que os modelos incorporem terminologias próprias, padrões de relatórios e práticas de governança específicas de cada PMO.

Quando aplicada em conjunto com a arquitetura baseada no MCP, a personalização se torna ainda mais eficaz. O modelo, além de ajustado ao vocabulário da organização, passa a acessar recursos internos confiáveis expostos via MCP, como relatórios passados,

registros de riscos e lições aprendidas. Isso aumenta a precisão na geração de relatórios de status e assegura que as recomendações sejam contextualizadas com base em dados reais, fortalecendo a confiabilidade das informações apresentadas aos *stakeholders*.

2.5.2 Integração com Ferramentas de Gerenciamento

Outra estratégia essencial é integrar os LLMs às ferramentas corporativas já utilizadas em PMO, a sistemas de gestão de demandas em quadro *kanban*, a sistemas de cronograma e a plataformas corporativas de BI. Por meio de APIs, é possível conectar os modelos a essas plataformas, permitindo que consolidem informações de cronogramas, orçamentos e indicadores de desempenho em relatórios automáticos.

O uso do MCP amplia ainda mais o potencial dessa integração. Ao expor dados e operações dessas ferramentas como recursos e ferramentas padronizados, o modelo pode gerar relatórios atualizados e contextualizados, garantindo rastreabilidade e transparência. Por exemplo, um gerente de projetos poderia solicitar ao assistente virtual um resumo do status de um programa estratégico, e o LLM, via MCP, acessaria, por exemplo, soluções de gestão como o Jira e/ou plataformas de BI como o *Power BI* para consolidar automaticamente cronogramas, riscos e indicadores financeiros.

2.5.3 Análise Preditiva e Gestão de Riscos

A análise preditiva é uma das aplicações mais estratégicas da IA em projetos, pois permite antecipar atrasos, identificar sobrecarga de recursos e prever potenciais desvios de custo e qualidade. Nesse contexto, a utilização de dados históricos como parte do contexto do *prompt* da LLM, ou ainda por meio de processos de *fine-tuning* com registros anteriores da organização, possibilita que o modelo aprenda padrões de desempenho e extraia sinais relevantes para prever cenários futuros. Ao considerar registros de atrasos passados, indicadores de produtividade e métricas financeiras, por exemplo, o modelo pode não apenas projetar riscos potenciais, mas também gerar relatórios explicativos com recomendações práticas. Dessa forma, a gestão de riscos deixa de ser uma atividade reativa e passa a assumir caráter estratégico, apoiando a maturidade da governança.

2.5.4 Automação de Comunicação e Assistência Virtual

A comunicação é um dos principais fatores críticos de sucesso em projetos, mas também uma das maiores causas de insucesso, como mostra o relatório *Pulse of the Profession* (Project Management Institute, 2023). Nesse sentido, a automação da comunicação por meio de LLMs apresenta grande potencial de impacto. Assistentes virtuais podem apoiar a elaboração de atas, responder a dúvidas de stakeholders em linguagem natural e enviar notificações automáticas sobre mudanças em cronogramas ou riscos.

Quando integrados ao MCP, esses assistentes virtuais deixam de depender de respostas genéricas e passam a consultar diretamente recursos confiáveis dos sistemas corporativos e acionar ferramentas autorizadas. Isso significa que um diretor, por exemplo, pode solicitar um relatório de status atualizado e o assistente virtual gerará o documento com base em dados reais de sistemas como cronogramas e bases corporativas de BI. Além de aumentar a agilidade e reduzir ruídos de comunicação, essa abordagem fortalece a transparência e a confiança entre os diferentes níveis da organização. Diferentemente de respostas genéricas, a geração condicionada por dados e operações expostos via MCP, com citações/ponteiros automáticos, reforça explicabilidade e trilhas de auditoria, atributos essenciais para a governança.

2.6 Lacunas e Posicionamento deste Estudo

A literatura recente sobre IA em gestão de projetos enfatiza ganhos de produtividade e comunicação, além de desafios de dados, explicabilidade e adoção. Todavia, permanece subexplorado o recorte específico de *reporting* de governança com rastreabilidade verificável da origem em formato narrativo (*storytelling*). Este estudo se posiciona exatamente nesse vazio: não busca apenas “acelerar” o *status report*, mas estabelecer um protocolo reproduzível de conteúdo e evidência que reduza o descompasso entre o que se declara e o que está documentado.

Como resposta prática, o trabalho formaliza o TGRP e demonstra sua orquestração por MCP que será descrita com mais detalhes no Capítulo 4 deste trabalho. Em síntese, a contribuição não é “mais um gerador de texto”, mas um padrão de *reporting* rastreável implementado em MVP, que concilia padronização, transparência e auditabilidade sem impor dependência tecnológica ao PMO.

3 PANORAMA DE MERCADO, INVESTIMENTOS E RESULTADOS ESPERADOS

A aceleração da transformação digital nas organizações tem reforçado a importância da adoção de tecnologias baseadas em inteligência artificial (IA), especialmente aquelas que auxiliam na automação de processos operacionais e no suporte à tomada de decisão. Nesse cenário, a governança de projetos, função estratégica dentro das empresas, ainda enfrenta desafios significativos quanto à geração de informações consistentes, atualizadas e acessíveis. Relatórios manuais, falta de padronização e ausência de indicadores preditivos reduzem a eficiência dos PMOs e comprometem a gestão do portfólio. LLMs, quando estruturados em uma arquitetura baseada no MCP, surgem como uma alternativa poderosa e acessível para organizações que buscam evoluir sem depender de grandes orçamentos ou estruturas técnicas complexas. Esse diferencial torna possível levar automação inteligente, padronização dos processos de governança em empresas de médio porte, um segmento muitas vezes negligenciado pelas soluções tradicionais de mercado.

Segundo a Bloomberg Intelligence (2024), o mercado global de inteligência artificial generativa deve movimentar cerca de US\$ 1,3 trilhão em receitas até 2032, abrangendo hardware, software e serviços, com destaque para a expansão de soluções baseadas em modelos de linguagem de larga escala (LLMs) e o uso crescente de infraestruturas em nuvem por grandes provedores tecnológicos. Relatórios da Accenture (2024b) indicam que empresas que adotaram IA em processos de apoio à gestão de projetos obtiveram até 30% de redução de custos operacionais, 25% de aumento de produtividade e melhorias expressivas na análise de riscos e de *compliance*. Esses números evidenciam que a IA não é mais uma tendência futura, mas uma ferramenta essencial no presente para entregar eficiência e assertividade nas operações corporativas.

3.1 Business Model Canvas

O Business Model Canvas (BMC) é uma ferramenta de planejamento estratégico amplamente utilizada para representar de forma integrada e visual os principais elementos de um modelo de negócio. Segundo Osterwalder e Pigneur (2011), o Canvas possibilita que gestores e empreendedores compreendam como uma organização cria, entrega e captura valor, estruturando a proposta de forma sistemática em nove blocos. Ao aplicá-lo ao presente trabalho, torna-se possível organizar os aspectos centrais do modelo de negócio proposto, que tem como foco o desenvolvimento de um assistente virtual baseado em LLMs orquestrado via MCP, voltado à automação de relatórios de governança de projetos.

3.1.1 Proposta de Valor

A proposta de valor está fundamentada na oferta de uma solução inovadora de automação de relatórios de governança de projetos, capaz de reduzir o esforço manual dos gestores e aumentar a precisão e a padronização das informações. Por meio da integração entre LLM orquestrados via MCP, o sistema busca consolidar dados dispersos e gerar relatórios consistentes, claros e rastreáveis. Isso permite que os profissionais de projetos dediquem menos tempo à coleta e formatação de informações e mais tempo à análise estratégica e à tomada de decisão.

Além disso, o diferencial competitivo reside na confiabilidade e na transparência do processo. O uso do MCP padroniza o acesso a dados e ferramentas corporativas (p.ex., cronogramas, indicadores, atas), garantindo consultas a fontes internas atualizadas com rastreabilidade e controle de permissões, mitigando riscos de inconsistência ou informações genéricas. Segundo o *GenAI Adoption Report* (Project Management Institute, 2024a), organizações classificadas como *trailblazers* já colhem ganhos de 93% em produtividade e 88% em eficácia na gestão de projetos, o que reforça a relevância e o potencial da proposta apresentada.

Outro dos principais diferenciais é a rastreabilidade: cada afirmação do relatório é acompanhada de citação explícita de origem (por exemplo, item de *backlog*, trecho de ata), elevando transparência e confiança dos comitês decisórios.

3.1.2 Segmentos de Clientes

Os segmentos de clientes contemplados pelo modelo incluem escritórios de projetos PMOs de grandes corporações, consultorias especializadas em governança e gestão, e órgãos públicos que lidam com portfólios de projetos de grande porte. Essas organizações enfrentam desafios recorrentes de padronização e confiabilidade na comunicação com *stakeholders*, o que torna a solução proposta particularmente atrativa, especialmente quando a solução reduz dependência de integrações ponto-a-ponto ao adotar o MCP como camada padrão de acesso a dados e ferramentas.

Empresas de médio porte em setores intensivos em projetos, como tecnologia, energia, saúde e construção civil, também representam um mercado promissor. De acordo com o relatório *The State of AI: How Organizations Are Rewiring to Capture Value* McKinsey & Company (2025a), empresas que lideram a adoção de inteligência artificial reportam ganhos significativos em eficiência operacional e qualidade das decisões estratégicas, especialmente à medida que reestruturam fluxos de trabalho e ampliam o uso de modelos generativos. Esses resultados evidenciam que há uma base sólida de mercado interessada em ferramentas que melhorem a governança de projetos de forma prática e mensurável.

3.1.3 Canais

A distribuição da solução poderá ocorrer por meio de uma plataforma SaaS (*Software as a Service*), acessível em nuvem, o que permite escalabilidade e flexibilidade de uso. Esse modelo é amplamente consolidado em soluções corporativas e facilita a adoção por parte de empresas de diferentes portes.

Além disso, a integração via MCP com ferramentas já utilizadas em PMOs, como MS Project, Jira e Power BI, representa um canal estratégico de entrega, aumentando a aderência do produto ao ecossistema corporativo. Parcerias com consultorias de gestão, como PwC, EY e Deloitte, podem potencializar a penetração no mercado, já que essas organizações atuam diretamente na implementação de soluções de governança em clientes de grande porte.

3.1.4 Relacionamento com Clientes

O relacionamento com os clientes será estruturado em dois níveis. O primeiro envolve suporte consultivo durante a fase de implementação, garantindo a configuração adequada do modelo às necessidades de cada organização. Esse processo inclui treinamentos, *workshops* e acompanhamento próximo dos times de PMOs, para assegurar a correta adoção e integração da solução às práticas existentes.

O segundo nível contempla um relacionamento contínuo, apoiado por canais híbridos de atendimento. Além do suporte humano especializado, o modelo prevê a disponibilização de um *chatbot* baseado em LLM para dúvidas frequentes, relatórios de suporte e assistência em tempo real. Essa abordagem híbrida contribui para reduzir custos de suporte e, ao mesmo tempo, fortalece a experiência do cliente, criando um ciclo de confiança e fidelização.

