

**Uso de Sistemas Multiagentes de IA em Gerenciamento de Projetos**

**Ricardo Orlandeli Augusto**

Trabalho de Conclusão de Curso  
MBA em Inteligência Artificial e Big Data

**UNIVERSIDADE DE SÃO PAULO**  
**Instituto de Ciências Matemáticas e de Computação**

---

Uso de Sistemas Multiagentes de IA  
em Gerenciamento de Projetos

***Ricardo Orlandeli Augusto***

---

USP - São Carlos

2025

Ricardo Orlandeli Augusto

## Uso de Sistemas Multiagentes de IA em Gerenciamento de Projetos

Trabalho de conclusão de curso apresentado 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. Júlio Cesar Estrella.

USP - 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)

O71u Orlandeli Augusto, Ricardo  
Uso de sistemas multiagentes de IA em Gerenciamento de Projeto / Ricardo Orlandeli Augusto; orientador Júlio Estrella. -- São Carlos, 2025.  
115 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. Sistemas multiagentes de IA. 2. Gerenciamento de Projetos. I. Estrella, Julio, orient. II. Título.

Bibliotecários responsáveis pela estrutura de catalogação da publicação de acordo com a AACR2:  
Gláucia Maria Saia Cristianini - CRB - 8/4938  
Juliana de Souza Moraes - CRB - 8/6176



## DEDICATÓRIA

Dedico esse trabalho de conclusão do MBA de IA e Big Data a minha família – minha esposa Luciana e meus 3 filhos: Benicio, Valentina e Gael. Minha esposa que sempre acreditou em mim, até mais do que eu mesmo em muitas circunstâncias, pelo incentivo e apoio em buscar novos conhecimentos. Agradeço pela sensibilidade e difícil decisão de abrir mão da graduação em Pedagogia para que eu pudesse me dedicar ao MBA. Pelo cuidado e atenção com nossa família mesmo quando a carga emocional aumentava, somando-se a isso a mudança de cidade, 2 mudanças de residência que impactaram muito na conciliação de acomodar todas as rotinas, e principalmente os estudos.

Agradeço aos meus filhos por cooperarem, entenderem e aceitarem abrir mão do tempo de brincar, passear e se divertir em família para que eu pudesse assistir as aulas durante a semana à noite, mas principalmente aos Sábados pelas manhãs em que muitos planos tiveram que ser remanejados. E ao final da entrega deste trabalho, tiveram a compreensão e forneceram apoio para tudo pudesse ser concluído dentro do que foi possível fazer e entregar.

*A minha esposa Luciana pela  
compreensão, carinho, dedicação,  
sustentação e apoio.*

## AGRADECIMENTOS

Ao meu orientador Júlio Cesar, que muito me ensinou e direcionou contribuindo para o meu crescimento científico.

A professora Solange, pelo incentivo e apoio nos momentos de dificuldade.

Aos professores que dispenderam de horas de planejamento, dedicação e carinho para criar o conteúdo de cada uma das aulas de curso.

Ao professor Ricardo Marcacini pelo acolhimento nas primeiras tutorias, mostrando empatia e nos dando abertura de perguntar e discutir ideias.

Aos organizadores, tutores e time de coordenação do MBA, pelo suporte, apoio e dedicação em resolver todos os problemas com as ferramentas e notebooks de apoio das aulas.

Aos colegas de MBA, pelo apoio, incentivo e troca de experiências enriquecedoras.

Aos colegas de MBA que organizaram e realizaram um encontro presencial em São Carlos, muito enriquecedor onde pudemos nos conhecer pessoalmente.

## EPÍGRAFE

*“A inteligência coletiva emerge quando indivíduos colaboram e coordenam suas ações para atingir objetivos comuns.”*

**LÉVY, Pierre.**

## RESUMO

AUGUSTO, RICARDO ORLANDELI. P. **Uso de Sistemas Multiagentes em Gerenciamento de Projetos.** 2025. 52 f. Monografia (MBA em IA e Big Data) – Centro de Ciências Matemáticas Aplicadas à Indústria, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

O ambiente corporativo contemporâneo de negócios e de tecnologia vem se transformando de forma acelerada e tornou os projetos mais complexos. Essa complexidade exige novas abordagens para apoiar decisões e garantir entregas dentro de prazo, orçamento e escopo. Este estudo apresenta o desenvolvimento e a avaliação de um sistema de inteligência artificial baseado em sistemas multiagentes aplicados ao gerenciamento de projetos. O foco recai sobre análise de desempenho, recomendações automatizadas e redução proativa de riscos decorrentes de análises tardias ou incompletas ao longo do ciclo de vida dos projetos.

A solução emprega uma arquitetura híbrida de RAG (busca lexical, via TF-IDF, e semântica, via S-BERT), combinada a LLMs e a guardrails derivados do PMBOK® 7ª edição. Agentes especializados atuam em domínios de cronograma, custos, riscos, escopo, qualidade e comunicação. Eles executam análises, sugerem ações corretivas e preventivas e interagem para elevar a precisão dos insights. A validação experimental utiliza um dataset sintético temporal de 1.000 projetos e simulações longitudinais em múltiplas rodadas.

Os resultados indicam melhorias significativas em SPI, CPI, ROI e taxa de sucesso dos projetos. A abordagem promove uma gestão mais proativa, explicável e eficiente, além de oferecer um caminho promissor para a evolução de sistemas de apoio à decisão em portfólios corporativos.

Palavras-chave: Sistemas multiagentes. Inteligência Artificial. Gerenciamento de Projetos. RAG. PMBOK.

## ABSTRACT

AUGUSTO, RICARDO ORLANDELI. P. **Usage of Multi-Agents of AI in Project Management.** 2025. 52 f. Monografia (MBA em IA e Big Data) – Centro de Ciências Matemáticas Aplicadas à Indústria, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

The contemporary corporate and technological environment has undergone rapid transformation, increasing the complexity of projects. This complexity demands new approaches to support decision-making and ensure delivery within schedule, budget, and scope constraints. This study presents the development and evaluation of an artificial intelligence system based on multi-agent systems applied to project management. The focus lies on performance analysis, automated recommendations, and proactive risk mitigation to address issues arising from delayed or incomplete assessments throughout the project life cycle.

The proposed solution employs a hybrid Retrieval-Augmented Generation (RAG) architecture - combining lexical search (TF-IDF) and semantic search (S-BERT)—integrated with large language models (LLMs) and guardrails derived from the PMBOK® Guide, 7th edition. Specialized agents operate across domains such as schedule, cost, risk, scope, quality, and communication. They perform analysis, suggest corrective and preventive actions, and interact to enhance the accuracy of generated insights. Experimental validation was conducted using a synthetic temporal dataset of 1,000 projects and longitudinal simulations across multiple iterations.

The results indicate significant improvements in SPI, CPI, ROI, and overall project success rates. The proposed approach enables more proactive, explainable, and efficient project management, offering a promising pathway for the evolution of decision-support systems in corporate portfolios.

Keywords: Multi-agent systems. Project Management. Artificial Intelligence. RAG. PMBOK.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Ciclo experimental do sistema Multiagentes .....	50