3.1.5 Fontes de Receita

O modelo de negócio prevê múltiplas fontes de receita, com base em práticas consolidadas no mercado de SaaS. A principal forma será a assinatura mensal ou anual por usuário, permitindo receitas recorrentes e previsíveis. Além disso, será oferecido um modelo de licenciamento corporativo com base no número de projetos ativos monitorados pela solução, adequado para grandes empresas que buscam escalabilidade.

Outras formas de receita incluem a adoção de um modelo *freemium*, em que funcionalidades básicas seriam gratuitas para atrair novos clientes, enquanto recursos avançados estariam disponíveis apenas em planos pagos. Também será possível monetizar serviços de consultoria associados ao *fine-tuning* e à personalização do modelo de IA para contextos específicos. De acordo com a McKinsey & Company (2025b), à medida que produtos baseados em IA passam a desempenhar funções antes realizadas por humanos, os modelos de software baseados em assinaturas e consumo tornam-se os mais adequados

para capturar valor, alinhando preço e desempenho à entrega de resultados. Esse formato se mostra, portanto, consistente com o modelo de negócios proposto neste projeto.

3.1.6 Recursos Principais

Os recursos principais necessários para viabilizar o modelo incluem a arquitetura tecnológica baseada em LLMs orquestrados via MCP (com RAG opcional como recurso de recuperação), infraestrutura em nuvem escalável e bases de dados históricas de projetos. Além disso, são fundamentais equipes multidisciplinares compostas por cientistas de dados, engenheiros de machine learning e especialistas em gestão de projetos, capazes de traduzir as necessidades organizacionais em soluções práticas e de alto valor agregado.

Outro recurso relevante é a capacidade de integração da plataforma com sistemas corporativos já consolidados. Isso exige o desenvolvimento de servidores/conectores MCP seguros (expondo *resources*, *tools* e *prompts*), além de APIs quando necessário, que possibilitem o acesso a dados internos sem comprometer a privacidade ou a segurança das informações.

3.1.7 Atividades-Chave

As principais atividades do modelo de negócio incluem o desenvolvimento e a manutenção da plataforma SaaS, a execução de processos de *fine-tuning* dos modelos de IA e a publicação/manutenção de conectores MCP para bases de dados e ferramentas corporativas. Além disso, a oferta de suporte técnico e a atualização de funcionalidades representam atividades críticas para garantir a satisfação e fidelização dos clientes.

Outra atividade essencial é o monitoramento constante da performance do modelo, tanto do ponto de vista técnico quanto em relação à experiência do usuário. Esse acompanhamento possibilita ajustes ágeis, assegurando que a solução se mantenha competitiva em um ambiente de mercado dinâmico e em rápida evolução.

3.1.8 Parcerias Principais

As parcerias estratégicas incluem consultorias globais, como PwC, EY e Deloitte, que podem atuar como canais de implementação e expansão. Também se destacam provedores de nuvem, como AWS, Azure e Google Cloud, responsáveis por garantir a escalabilidade e a segurança da infraestrutura.

Parcerias com associações de gestão de projetos, como PMI Chapters, podem ampliar a credibilidade e facilitar o acesso a potenciais clientes. Além disso, a colaboração com universidades e centros de pesquisa especializados em IA e governança pode acelerar a evolução tecnológica da solução, garantindo inovação contínua.

3.1.9 Estrutura de Custos

A estrutura de custos envolve principalmente investimentos em infraestrutura de nuvem, processamento de dados e licenciamento de modelos de linguagem e desenvolvimento/operacionalização de conectores MCP. Custos com equipe de desenvolvimento, suporte e comercial também representam parcela significativa do orçamento. Adicionalmente, despesas relacionadas a *marketing*, treinamentos e parcerias estratégicas devem ser consideradas, uma vez que são fundamentais para a penetração no mercado e para a construção de uma base sólida de clientes.

3.2 Benchmarking Tecnológico

Partindo do posicionamento tecnológico e do público-alvo delineados na Seção 3.1, esta seção realiza um *benchmarking* entre soluções representativas do estado da prática em IA/LLMs aplicadas à governança de projetos. O objetivo é evidenciar funcionalidades existentes, lacunas e as condições sob as quais a proposta deste trabalho, arquitetura modular (componível) com LLM comercial de última geração disponível via API e orquestração via MCP — com *resources* para exposição governada de dados (ponteiros canônicos), *tools* para cálculos/validações e *prompts* versionáveis — além de conectores para quadros *kanban* e planilhas ou bases corporativas, gera benefícios mensuráveis em escopo, prazo, custo e qualidade, assegurando transparência metodológica e coerência com requisitos de explicabilidade e conformidade já discutidos neste capítulo.

Nesse enquadramento, comparam-se três grupos: (i) suítes de produtividade com IA (p.ex., Notion AI, ClickUp, Asana, Monday.com), eficazes para organização e redação, porém com foco limitado em governança e integração auditável a dados operacionais; (ii) plataformas corporativas de IA (p.ex., IBM Watson Orchestrate, Azure AI Services), com alto poder de integração, porém custos e complexidade superiores; e (iii) a arquitetura modular proposta — LLM comercial disponível via API e orquestração via MCP (*resources*, *tools* e *prompts*), com integrações a fonte de dados — que equilibra capacidade, explicabilidade (citação de fontes e trilha de auditoria) e custo, especialmente para Pequenas e Médias Empresas (PMEs). A análise SWOT subsequente sintetizará esses achados sob a ótica de forças, fraquezas, oportunidades e ameaças, preparando a ponte para o MVP.

3.2.1 Método e Critérios de Comparação

O *benchmarking* foi estruturado em três etapas: (a) delimitação do universo comparado (os três grupos acima); (b) definição operacional de eixos avaliativos; e (c) análise qualitativa com justificativas, ancorada em materiais do curso e evidências de mercado. Os eixos refletem requisitos críticos para governança de projetos com LLMs: integração governada via MCP, explicabilidade e trilha de auditoria via MCP, custo total de propriedade (TCO), tempo de implantação, aderência a PMEs (recursos/competências disponíveis),

dependência de competência (engenharia de *prompts* e curadoria de dados) e impacto mensurável em escopo, prazo, custo e qualidade.

A operacionalização buscou aderir às diretrizes metodológicas do curso (clareza de critérios, coleta transparente e síntese comparativa), incorporando o arcabouço de governança de IA já descrito no trabalho (LGPD, exposição de dados sensíveis, explicabilidade e dependência de fornecedor). Os resultados são apresentados em matriz qualitativa e, ao final, sintetizados em implicações práticas para adoção, servindo de ponte para a priorização de casos de uso e métricas do MVP.

3.2.2 Matriz Comparativa “Estado da Prática” versus Proposta

A Tabela 2 compara, em escala qualitativa (“baixa”, “média”, “alta”), três alternativas: (A) suítes de produtividade com IA; (B) plataformas corporativas de IA; (C) proposta LLM com orquestração via MCP.

3.2.3 Implicações para Adoção em PMEs

Para PMEs, TCO, tempo de implantação e disponibilidade de competências são determinantes. A arquitetura modular proposta privilegia APIs amplamente usadas, *frameworks open source* e infraestrutura leve (p.ex., Streamlit/Hugging Face/Colab), reduzindo barreiras de entrada, viabilizando PoCs com parceiros e mantendo registro e explicabilidade via MCP, com ponteiros canônicos, logs de invocação de *resources/tools* e versionamento de *prompts*. Essa estratégia atende à necessidade de “valor rápido” sem abrir mão de governança. A adoção, porém, depende de disciplina de dados (atualização/qualidade das fontes operacionais) e de práticas de *prompt engineering* para respostas consistentes. As evidências indicam que organizações com maior habilitação capturam benefícios superiores (utilidade percebida, uso intensivo e impacto em fatores clássicos de desempenho), reforçando que a vantagem não é apenas tecnológica, mas também organizacional.

3.2.4 Síntese e Ligação com o MVP

O *benchmarking* sustenta duas conclusões práticas: (i) há espaço para uma solução especializada em governança que combine LLM de alto desempenho com integração auditável a dados operacionais e custos controlados; e (ii) o sucesso depende de competências e práticas de dados (engenharia de *prompts*, curadoria e padronização), o que demanda diretrizes e métricas de adoção desde o MVP. Essas conclusões alinham-se às recomendações de transparência, rastreabilidade e responsabilização já discutidas no trabalho.

Como ponte para o Capítulo 4, a Tabela 3 antecipa casos de uso com “quem usa/para quê/benefício mensurável”, a serem detalhados quando avançarmos para o MVP.

Em síntese, o mapeamento de soluções mostrou que, no caso de uso “*reporting* de governança”, fatores como custo, tempo de implantação e simplicidade de integração são tão decisivos quanto a capacidade de geração. O MVP proposto endereça essas demandas ao adotar orquestração via MCP, que permite modularidade, auditabilidade e neutralidade tecnológica, entregando relatórios estruturados em *Markdown* com baixo custo de entrada. Dessa forma, constitui um caminho de adoção progressiva para PMOs que precisam equilibrar restrições orçamentárias e de equipe com a busca por maior confiabilidade no processo de reporte.

3.3 Análise SWOT – Implantação de IA em Governança de Projetos

A Análise SWOT a seguir examina a proposta com base na orquestração via MCP. O objetivo é mapear de forma crítica as condições internas e externas que afetam a viabilidade do MVP em *reporting* de governança de projetos. Considera-se, nesse contexto, o contraste com arquiteturas centradas em RAG, em que a necessidade de conectores específicos e menor capacidade de padronização aumentam os custos de integração e manutenção.

3.3.1 Forças

O MCP introduz governança embutida na arquitetura. A separação entre *resources*, *tools* e *prompts* versionados garante rastreabilidade e reprodutibilidade, atributos essenciais para relatórios de governança que dependem de verificabilidade e consistência. Esse desenho reduz a dependência de implementações ad hoc, pois cada artefato é exposto de forma controlada e auditável.

Outro ponto de destaque é a independência tecnológica. Diferentemente de modelos baseados em RAG que exigem conectores específicos para cada fonte ou aplicação, o MCP utiliza contratos padronizados, simplificando a integração com sistemas heterogêneos. Essa característica reduz esforço de manutenção, facilita a substituição de serviços e acelera a escalabilidade, já que novas fontes podem ser adicionadas sem customizações extensivas. A comparação com arquiteturas RAG reforça esse diferencial: enquanto estas implicam forte acoplamento técnico, o MCP abstrai a complexidade e torna a orquestração mais sustentável a longo prazo.

Adicionalmente, o fato de o MCP ser um protocolo aberto promove interoperabilidade e evita dependência de fornecedores. O ecossistema aberto favorece a colaboração, a evolução coletiva e a adoção de melhores práticas, o que potencializa ganhos de qualidade e transparência em ambientes corporativos que demandam neutralidade tecnológica.

3.3.2 Fraquezas

Apesar de suas vantagens, o MCP demanda maturidade organizacional e técnica para ser explorado em todo o seu potencial. PMOs sem práticas sólidas de versionamento e catálogo de recursos podem enfrentar curva de adoção significativa. O processo de publicar *resources*, atualizar *tools* e gerir *prompts* exige disciplina e governança mínima, que nem sempre estão presentes em estruturas enxutas.

Outra fraqueza é a dependência da comunidade e da evolução contínua do protocolo. Por ser *open source*, não há garantias contratuais de suporte ou *roadmap* estável, diferentemente de soluções proprietárias. Isso pode gerar incertezas quanto à longevidade de determinadas implementações e exigir que a própria organização assuma responsabilidades de manutenção ou contribua ativamente para o ecossistema. Além disso, a ausência de padrões de fato consolidados em certos setores pode levar a interpretações divergentes do protocolo, criando variações que comprometem a interoperabilidade plena.

Por fim, a promessa de independência tecnológica não elimina a necessidade de governança de dados. Se as fontes forem desorganizadas, inconsistentes ou pouco confiáveis, a arquitetura não consegue compensar essas lacunas, e o relatório resultante corre o risco de apresentar fragilidades.

3.3.3 Oportunidades

A adoção do MCP abre oportunidades de evolução incremental e sustentada. Como a recuperação de evidências é apenas um serviço opcional, novas abordagens podem ser testadas sem alterar o restante da arquitetura. Isso permite incorporar avanços em *embeddings* densos, *reranking* supervisionado ou até integrações com ontologias corporativas sem comprometer a estabilidade do pipeline.

Há também oportunidade de diferenciação competitiva por meio da conformidade automatizada. Ao encadear ferramentas de validação de *schema* e aplicação de políticas organizacionais, o MCP permite transformar requisitos regulatórios em etapas técnicas obrigatórias, o que agrega valor em setores altamente regulados. Da mesma forma, a conversão do *markdown* em diferentes formatos executivos pode ampliar a usabilidade da solução e integrá-la a múltiplos fluxos de comunicação gerencial.

No médio prazo, a consolidação do protocolo em escala mais ampla tende a reduzir custos de integração. Empresas que adotarem cedo o MCP podem se beneficiar da padronização emergente e posicionar seus PMOs como pioneiros em práticas de governança digital orientadas por protocolos abertos.

3.3.4 Ameaças

Embora seja um protocolo aberto, o MCP ainda é relativamente recente, o que implica riscos de maturidade. A falta de padronização definitiva ou de consenso sobre melhores práticas pode gerar fragmentação de implementações e dificultar a interoperabilidade entre organizações. Esse fator representa uma ameaça relevante em ambientes corporativos que valorizam estabilidade e previsibilidade tecnológica.

O caráter *open source*, embora traga vantagens, também acarreta riscos de suporte limitado. Caso a comunidade perca tração ou determinados mantenedores se afastem, pode haver descontinuidade ou lentidão na evolução de componentes críticos. Esse risco é menor em soluções proprietárias com contratos de SLA, e a mitigação passa por diversificação de fornecedores e eventual investimento interno em capacidade técnica.

Outra ameaça é o impacto financeiro indireto. Apesar de eliminar a necessidade de conectores proprietários, o MCP não dispensa o uso de serviços externos para certas funcionalidades (como modelos de linguagem ou servidores de recuperação). Mudanças em preços de APIs ou restrições de uso podem afetar o TCO da solução, exigindo planejamento de contingência. Além disso, a dependência de dados confiáveis continua a ser um fator-chave: sem qualidade na base de informações, o melhor arranjo arquitetural não garante confiabilidade nos relatórios.

Tabela 2 – Matriz comparativa de soluções para assistência à governança de projetos

Eixo	(A) Suítes de produtividade com IA	(B) Plataformas corporativas de IA	(C) Proposta: LLM com orquestração via MCP
Integração com dados operacionais	Baixa: foco em texto/organização; conectores genéricos; consulta a dados governados.	Alta: integrações profundas e customizáveis; requer time técnico.	Média–Alta: fontes operacionais expostas como <i>resources</i> MCP (Trello/Sheets); consultas/cálculos como <i>tools</i> MCP; acesso e logs governados pelo protocolo.
Explicabilidade / Trilha de auditoria	Baixa–Média: citações/logs não orientados a auditoria.	Alta: registros e versionamento; maior complexidade operacional.	Alta: ponteiros canônicos nas fontes; logs de invocação de <i>resources/tools</i> ; versionamento de <i>prompts</i> e metadados técnicos via MCP.
TCO (licenças/infra/uso)	Baixo–Médio: licenças acessíveis; limitações de governança.	Alto: licenças/infra e serviços especializados.	Baixo–Médio: APIs sob demanda; <i>framework</i> aberto; reuso de conectores; controle de uso e acesso via MCP.
Tempo de implantação	Curto: ativação simples; valor rápido porém superficial para governança.	Longo: projetos de integração dedicados.	Curto–Médio: PoC em dias; integrações como servidores MCP; evolução incremental.
Aderência a PMEs	Alta: baixo custo inicial, porém limitada para auditoria formal.	Baixa: barreiras de custo/complexidade.	Alta: foco em PoCs, custos variáveis e modularidade com MCP.
Competências requeridas	Baixas em dados/engenharia; <i>prompting</i> básico.	Altas em engenharia, dados e segurança.	Médias: <i>prompting</i> e orquestração via MCP; curadoria dos dados críticos.
Impacto em escopo, prazo, custo e qualidade	Limitado: ganhos de produtividade textual; pouco efeito direto em indicadores de projeto.	Potencialmente alto, condicionado à adoção/maturidade.	Alto com padronização + rastreabilidade (MCP); indicadores auditáveis no artefato de reporte.

Fonte: Elaborada pela autora.

Tabela 3 – Prévia de casos de uso orientados pelo *benchmarking*

Quem usa	Para quê	Benefício mensurável
Analista/PMO	Gerar status semanal com fontes citadas.	Redução do tempo de elaboração e aumento da confiabilidade percebida do relatório.
Gerente de Projetos	Sinalizar riscos de atraso por equipe/entrega.	Antecipação de desvios e menor taxa de atraso em marcos críticos.
Diretor/Comitê	Obter sumário executivo explicável (com trilha de fontes).	Melhoria da tomada de decisão por rastreabilidade e transparência.
Gerente de Projetos / Planejamento	Otimizar cronogramas e alocação de recursos com base em padrões históricos.	Menos variância de cronograma (SV) e menos sobrealocação; menos retrabalho.

Fonte: Elaborada pela autora.

4 ASSISTENTE VIRTUAL DE GOVERNANÇA COM MCP

Esta seção descreve o desenvolvimento conceitual e técnico da solução proposta, integrando os fundamentos de governança de projetos com os princípios de engenharia de IA generativa. O ponto de partida é a definição do **TGRP**, que estabelece o modelo normativo de conteúdo, rastreabilidade e conformidade para relatórios executivos. Em seguida, apresenta-se a **arquitetura de referência baseada no MCP**, que organiza a interação entre modelos de linguagem de grande escala, dados corporativos e ferramentas externas, garantindo interoperabilidade e auditabilidade. A terceira parte adota o **framework CRISP-DM** como método estruturante para o entendimento, preparação e modelagem dos dados que alimentam o Assistente Virtual de Governança. Por fim, a seção dedicada ao MVP demonstra, por meio de uma prova de conceito, como essas camadas se integram operacionalmente para gerar relatórios automáticos em formato narrativo e estruturado, validando a viabilidade da proposta.

4.1 *Traceable Governance Reporting Protocol (TGRP)*

O TGRP é o eixo normativo que sustenta o Assistente Virtual de Governança, funcionando como referência para a padronização de conteúdo, a rastreabilidade de fontes e a conformidade técnica das saídas. Sua definição parte da necessidade de transformar o relatório executivo de projetos em um artefato comparável entre ciclos, inteligível ao comitê diretivo e auditável por terceiros. Para isso, o protocolo organiza o documento em blocos específicos, cada qual com função distinta e regras próprias de preenchimento.

O primeiro desses blocos é o sumário executivo, que obrigatoriamente deve ser redigido em formato narrativo. Diferente de quadros numéricos, esse trecho traduz os principais achados do ciclo em uma narrativa coesa, explicitando atrasos, sobrecustos, riscos emergentes ou decisões críticas. O caráter narrativo permite que o texto seja lido como síntese estratégica, mas cada sentença assertiva só é considerada válida quando finalizada com o ponteiro exato para a evidência correspondente, preservando o vínculo com as fontes originais. Na sequência, o relatório detalha as variações de prazo, custo e recursos, sempre a partir da comparação entre *baseline* e realizado. O protocolo prevê que os desvios sejam quantificados e localizados (dias úteis, percentual de orçamento ou sobrecarga de papéis específicos), e que suas implicações sejam narradas em texto corrido, novamente finalizado por ponteiro. O TGRP prevê ainda o registro do Top 5 de riscos, que devem ser descritos de forma sintética, mas com indicação clara de evento, causa, impacto e responsável, bem como a consolidação de problemas e decisões pendentes. Esses elementos cumprem a função de trazer ao nível executivo os itens que exigem visibilidade e deliberação, sempre com referência explícita à ata, log ou base de dados de foram extraídos.

O cálculo do SST, por sua vez, segue regra objetiva declarada no corpo do relatório, atribuindo os rótulos “em dia”, “atenção” ou “atrasado” com base em critérios objetivos de prazo e custo. O rótulo deve ser acompanhado de uma frase explicativa e das fontes que o justificam, garantindo que o semáforo seja reproduzível e transparente. Por fim, o parecer do Assistente Virtual de Governança integra os sinais objetivos apresentados, emitindo recomendações prescritivas fundamentadas em evidências, sem introduzir dados inéditos. Esse parecer é o espaço em que a Inteligência Artificial exerce papel interpretativo, mas sempre em conformidade com as regras do protocolo.

A rastreabilidade é garantida por dois mecanismos complementares. O primeiro é a obrigatoriedade de notas numeradas com ponteiros canônicos, que ligam cada afirmação a seu ponto exato de origem. O segundo é a manutenção de uma trilha de auditoria técnica, que documenta parâmetros da execução: versão do LLM, *prompt* e *template* utilizado.

O fechamento do protocolo ocorre na definição da forma de entrega. A saída deve ser produzida em Markdown estruturado, de modo a preservar títulos, blocos textuais e a seção “Fontes”, onde todas as citações aparecem consolidadas. Esse formato assegura interoperabilidade com múltiplas plataformas, permitindo conversão direta para PPT ou PDF sem perda de estrutura. Ao optar pelo Markdown, o TGRP materializa um equilíbrio entre clareza narrativa, padronização técnica e integração corporativa, garantindo que o Assistente Virtual de Governança entregue relatórios consistentes, rastreáveis e prontos para consumo executivo.

4.2 Arquitetura

A arquitetura proposta organiza-se em cinco camadas, conforme ilustrado na Figura 3, cada uma desempenhando funções específicas para operacionalizar o TGRP de maneira padronizada, rastreável e auditável. A seguir, descrevem-se as responsabilidades de cada camada.

1. **Usuário.** O usuário — tipicamente um analista de PMO ou gerente de projetos — atua como ponto de entrada do processo. Sua interação ocorre por meio de *prompts* enviados ao Assistente Virtual de Governança. No protótipo (MVP), as informações de projeto são fornecidas mediante upload de planilhas e documentos. Na arquitetura-alvo, essa camada passa a operar de forma nativamente integrada ao ecossistema corporativo por meio de conectores MCP do tipo *resources*, permitindo ingestão automática de dados provenientes de sistemas como Jira, Planner, SharePoint, Trello e bases relacionais internas, eliminando etapas manuais e garantindo atualização contínua.
2. **Host MCP.** O Host MCP é o ambiente onde o LLM opera sob controle de protocolo. Ele recebe o *prompt* do usuário, aciona os clientes MCP necessários, consolida as


evidências trazidas pelos servidores e gera o relatório narrativo final em *Markdown* estruturado, conforme as regras do TGRP. É também responsável por registrar metadados técnicos de auditoria (identificadores de evidência, versão do modelo, parâmetros, instruções utilizadas) para assegurar reprodutibilidade e conformidade com normas de governança da informação.

3. **Clientes MCP.** Os clientes MCP funcionam como componentes intermediários que mantêm conexões 1:1 entre o Host MCP e os Servidores MCP. Eles transmitem requisições e respostas por meio de RPC (*Remote Procedure Call*), garantindo isolamento, modularidade e comunicação padronizada entre o Host e múltiplos serviços externos. Esses clientes não interpretam dados; apenas encaminham chamadas e retornos entre as camadas.
4. **Servidores MCP.** Os servidores MCP expõem, de forma governada, os três tipos de primitivas definidas pelo protocolo:
 - *Resources*: fornecem acesso a dados e contextos, sempre com ponteiros canônicos para garantir rastreabilidade das evidências. Incluem consultas a bases, leitura de planilhas, recuperação de documentos e metadados.
 - *Tools*: executam cálculos determinísticos e verificações objetivas, como aferição de variação de cronograma, comparação de orçamento planejado versus realizado ou aplicação das regras do Status–Schedule–Trend (SST).
 - *Prompts*: disponibilizam templates de instrução versionáveis que padronizam como o LLM deve estruturar narrativas, sintetizar evidências e produzir seções do relatório conforme o TGRP.

Essa camada concentra a lógica operacional que garante confiabilidade, padronização e vínculo explícito entre cada afirmação e sua fonte.

5. **Saída: Relatório Executivo.** Após consolidar os resultados provenientes das primitivas MCP, o Host gera o relatório executivo em *Markdown* estruturado. Esse formato preserva a hierarquia do TGRP, facilita conversão para PPT ou PDF e mantém a legibilidade da narrativa. A seção final inclui a trilha de auditoria técnica, contendo versão do modelo, identificadores das evidências usadas e o *hash* do template acionado, garantindo transparência, reprodutibilidade e aderência às práticas de governança de informações.

Figura 3 – Arquitetura do Assistente Virtual de Governança com MCP (visão lógica por camadas).



Fonte: Elaboração própria.

4.3 Metodologia de Construção


Esta seção descreve a metodologia utilizada para o desenvolvimento e implantação da solução proposta Assistente Virtual de Governança com MCP. A construção segue a metodologia CRISP-DM (Cross Industry Standard Process for Data Mining) — conforme ilustrado na Figura 4 — que estrutura as etapas de entendimento do negócio, entendimento e preparação dos dados, modelagem, avaliação e implantação, orientando o encadeamento lógico do capítulo.

O CRISP-DM não é um processo linear, mas cíclico. Isso significa que pode ser reexecutado à medida que novos dados se tornam disponíveis para o treinamento ou ajuste do modelo e que é possível retornar a fases anteriores sempre que os resultados de uma etapa indicarem a necessidade de revisões. Essa característica assegura flexibilidade e evolução contínua da solução proposta.

4.3.1 Entendimento do Negócio

A elaboração do Relatório Executivo de Governança no PMO ainda demanda esforço elevado de compilação e revisão, com registros heterogêneos entre áreas que geram desalinhamento entre o que se apresenta e o que se consegue evidenciar. Isso atrasa a entrega de informação confiável à diretoria e aumenta retrabalho. O Assistente Virtual de Governança com MCP responde a esse problema com um objetivo de negócio direto: reduzir o tempo de preparação do relatório, padronizar o conteúdo e garantir rastreabilidade de

Figura 4 – Fases do CRISP-DM e seu caráter iterativo.



Fonte: Elaboração própria.

cada informação reportada, de modo que a liderança possa decidir com mais agilidade sobre prazos, custos e alocação de recursos.

O sucesso, sob a ótica do negócio, significa entregar um relatório mais rápido de gerar, comparável entre iniciativas e confiável para quem decide. A verificação detalhada desses resultados será apresentada na subseção de Avaliação, mas, desde já, a expectativa é reduzir o trabalho manual do PMO, diminuir revisões por inconsistência e elevar a clareza percebida pelos executivos.

O escopo deste projeto concentra-se no *reporting* de governança em nível de portfólio e projeto — status do período, variações relevantes e riscos/decisões priorizadas. Ficam fora análises preditivas avançadas, otimização de capacidade e automações de execução. *Stakeholders* diretos incluem diretoria e líderes de projeto (tomadores de decisão), o PMO (produtor do artefato) e as áreas que mantêm registros operacionais. Entre as restrições estão disponibilidade de equipe, aderência aos ritos já existentes (semanal/quinzenal) e

limites orçamentários; os riscos mais prováveis envolvem maturidade desigual de processos e mudança de prioridades, mitigados por comunicação clara de valor, vocabulário padronizado e adoção progressiva.

Como plano preliminar, a proposta avança por um ciclo curto de validação: formalização final do conteúdo mínimo do relatório e de seus critérios de aceitação, execução de um piloto controlado com um conjunto representativo de projetos e ajustes iterativos a partir do *feedback* executivo. A neutralidade tecnológica é preservada pelo uso do MCP, que organiza o acesso a dados e funções de forma independente de fornecedor; os detalhes técnicos, bem como a escolha concreta usada neste trabalho, aparecem na seção dedicada ao MVP e nas subseções seguintes.

4.3.2 Entendimento e Preparação dos Dados

O relatório de governança se apoia em um ecossistema de informações com naturezas distintas. De um lado, há dados estruturados mantidos pelo PMO — registros de identificação do projeto e sua fase, cronogramas com marcos planejados e realizados, atividades com histórico de atualização, o *log RAID*, a estrutura orçamentária (WBS e orçamento planejado×realizado por pacote de trabalho) e o cadastro de recursos com seus planos de alocação e custo-hora. De outro, existem dados semiestruturados, como atas e resumos de reunião em formato textual, que qualificam a interpretação de eventos e justificativas. Complementarmente, dados derivados podem ser obtidos a partir de *dashboards* de BI, oferecendo séries históricas e indicadores consolidados. Na prática, todas essas origens são disponibilizadas ao Assistente por meio do MCP, que as publica como *resources* padronizados, preservando neutralidade de fornecedor e permitindo substituições sem reescritas de conectores.

Antes de utilizar essas fontes na etapa de modelagem, aplica-se uma preparação focada em consistência, comparabilidade e rastreabilidade. Os dados estruturados passam por normalização de formatos (datas em padrão único; categorias padronizadas para status, fases, tipos de risco etc.), padronização de nomenclaturas entre áreas e reconciliação de chaves (projeto, marco, pacote WBS, recurso). São executadas rotinas de saneamento, como remoção de duplicidades, validação de campos obrigatórios e higienização de caracteres inválidos em textos. Em relação a anomalias, adota-se um critério conservador: *outliers* não são descartados; permanecem como registros válidos e sinalizados para interpretação posterior (por exemplo, alocações acima de 100% ou valores negativos de orçamento). Nos insumos textuais, realiza-se limpeza e segmentação em trechos curtos, etiquetados com ponteiros canônicos que permitem a referência a passagens específicas de documentos, assegurando citação precisa e reconstituível.

A integração das fontes ocorre formando visões temáticas coerentes com o uso gerencial do relatório: prazo (projetos, marcos e histórico de atividades), custo (WBS e

orçamento) e alocação (recursos e plano de esforço). Como produto dessa etapa, cada evidência factual fica associada ao seu ponteiro canônico, vinculado ao documento e à posição da informação dentro da fonte original — compondo uma tabela interna de evidências que viabiliza a rastreabilidade sem poluir o corpo do relatório. A materialização dessas referências ao leitor ocorre exclusivamente na seção “Fontes”, conforme diretriz do protocolo adotado, preservando a legibilidade do documento principal.

4.3.3 Modelagem

A modelagem consiste em gerar um relatório executivo estruturado a partir das fontes de dados conectadas, combinando cálculos determinísticos externos e geração textual assistida por modelos de linguagem. Os cálculos objetivos — variações de prazo, custo e alocação, além da determinação do SST — são processados previamente como *tools* MCP, assegurando consistência numérica e reprodutibilidade. O papel do LLM é restrito à composição narrativa e à formatação do relatório segundo o esquema do TGRP.

O contexto enviado ao modelo inclui (i) os resultados determinísticos já calculados; (ii) um conjunto de evidências estruturadas e textuais selecionadas de forma direcionada; e (iii) sinais objetivos derivados na etapa anterior. Essa seleção de evidências pode ser realizada por um *retriever* leve operando como serviço MCP opcional, que identifica trechos curtos de atas ou registros relevantes por termos-chave, preservando sempre o ponteiro canônico para rastreabilidade. Dessa forma, cada afirmação factual permanece ancorada em sua fonte, e a ausência de evidência é tratada explicitamente como lacuna.

A saída do LLM é estruturada em *Markdown*, aderente ao *template* mínimo do TGRP, que define blocos obrigatórios, títulos e subtítulos, além do modo de apresentação das notas de fonte. A renderização subsequente transforma esse conteúdo em formato narrativo (*storytelling*) para PPT/PDF, pronto para consumo executivo. O relatório contempla, no mínimo, sumário executivo, variações de prazo/custo/alocação, Top-5 riscos com ações de mitigação, decisões pendentes (o quê/quem/quando), o rótulo SST justificado por evidências e o Parecer do Assistente de Governança.

O *prompt* disciplina a geração com três regras principais: (i) não inferir sem fonte; (ii) separar fato e opinião; e (iii) não exibir ponteiros no corpo do texto. Internamente, cada enunciado factual é vinculado a uma ou mais evidências; na renderização, esses vínculos se tornam notas numeradas exibidas apenas na seção “Fontes”. Para reduzir variação entre execuções, parâmetros conservadores (como *temperature* baixa) são adotados, favorecendo consistência factual.

O Parecer do Assistente de Governança é produzido como bloco separado e tem caráter explicitamente opinativo. Ele não contradiz fatos existentes, mas pode apontar lacunas (ex.: campos não preenchidos, dados desatualizados, ausência de responsável por riscos) e oferecer recomendações baseadas em sinais objetivos e boas práticas de governança.

Esse mecanismo assegura que o parecer agregue valor interpretativo sem comprometer a confiabilidade factual do relatório.

Quanto à escolha tecnológica, a arquitetura preserva duas possibilidades: (i) uso de um LLM comercial acessado via API, aproveitando modelos de última geração e infraestrutura gerenciada; ou (ii) adoção de um LLM aberto executado em estrutura própria (*on-premises* ou em nuvem), favorecendo maior controle, customização e confidencialidade. Em ambos os casos, o MCP encapsula o provedor como um servidor substituível, de modo que a troca de modelo exige apenas reconfiguração do *endpoint*, e não a reescrita do fluxo. A opção efetivamente adotada para o protótipo é detalhada na Seção dedicada ao MVP, ao final do capítulo.

4.3.4 Avaliação

A etapa de avaliação examina em que medida o modelo construído atende aos objetivos de negócio definidos no início do processo. No caso do Assistente Virtual de Governança com MCP, a verificação se concentra em três pontos principais: se o relatório produzido é mais ágil de gerar em comparação ao processo manual anterior; se a estrutura e o conteúdo permitem comparação entre iniciativas; e se as evidências que sustentam cada afirmação são acessíveis e verificáveis. Esses aspectos traduzem, de forma prática, a busca por reduzir esforço operacional, padronizar o artefato e aumentar a confiança das informações reportadas à diretoria.

Por seguir o ciclo CRISP-DM, a avaliação não é apenas uma etapa final, mas parte de um processo iterativo. Resultados parciais podem indicar a necessidade de voltar a fases anteriores — ajustando fontes, revisando regras de preparação ou calibrando parâmetros de modelagem. Essa característica garante que o artefato evolua progressivamente, incorporando melhorias a cada iteração. A conclusão da avaliação nesta fase fornece insumos para a Seção do MVP, onde são apresentados os critérios específicos de aceitação, os instrumentos de mensuração utilizados e as evidências de que o protótipo cumpre os requisitos definidos.

4.3.5 Implantação

A etapa de implantação, no escopo do CRISP-DM, discute as alternativas de como a solução poderá ser disponibilizada e utilizada em um ambiente organizacional. No caso do Assistente Virtual de Governança com MCP, a arquitetura é desenhada para preservar neutralidade tecnológica e permitir diferentes arranjos de adoção, de acordo com as condições de cada PMO.

Do ponto de vista dos modelos de linguagem, a solução pode ser implementada tanto com LLMs comerciais acessados via API, que oferecem maior conveniência e desempenho imediato, quanto com modelos abertos executados em infraestrutura própria (*on-premises*

ou em nuvem privada), quando há requisitos de confidencialidade, customização ou controle de custos. Em ambos os cenários, o uso do MCP assegura padronização na forma de acesso a dados e funções, de modo que a substituição do provedor de LLM não exige reescrita do fluxo, apenas a reconfiguração do *endpoint* correspondente.

Quanto à entrega, existem igualmente duas possibilidades. A primeira é disponibilizar o Assistente como um serviço em nuvem, exposto via API, permitindo que diferentes unidades de negócio ou empresas acessem o relatório executivo sob demanda. A segunda é realizar a implantação na infraestrutura da própria organização, integrando-se ao ambiente existente do PMO, o que pode ser preferível em contextos de maior sensibilidade de dados ou restrições regulatórias. Em ambos os casos, a intermediação via MCP garante que o acesso aos recursos — sejam eles planilhas corporativas, bases de dados, repositórios textuais ou ferramentas auxiliares — seja governado por um protocolo uniforme, com rastreabilidade e segregação de responsabilidades.

A descrição detalhada da implantação prática, incluindo os artefatos de dados utilizados, parâmetros de execução e registros de auditoria, é apresentada no capítulo específico do MVP. Nesta subseção, o que se destaca é a flexibilidade da arquitetura proposta e sua capacidade de adaptação a diferentes cenários de governança de projetos, sem abrir mão de rastreabilidade, neutralidade tecnológica e confiabilidade.

4.4 MVP

A etapa de validação da solução proposta foi conduzida por meio do desenvolvimento de MVP, cujo propósito é demonstrar a viabilidade técnica e conceitual do TGRP na geração automatizada de relatórios de governança de projetos. O MVP simula o fluxo completo de interação entre o usuário final (gestor de projetos) e o Assistente Virtual de Governança, reproduzindo a sequência lógica de execução descrita no protocolo — desde a ingestão do corpus de dados até a emissão do relatório estruturado em formato *Markdown*.

4.4.1 Dados Utilizados no MVP

O conjunto de dados utilizado na simulação do MVP foi construído especificamente para reproduzir a dinâmica de informações de um PMO. Um conjunto de dados foi elaborado de forma sintética de três projetos hipotéticos, mas mantendo coerência entre os elementos que normalmente compõem o ecossistema de governança corporativa. Assim, o objetivo não foi testar volume de dados, mas sim validar a integridade lógica e a rastreabilidade das informações entre as diferentes dimensões de controle.

A primeira aba, **Projeto**, apresenta uma visão geral das iniciativas em acompanhamento, funcionando como ponto de partida para a análise. Nela constam as informações essenciais sobre cada projeto — sua descrição, escopo e situação geral — permitindo ao modelo compreender o contexto e identificar o responsável pela execução.

Na aba **Projeto_milestones**, estão dispostos os principais marcos e entregas de cada projeto, com as respectivas datas de planejamento e realização. Essa camada temporal é a base para que o sistema reconheça variações de prazo e classifique automaticamente o status de andamento conforme as regras do TGRP.

A aba **Budget** traz uma visão financeira consolidada, com os valores planejados e realizados ao longo do período de referência. Ela permite observar desvios de custo e oferece insumos objetivos para a seção de variações financeiras do relatório.

Complementarmente, a aba **Plano_alocação** reflete a distribuição do trabalho entre os membros da equipe, registrando a quantidade de horas atribuídas a cada profissional por período. Já a aba Recursos reúne as informações de identificação e custo dos profissionais alocados, funcionando como uma referência para estimar o esforço total despendido em cada projeto.

Por fim, a aba **RAID Log** consolida os registros relacionados à gestão de riscos e pendências, incluindo eventos que demandam atenção, decisões ainda não tomadas e ações de mitigação em curso. Essa dimensão qualitativa confere profundidade interpretativa ao relatório, pois permite ao Assistente Virtual identificar padrões de risco e construir recomendações contextualizadas no Parecer de Governança.

Em conjunto, essas seis abas formam uma base integrada, na qual cada informação se conecta de forma lógica às demais. Essa organização reflete o funcionamento real de um ambiente de governança e garante que as análises geradas pelo MVP estejam ancoradas em dados estruturados, rastreáveis e interpretáveis.

O detalhamento técnico de campos, chaves e regras encontra-se no Apêndice A. Aqui, o que importa é estabelecer que o pipeline de dados coletado via MCP, devidamente normalizado, saneado, integrado e referenciado por ponteiros canônicos, entrega um contexto confiável e compacto para a etapa de Modelagem, onde o conteúdo será organizado e redigido segundo o esquema definido para o relatório.

4.4.2 Configuração da LLM e Mecanismo de Inferência

A configuração do MVP fundamentou-se na utilização de uma LLM como núcleo cognitivo da solução. A LLM é o componente responsável por compreender, relacionar e sintetizar as informações provenientes do corpus, transformando dados estruturados em narrativa auditável.

Para essa finalidade, foi adotado o GPT-5, modelo de última geração da família OpenAI, reconhecido pela capacidade de raciocínio contextual e consistência semântica em textos longos. A escolha desse modelo decorre da necessidade de conjugar interpretação técnica precisa com geração de linguagem natural padronizada, assegurando coerência narrativa e rastreabilidade.

Tendo definida a LLM a ser utilizada, tornou-se necessário estabelecer como esse modelo seria instanciado, configurado e conduzido dentro do MCP. Essa etapa envolve a definição dos parâmetros de inferência, do ambiente de execução e das regras que orientam o raciocínio do modelo, compondo o que aqui se denomina mecanismo de inferência do MVP.

O GPT-5 foi instanciado por meio do ambiente ChatGPT, que permite a execução interativa de *prompts* estruturados dentro de sessões controladas. A comunicação entre o modelo e o corpus ocorre via MCP, que define um conjunto de primitivas para registro de dados, execução de ferramentas determinísticas e geração textual. Uma vez definido o ambiente de execução, o modelo passa a operar de forma governada pelo MCP que define três etapas sequenciais através da execução de prompts distintos descritos a seguir compondo em conjunto o pipeline completo de execução do MVP:

Etapas 1 — Registro do Recurso (equivalente a MCP.resources)

A primeira etapa tem como finalidade estabelecer o contexto de operação do modelo, instruindo o GPT-5 a reconhecer o workbook Excel como a única fonte factual a ser utilizada durante a geração do relatório. Essa configuração assegura que todas as respostas do sistema estejam vinculadas ao conjunto de dados fornecido, preservando a rastreabilidade e a integridade da informação.

O *prompt* utilizado nessa etapa foi estruturado da seguinte forma:

```
MCP.resourexcel.workbook
file: ces:
- id: res.corpus
type: "Corpus Protótipo.xlsx"
policy:
- usar SOMENTE este arquivo como base factual
- toda frase assertiva DEVE terminar com um número sequencial [n]
Liste as abas detectadas para confirmar o carregamento.
```

Etapas 2 — Execução das Ferramentas

Após o registro do recurso, inicia-se a execução das ferramentas auxiliares (*tools*), que correspondem às operações de leitura e processamento de dados realizadas antes da geração textual. Nessa fase, o modelo simula dois tipos de funções MCP: a ferramenta de indexação de ponteiros e a ferramenta de avaliação de desempenho.

A primeira, denominada *pointer_index*, tem como propósito mapear as informações relevantes dentro do corpus, identificando automaticamente os valores e células que servirão

como evidências no relatório.

O *prompt* que orienta essa etapa é o seguinte:

```
MCP.tools.call: pointer_index
```

```
Tarefa: percorrer o workbook (res.corpus) e montar, APENAS NA RESPOSTA,
uma tabela chamada PointerIndex com colunas:
```

```
[Projeto, Período, fact, sheet, cell, pointer, value].
```

```
Parâmetro opcional:
```

```
- ProjetoSelecioneado: [ ]
```

```
Se informado, filtrar todos os registros do PointerIndex apenas para esse
```

```
Inclua:
```

```
- Projeto (aba Projeto): identificador, status e gerente
```

```
- Projeto\_milestones: datas planejadas e reais de cada marco
```

```
- Budget: planejado e realizado do mês corrente
```

```
- Recursos e Plano\_alocação: horas planejadas e valor/hora por recurso
```

```
- RAID Log: até 5 riscos ``Em aberto'' com evento, causa, impacto e respons
```

```
Regras:
```

```
- pointer = Corpus Protótipo#Aba!Célula
```

```
- NÃO invente -- registre como [lacuna] se o dado não existir.
```

Com esse comando, o modelo percorre o *workbook* e produz um índice descritivo de evidências, que relaciona cada fato encontrado à sua localização na planilha. O resultado esperado é a criação de um mapa textual de ponteiros — um inventário das informações que poderão ser citadas posteriormente no relatório, como datas de marcos, valores de orçamento ou registros de risco. Essa ferramenta cumpre o papel de fundamentar a rastreabilidade, permitindo que o modelo compreenda onde cada evidência se encontra e como referenciá-la no texto.

A segunda ferramenta, denominada *sst_rule*, aplica a regra objetiva do SST, calculando a situação de andamento de cada projeto com base nas informações de cronograma, orçamento e riscos.

O *prompt* utilizado é o seguinte:

```
MCP.tools.call: sst\_rule
```

```
Entrada:
```

```
- base\_table: PointerIndex
```

```
Regra: SST =
```

- Atrasado se QUALQUER milestone tiver Data Final Real $>$ Planejada
- Em dia se todas as datas reais $\leq$ planejadas
- Atenção se houver variação de custo acima de 10\% mesmo sem atraso o riscos com impacto alto ou médio em aberto

Saída: tabela [Projeto, Período, SST, Justificativa, pointers_usados]

Nessa etapa, o modelo é orientado a percorrer os marcos, valores financeiros e riscos do corpus, aplicando a lógica do semáforo e registrando, para cada projeto, um rótulo de status acompanhado de uma justificativa e das referências às células que sustentam o cálculo.

O resultado esperado é a geração de um conjunto de classificações automáticas — Em dia, Atenção ou Atrasado — que servem de insumo para a composição da seção de status no relatório final.

Essas duas ferramentas, em conjunto, simulam o funcionamento analítico do MCP: uma descobre as evidências e a outra aplica as regras objetivas sobre os dados.

Etapa 3 — Geração do Relatório

A terceira etapa é a mais interpretativa do *pipeline* e representa a execução do *prompt* principal de geração, responsável por redigir o relatório executivo conforme o protocolo TGRP. Nessa fase, o GPT-5 utiliza as evidências e classificações previamente obtidas para compor uma narrativa estruturada, seguindo as seções e convenções definidas pelo protocolo.

O *prompt* empregado nesta etapa foi o seguinte:

```
MCP.prompts.load: TGRP\_v1
```

```
Diretrizes:
```

```
1) Estrutura obrigatória do relatório (em Markdown):
```

```
### Sumário Executivo
```

```
### Variações de Prazo, Custo e Recursos
```

```
### Top 5 Riscos e Pendências
```

```
### Status-Schedule-Trend (SST)
```

```
### Parecer do Assistente Virtual de Governança
```

```
### Fontes
```

```
2) Todo o texto deve ser narrativo, coeso e interpretativo,
mas com base 100\% factual.
```

```
3) Cada frase assertiva deve terminar com um número sequencial [n] que
se refere à fonte
```

- 4) O cálculo do SST deve seguir a regra da etapa anterior (Atrasado / Atenção / Em dia), com a justificativa e os ponteiros citados no formato sequencial [n],[n]..., seguindo o mesmo padrão da seção Fontes
- 5) Em Top 5 Riscos, listar os eventos de maior severidade, resumindo evento, causa, impacto e responsável.
- 6) O Parecer do Assistente Virtual de Governança deve consolidar as evidências, emitir recomendações prescritivas fundamentadas e NUNCA introduzir dados inéditos.
- 7) A seção Fontes deve consolidar todas as citações usadas, uma por linha no formato:[Fonte: n Corpus Protótipo#Aba!Célula].
- 8) Em nenhuma seção devem aparecer ponteiros no formato de caminho de célula. Todos os apontamentos devem ser representados apenas por seus índices sequenciais [n] definidos na seção Fontes

Gere o RELATÓRIO EXECUTIVO completo para o período [Informar MES/ANO] e projeto(s) [Informar projeto].

Esse *prompt* orienta o modelo a combinar os dados processados com as regras de redação do TGRP, produzindo uma saída estruturada e padronizada. O resultado esperado é um relatório em formato *Markdown*, dividido nas seis seções obrigatórias: Sumário Executivo, Variações de Prazo, Custo e Recursos, Top 5 Riscos e Pendências, SST, Parecer do Assistente Virtual de Governança e Fontes.

Cada seção deve apresentar uma narrativa sintética e objetiva, construída a partir das evidências previamente mapeadas. Todas as frases assertivas devem ser acompanhadas do respectivo ponteiro canônico, que indica a célula de origem no *workbook*.

Ao final dessa etapa, o modelo consolida o ciclo de execução do MCP — iniciando com o registro da fonte, processando as evidências e finalizando com a geração do texto estruturado. O processo resulta em um artefato de saída que representa o relatório executivo completo, compatível com o formato exigido pelo TGRP e pronto para exportação e avaliação. Todo o raciocínio do modelo ocorre dentro do contexto governado, sem inferências externas. Assim, o processo mantém consistência semântica e rastreabilidade total.

4.4.3 Exemplos de Execução

Esta subseção apresenta a execução integral do protótipo, evidenciando a forma como o pipeline baseado em MCP opera de ponta a ponta — do registro do recurso à redação do relatório executivo final. O objetivo é demonstrar a aplicação prática das três etapas descritas na seção anterior, bem como ilustrar a rastreabilidade das evidências, a coerência temporal dos dados e a conformidade do resultado com o protocolo TGRP.

Parâmetros de Entrada:

Para a demonstração, foi selecionado o **Projeto P-003 – Sistema de Monitoramento Operacional**, referente ao período de **julho a setembro de 2025**, com dados provenientes do workbook considerado neste trabalho e detalhado no apêndice A.

Saída da Etapa 1: Carregamento dos dados

Conforme apresentado na Figura 5 abaixo, esse resultado confirma que o ambiente de inferência foi corretamente delimitado e que o modelo reconheceu o corpus como repositório único de evidências — condição essencial para a rastreabilidade e a reprodutibilidade das saídas.

Figura 5 – Evidencia da saída da etapa 1 de carregamento dos dados

As instruções foram carregadas corretamente 

O recurso "Corpus Protótipo.xlsx" foi registrado como a única base factual permitida, com a política de que toda frase assertiva deve terminar com um número sequencial [n].

Após a leitura do workbook, foram detectadas as seguintes abas:

1. Projeto
2. Milestones_projeto
3. Atividades_projeto
4. Historico_atividades
5. RAID_Log
6. WBS
7. Budget
8. Recursos
9. Plano_alocacao

Fonte: Elaboração própria, com apoio do ChatGPT (OpenAI, 2025)

Saída da Etapa 2: Execução de Ferramentas

a) Ferramenta *pointer_index*: Mapeamento de evidências

O modelo percorreu o *workbook* e produziu uma tabela de inventário de evidências (*PointerIndex*), associando cada fato relevante ao seu ponteiro canônico, no formato Corpus Protótipo.xlsx#Aba!Célula. Esse inventário constitui o mapa de ponteiros que será utilizado nas próximas etapas para justificar cada afirmação no texto narrativo, conforme evidenciado na Figura 6.

b) Ferramenta *sst_rule*: Cálculo do indicador de status

Com base na tabela *PointerIndex*, foi aplicada a regra objetiva do SST, cruzando

Figura 6 – Evidência da saída da etapa 2 de mapeamento de evidências (amostra)

PointerIndex — Projeto P-003						
Projeto	Período	fact	sheet	cell	pointer	value
P-003	—	Identificador do projeto	Projeto	A3	Corpus Protótipo#Projeto!A3	P-003
P-003	—	Status do projeto	Projeto	D3	Corpus Protótipo#Projeto!D3	Em andamento
P-003	—	Gerente responsável	Projeto	E3	Corpus Protótipo#Projeto!E3	[lacuna]
P-003	Planejado	Início do marco "Planejamento"	Milestones_projeto	C5	Corpus Protótipo#Milestones_projeto!C5	01/02/2025
P-003	Realizado	Conclusão do marco "Planejamento"	Milestones_projeto	D5	Corpus Protótipo#Milestones_projeto!D5	12/02/2025
P-003	Planejado	Início do marco "Execução"	Milestones_projeto	C6	Corpus Protótipo#Milestones_projeto!C6	13/02/2025
P-003	Realizado	Conclusão do marco "Execução"	Milestones_projeto	D6	Corpus Protótipo#Milestones_projeto!D6	[lacuna]

Fonte: Elaboração própria, com apoio do ChatGPT (OpenAI, 2025)

cronograma, orçamento e riscos. A ferramenta analítica retornou o rótulo Atenção, refletindo uma leve divergência de prazo e a existência de riscos abertos de impacto médio, insumos que alimentam a seção de status do relatório final, conforme demonstrado na figura 7.

Figura 7 – Evidência de amostra da saída da etapa 2 de cálculo do indicador de status

Resultado da Regra SST — Projeto P-003				
Projeto	Período	SST	Justificativa	pointers_usados[]
P-003	Mês corrente	Atenção	Nenhum marco ultrapassou o prazo planejado, porém o custo realizado (119 500) está 4,4% abaixo do planejado (125 000) — dentro do limite. No entanto, há riscos em aberto com impacto médio ("Estouro de prazo de 10 dias", "Retrabalho e atraso"), o que justifica estado <i>Atenção</i> .	[Corpus Protótipo#Milestones_projeto!C5, Corpus Protótipo#Milestones_projeto!D5, Corpus Protótipo#Milestones_projeto!C6, Corpus Protótipo#Milestones_projeto!D6, Corpus Protótipo#Budget!E3, Corpus Protótipo#Budget!F3, Corpus Protótipo#RAID_Log!D4, Corpus Protótipo#RAID_Log!D5]

Fonte: Elaboração própria, com apoio do ChatGPT (OpenAI, 2025)

Saída da Etapa 3: Geração do Relatório

Relatório Executivo -- Projeto P-003

Período de Referência: Setembro/2025
Sumário Executivo

O projeto P-003 encontra-se em andamento, apresentando boa aderência entre planejamento e execução [1]. Os marcos concluídos foram finalizados dentro dos prazos planejados, sem registros de atrasos [2]. O custo realizado no mês foi de R\$119.500, inferior ao orçamento previsto de R\$125.000, representando uma variação favorável de - 4,4 % [3]. Apesar do controle orçamentário e cronograma estáveis, há riscos operacionais de impacto médio em aberto, o que requer atenção preventiva da equipe de gestão [4].

Variações de Prazo, Custo e Recursos

O marco de Planejamento iniciou-se em 01/02/2025 e foi concluído em 12/02/2025, dentro do prazo estipulado [5],[6]. O marco de Execução começou em 13/02/2025 e permanece ativo, sem data de encerramento registrada [7],[8].

No âmbito financeiro, o custo planejado de R\$ 125.000 e o realizado de R\$ 119.500 confirmam eficiência orçamentária, sem desvios relevantes [9],[10].

Entre os recursos, o Recurso 1 contabiliza 160 horas planejadas a R\$ 85/hora, enquanto o Recurso 2 apresenta 140 horas planejadas, mas com valor-hora ainda não informado [11],[12],[13],[14]. Essa lacuna de custo-hora deve ser sanada para garantir o fechamento correto do orçamento.

Top 5 Riscos e Pendências

Atraso na entrega de fornecedor -- provocado por dependência de peça importada, com impacto potencial de 10 dias de atraso. Responsável: Compras [15],[16],[17],[18].

Falha de integração do sistema -- decorrente de incompatibilidade de versão, gerando retrabalho e possível atraso. Responsável: TI [19],[20],[21],[22].

Os demais riscos permanecem sem detalhamento, caracterizando [lacunas] que devem ser atualizadas [23],[24],[25].

Status - Schedule - Trend (SST)

O projeto não apresenta marcos atrasados, uma vez que as datas reais não ultrapassaram as planejadas [26]. O custo realizado está dentro da faixa de tolerância de ± 10 % [27]. Contudo, riscos de impacto médio permanecem abertos, justificando a classificação: Atenção.

Justificativa: Nenhum marco ultrapassou o prazo planejado; o custo está dentro da margem de tolerância; entretanto, existem riscos em aberto de severidade média relacionados a fornecedor e integração [26],[27],[28],[29].

Parecer do Assistente Virtual de Governança

Com base nas evidências, o projeto P-003 mantém desempenho consistente, com boa execução orçamentária e gestão adequada de cronograma [30]. Entretanto, a falta de valor-hora para parte dos recursos e a existência de riscos operacionais abertos evidenciam vulnerabilidades que devem ser mitigadas [31].

Recomenda-se:

Atualizar o cadastro de recursos com os valores-hora faltantes;

Reforçar o monitoramento das dependências externas e da integração de sistemas;

Registrar as datas reais dos marcos de execução para assegurar rastreabilidade;

Fontes

[Fonte: 1 Corpus Protótipo#Projeto!D3]
[Fonte: 2 Corpus Protótipo#Milestones_projeto!C5]
[Fonte: 3 Corpus Protótipo#Budget!F3]
[Fonte: 4 Corpus Protótipo#RAID_Log!D4]
[Fonte: 5 Corpus Protótipo#Milestones_projeto!C5]
[Fonte: 6 Corpus Protótipo#Milestones_projeto!D5]
[Fonte: 7 Corpus Protótipo#Milestones_projeto!C6]
[Fonte: 8 Corpus Protótipo#Milestones_projeto!D6]
[Fonte: 9 Corpus Protótipo#Budget!E3]
[Fonte: 10 Corpus Protótipo#Budget!F3]
[Fonte: 11 Corpus Protótipo#Plano_alocacao!D10]
[Fonte: 12 Corpus Protótipo#Recursos!C10]
[Fonte: 13 Corpus Protótipo#Plano_alocacao!D11]
[Fonte: 14 Corpus Protótipo#Recursos!C11]
[Fonte: 15 Corpus Protótipo#RAID_Log!B4]
[Fonte: 16 Corpus Protótipo#RAID_Log!C4]
[Fonte: 17 Corpus Protótipo#RAID_Log!D4]
[Fonte: 18 Corpus Protótipo#RAID_Log!E4]
[Fonte: 19 Corpus Protótipo#RAID_Log!B5]
[Fonte: 20 Corpus Protótipo#RAID_Log!C5]
[Fonte: 21 Corpus Protótipo#RAID_Log!D5]

```
[Fonte: 22 Corpus Protótipo#RAID_Log!E5]
[Fonte: 23 Corpus Protótipo#RAID_Log!B6]
[Fonte: 24 Corpus Protótipo#RAID_Log!B7]
[Fonte: 25 Corpus Protótipo#RAID_Log!B8]
[Fonte: 26 Corpus Protótipo#Milestones_projeto!D5]
[Fonte: 27 Corpus Protótipo#Budget!F3]
[Fonte: 28 Corpus Protótipo#RAID_Log!D4]
[Fonte: 29 Corpus Protótipo#RAID_Log!D5]
[Fonte: 30 Corpus Protótipo#Projeto!A3]
[Fonte: 31 Corpus Protótipo#Recursos!C11]
[Fonte: 32 Corpus Protótipo#Milestones_projeto!D6]
[Fonte: 33 Corpus Protótipo#Projeto!A3]
```

Com o recurso e as evidências já processadas, o modelo executou o *prompt* principal TGRP_v1, responsável pela geração textual do relatório executivo estruturado em *Markdown*. A seguir, apresenta-se a saída integral produzida pelo sistema.

4.4.4 Avaliação dos Resultados

A avaliação do protótipo mínimo viável concentrou-se em três critérios previamente definidos: (i) agilidade na geração do relatório em comparação ao processo manual, (ii) estrutura e conteúdo que permitam comparabilidade entre iniciativas (iii) validação manual dos dados do relatório para confirmar se conteúdo corresponde à realidade e (iv) acessibilidade e verificabilidade das evidências que sustentam cada afirmação.

Embora o corpus utilizado tenha caráter sintético e, portanto, não permita mensurar ganhos de tempo em condições reais de operação, a execução do experimento evidenciou potencial expressivo de automação. O fluxo completo — composto pelas etapas de registro de recurso, carregamento de *prompt* e geração de relatório — foi executado de forma contínua e reproduzível, dispensando tarefas manuais de consolidação e formatação.

No segundo critério, referente à comparabilidade entre iniciativas, o resultado obtido foi satisfatório. O relatório gerado seguiu o modelo padronizado do TGRP, contendo seções fixas — Sumário Executivo, Variações de Prazo, Custo e Recursos, Top 5 Riscos e Pendências, SST e Parecer do Assistente Virtual de Governança — com linguagem e estrutura uniformes. Essa consistência garante que relatórios de diferentes projetos possam ser confrontados entre si sem ambiguidade de formato, favorecendo a análise transversal e a comunicação executiva. A saída em *Markdown* reforçou essa interoperabilidade, viabilizando conversões automáticas para apresentações ou painéis, conforme previsto no desenho do MVP. O terceiro critério, relativo à verificabilidade das evidências, apresentou desempenho plenamente aderente ao propósito da pesquisa. Cada frase assertiva no relatório foi acompanhada de um identificador sequencial [n], remetendo à seção “Fontes”. Essa

mecânica confere ao artefato propriedades de auditabilidade e explicabilidade, permitindo que qualquer leitor reconstitua o vínculo entre o texto e os dados que o fundamentam — princípio central do TGRP. A rastreabilidade implementada pelo MCP assegura, adicionalmente, que futuras iterações do relatório possam recuperar contexto atualizado sem perda de integridade.

Além desses aspectos, observou-se que o modelo elimina boa parte da subjetividade inerente ao processo manual de elaboração de relatórios. As classificações e julgamentos são derivados de regras explícitas (como o cálculo do SST) e de evidências citadas diretamente a partir do corpus, reduzindo a influência de percepções individuais sobre o status do projeto. Essa objetividade é fundamental para elevar a confiabilidade das informações apresentadas e assegurar coerência entre ciclos de reporte.

Em síntese, os resultados obtidos confirmam a viabilidade técnica e conceitual do protótipo. Esses achados indicam que o MVP cumpre sua função como prova de conceito e fornece evidências suficientes para prosseguir com uma fase de validação ampliada em contexto real, na qual métricas de tempo e custo possam ser quantificadas com maior precisão.

5 CONCLUSÃO

O presente trabalho teve como tema central a aplicação da Inteligência Artificial Generativa na governança de projetos, com foco na automação, padronização e rastreabilidade de relatórios executivos. Partiu-se do reconhecimento de que, mesmo com a evolução de *frameworks* como o PMBOK, o PRINCE2 e as práticas ágeis, ainda persiste uma lacuna significativa na capacidade dos Escritórios de Projetos de produzirem relatórios consistentes, comparáveis e auditáveis. O objetivo geral consistiu em desenvolver o TGRP, fundamentado em LLMs e MCP, capaz de estruturar relatórios executivos padronizados e assegurar a rastreabilidade entre afirmações e suas evidências de origem.

Os resultados obtidos demonstraram a viabilidade técnica e conceitual da integração entre LLMs e MCP para gerar relatórios narrativos de governança com rastreabilidade e padronização. O MVP desenvolvido neste estudo comprovou que é possível automatizar a produção do relatório executivo conforme as diretrizes do TGRP, consolidando dados provenientes de múltiplas fontes, estruturando seções padronizadas e registrando metadados técnicos de versão e origem. A aplicação do protocolo permitiu validar critérios de completude de dados, consistência factual e reprodutibilidade das saídas. O modelo proposto demonstrou que cada sentença assertiva pode ser associada a uma evidência de origem, permitindo auditoria integral e assegurando transparência no processo de comunicação com os *stakeholders*. Assim, o TGRP mostra-se uma alternativa prática para aprimorar a governança de informações de PMOs, fortalecendo a confiabilidade dos relatórios e o alinhamento entre dados e decisões.

Avaliação do atendimento dos objetivos específicos. A partir da implementação e validação do protótipo, foi possível avaliar o cumprimento dos objetivos específicos delineados na Subseção 1.3.2. A síntese é apresentada a seguir:

- 1) **Protótipo mínimo viável (MVP) para validação do TGRP.** O objetivo foi integralmente atendido.
 - a) O pipeline baseado em LLMs integrados via MCP foi implementado e executado com sucesso;
 - b) O sumário executivo foi produzido com ancoragem explícita em evidências e indicação de lacunas;
 - c) As variações de prazo foram calculadas a partir da integração entre *milestones*, atividades e histórico;
 - d) As variações de custo foram reportadas por meio da comparação entre valores planejados e realizados;

- e) As variações de recursos foram consolidadas a partir do plano de alocação, disponibilidade e custo/hora;
 - f) O *Top-5* riscos foi estruturado com justificativas baseadas em sinais objetivos;
 - g) Problemas e decisões pendentes foram consolidados conforme registros do RAID;
 - h) O indicador Status–Schedule–Trend (SST) foi calculado aplicando regras objetivas e justificadas;
 - i) O parecer do Assistente Virtual de Governança foi gerado de forma segregada e fundamentada.
- 2) **Projetar esquema de dados e renderização dos resultados.** O objetivo foi plenamente atingido. A saída estruturada em *Markdown* mostrou-se adequada para renderização automática em PowerPoint (PPT) e PDF, mantendo interoperabilidade e padronização.
- 3) **Viabilizar auditoria e reprodutibilidade.** O objetivo foi parcialmente atendido. O MVP implementou a rastreabilidade entre afirmações e suas respectivas evidências por meio de ponteiros canônicos, garantindo reprodutibilidade do conteúdo factual e transparência na formação do relatório. Entretanto, elementos adicionais previstos no escopo — como o registro automático da versão do modelo, do *hash* do template e dos parâmetros de geração — não foram implementados no protótipo atual, configurando uma oportunidade de evolução para as próximas etapas de desenvolvimento.

Do ponto de vista acadêmico e prático, a pesquisa contribui para o campo da Inteligência Artificial aplicada à gestão e governança de projetos ao propor uma arquitetura inédita que combina IA Generativa e governança de dados sob princípios de rastreabilidade e auditabilidade. Teoricamente, oferece um modelo de referência que complementa a literatura existente — predominantemente voltada à previsão de prazos e custos — ao abordar uma dimensão ainda pouco explorada: a automação da comunicação executiva baseada em evidências. Na esfera prática, apresenta um caminho implementável para que PMOs reduzam o esforço manual na consolidação de informações e aprimorem a padronização e a rastreabilidade de seus artefatos de governança.

Entre as limitações observadas, destaca-se o fato de que a validação do protótipo ocorreu em ambiente controlado e com base em dados sintéticos, o que restringe sua generalização imediata para contextos corporativos reais. Essa condição evidencia a necessidade de avançar para fases posteriores de implantação, nas quais o protocolo possa ser efetivamente conectado a ecossistemas organizacionais. A transição da prova de conceito para o ambiente real requer ajustes estruturais, integração com sistemas legados e ferramentas de gestão de projetos, como Jira, Power BI ou Microsoft Project, além do estabelecimento de políticas de segurança, versionamento de *prompts* e auditoria das

inferências. Somente a partir dessa integração o modelo poderá operar de forma segura, versionada e auditável, em conformidade com padrões corporativos de governança de dados e *compliance* regulatório.

Nessa direção, para trabalhos futuros, sugerem-se quatro frentes complementares. A primeira consiste em conectar o modelo a ambientes organizacionais reais, substituindo os dados sintéticos por integrações diretas com sistemas corporativos de gestão de projetos, utilizando APIs e conectores compatíveis com o MCP. A segunda propõe o desenvolvimento de uma interface conversacional para o gerente de projetos, permitindo consultas abertas sobre o portfólio e respostas contextualizadas com base em dados reais da organização. A terceira linha de evolução envolve o aprimoramento do próprio MCP com técnicas avançadas de processamento da requisição do usuário, em especial a reescrita de *prompt*, permitindo decompor e refinar a instrução original e reduzir ambiguidades semânticas antes da recuperação de evidências. Por fim, a quarta propõe a evolução do Assistente Virtual de Governança de um agente reativo, baseado em critérios objetivos, para um agente cognitivo de recomendação, capaz de sugerir boas práticas de governança e gestão de projetos fundamentadas em políticas internas e *frameworks* institucionais como PMBOK e PRINCE2.

Conclui-se que o *Traceable Governance Reporting Protocol* (TGRP), aliado ao *Model Context Protocol* (MCP) e aos *Large Language Models* (LLMs), representa uma contribuição concreta e inovadora para a área de governança de projetos. O modelo desenvolvido demonstra que a Inteligência Artificial Generativa pode ser integrada de forma auditável, transparente e padronizada aos processos de *reporting* corporativo, fortalecendo o elo entre dados, narrativa e decisão e configurando um avanço relevante para a transformação digital da governança de projetos em organizações.

REFERÊNCIAS

ACCENTURE. **New Accenture Research Finds that Companies with AI-Led Processes Outperform Peers**. 2024. Press release oficial publicado em 10 out. 2024. Accenture Newsroom. Disponível em: <https://newsroom.accenture.com/news/2024/new-accenture-research-finds-that-companies-with-ai-led-processes-outperform-peers>. Acesso em: 13 set. 2025.

ACCENTURE. **Reinventing Enterprise Operations with Gen AI**: New research finds that companies with ai-led processes outperform peers. 2024. Relatório corporativo. Accenture Research, 2024. Disponível em: <https://newsroom.accenture.com/news/2024/new-accenture-research-finds-that-companies-with-ai-led-processes-outperform-peers>. Acesso em: 13 set. 2025.

Anthropic. **Model Context Protocol (MCP)**. 2024. Publicação institucional sobre o protocolo de contexto de modelos (MCP). Disponível em: <https://www.anthropic.com/news/model-context-protocol>. Acesso em: 15 out. 2025.

AXELOS Limited. **Managing Successful Projects with PRINCE2**. 6th ed.. ed. The Stationery Office, 2017. Guia oficial do método PRINCE2, publicado pela AXELOS. Disponível em: <https://www.axelos.com/resource-hub/book/managing-successful-projects-prince2-2017-edition>. Acesso em: 15 out. 2025.

Bloomberg Intelligence. **Generative AI – 2024 Report: Assessing Opportunities and Disruptions in an Evolving Trillion-Dollar Market**. 2024. Relatório de pesquisa. Disponível em: <https://www.bloomberg.com/professional/products/bloomberg-terminal/research/bloomberg-intelligence/download/generative-ai-2024-report/>. Acesso em: 18 out. 2025.

BUBECK, S. *et al.* **Sparks of Artificial General Intelligence: Early experiments with GPT-4**. 2023. Disponível em: <https://arxiv.org/abs/2303.12712>.

CHIARELLO, F. *et al.* Future applications of generative large language models: A data-driven case study on chatgpt. Elsevier, v. 133, p. 103002, 2024.

DEVLIN, J. *et al.* Bert: Pre-training of deep bidirectional transformers for language understanding. *In: Proceedings of the 2019 conference of the North American chapter of the association for computational linguistics: human language technologies, volume 1 (long and short papers)*. [S.l.: s.n.], 2019. p. 4171–4186.

FELICETTI, A. M. *et al.* Artificial intelligence and project management: An empirical investigation on the appropriation of generative chatbots by project managers. 2024. ISSN 2444-569X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2444569X24000842>.

FOROUZESHNEJAD, A. A.; ARABIKHAN, F.; AHELEROFF, S. Optimizing project time and cost prediction using a hybrid xgboost and simulated annealing algorithm. MDPI, v. 12, n. 12, p. 867, 2024.

GAO, N. *et al.* Construction risk identification using a multi-sentence context-aware method. Elsevier, v. 164, p. 105466, 2024.

Gartner. **Gartner Says 80 Percent of Today's Project Management Tasks Will Be Eliminated by Artificial Intelligence in 2030**. 2019. Press release. Stamford, CT: Gartner, 20 mar. 2019. Disponível em: <https://www.gartner.com/en/newsroom/press-releases/2019-03-20-gartner-says-80-percent-of-today-s-project-management>. Acesso em: 10 set. 2025.

Harvard Business Review. **How Generative AI is Changing Project Teams**. 2023. Disponível em: <https://hbr.org/2023/02/how-ai-will-transform-project-management>. Acesso em: 15 out. 2025.

JURAFSKY, D.; MARTIN, J. H. **Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models**. 3rd. ed. [S.l.: s.n.], 2025. Online manuscript released August 24, 2025. Disponível em: <https://web.stanford.edu/~jurafsky/slp3/>.

KERZNER, H. **Project management: a systems approach to planning, scheduling, and controlling**. [S.l.: s.n.]: John Wiley & Sons, 2025.

McKinsey & Company. **The Economic Potential of Generative AI: The next productivity frontier**. 2023. Relatório técnico. Disponível em: <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/the-economic-potential-of-generative-ai-the-next-productivity-frontier>. Acesso em: 15 out. 2025.

McKinsey & Company. **The State of AI: How Organizations Are Rewiring to Capture Value**. [S.l.], 2025. Disponível em: <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/a-generative-ai-reset-rewiring-to-turn-potential-into-value-in-2024>. Acesso em: 18 out. 2025.

McKinsey & Company. **Upgrading Software Business Models to Thrive in the AI Era**. [S.l.], 2025. Disponível em: <https://www.mckinsey.com/industries/technology-media-and-telecommunications/our-insights/upgrading-software-business-models-to-thrive-in-the-ai-era>. Acesso em: 18 out. 2025.

MIKOLOV, T. *et al.* Efficient estimation of word representations in vector space. 2013.

OpenAI. **Introducing GPT-5**. 2025. Artigo institucional publicado no site oficial da OpenAI. Disponível em: <https://openai.com/index/introducing-gpt-5/>. Acesso em: 15 out. 2025.

OSTERWALDER, A.; PIGNEUR, Y. **Business Model Generation: inovação em modelos de negócios**. [S.l.: s.n.]: Alta Books, 2011.

PAL, D. K. D. *et al.* Ai-assisted project management: Enhancing decision-making and forecasting. v. 3, p. 146–171, 2023.

PENNINGTON, J.; SOCHER, R.; MANNING, C. D. Glove: Global vectors for word representation. *In: Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*. [S.l.: s.n.], 2014. p. 1532–1543.

Project Management Institute. **A Guide to the Project Management Body of Knowledge (PMBOK® Guide)**. 7th ed.. ed. [S.l.: s.n.]: Project Management Institute, 2021. Guia oficial de boas práticas em gestão de projetos.

Project Management Institute. **Pulse of the Profession 2023: Power Skills, Redefining Project Success**. Project Management Institute, 2023. 14th edition. Relatório técnico anual do PMI. Disponível em: <https://www.pmi.org/learning/thought-leadership/pulse/power-skills-redefining-project-success>. Acesso em: 15 out. 2025.

Project Management Institute. **First Movers' Advantage: The Immediate Benefits of Adopting Generative AI for Project Management**. Project Management Institute, 2024. Relatório técnico sobre os benefícios da adoção de IA generativa na gestão de projetos. Disponível em: <https://www.pmi.org/learning/thought-leadership/benefits-of-ai-for-project-management>. Acesso em: 15 out. 2025.

Project Management Institute. **Pulse of the Profession 2024: The Future of Project Work — Moving Past Office-Centric Models**. Project Management Institute, 2024. 15th edition. Relatório técnico anual do PMI. Disponível em: <https://www.pmi.org/learning/thought-leadership/pulse/the-future-of-project-work>. Acesso em: 15 out. 2025.

RADFORD, A. *et al.* Improving language understanding by generative pre-training. San Francisco, CA, USA, 2018.

RAFFEL, C. *et al.* Exploring the limits of transfer learning with a unified text-to-text transformer. v. 21, n. 140, p. 1–67, 2020.

RUSSELL, S.; RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. Pearson, 2020. (Pearson series in artificial intelligence). ISBN 9780134610993. Disponível em: <https://books.google.com.br/books?id=koFptAEACAAJ>.

SHOUSHTARI, F.; DAGHIGHI, A.; GHAFOURIAN, E. Application of artificial intelligence in project management. v. 6, n. 2, p. 49–63, 2024. Disponível em: <https://bgsiran.ir/journal/ojs-3.1.1-4/index.php/IJIEOR/article/view/89>.

VASWANI, A. *et al.* Attention is all you need. v. 30, 2017.

ZADEH, E. K.; KHOULENJANI, A. B.; SAFAEI, M. Integrating ai for agile project management: Innovations, challenges, and benefits. v. 1, n. 1, p. 1–10, 2024.

APÊNDICES

APÊNDICE A – ESTRUTURA RELACIONAL DO CORPUS PROTÓTIPO

O *Corpus* utilizado neste trabalho constitui a base de dados utilizada pelo Assistente Virtual de Governança para geração dos relatórios executivos. Sua estrutura adota um modelo relacional que assegura coerência entre cronograma, orçamento, recursos e riscos, permitindo rastreabilidade entre eventos, indicadores e evidências utilizadas nos relatórios e simulam registros de um Escritório de Projetos.

Tabela 4 – Mapeamento das abas do *corpus* e suas chaves primárias

Aba	Chave Primária	Principais Relações
Projeto	Projeto_id	Entidade central que identifica cada projeto.
Milestones	Milestone_id	Define as fases do ciclo de vida do projeto.
Projeto_Milestones	Projeto_id + Milestone_id	Conecta projetos aos respectivos marcos.
Atividades_Projeto	Projeto_id + Milestone_id + Atividade_id	Detalha as atividades associadas a cada marco.
Histórico_- Atividades	Projeto_id + Milestone_id + Atividade_id + Data_Status	Registra as atualizações e status das atividades.
RAID_Log	Projeto_id + RAID_id	Consolida riscos, premissas, problemas e decisões.
WBS / Budget	WBS_id / Projeto_id + WBS_id + Mês/Ano	Representa a estrutura analítica e os dados de orçamento.
Recursos / Plano_alocação	Recurso_id / Projeto_id + Recurso_id	Controla o cadastro e a distribuição de recursos.

Fonte: Elaborada pela autora.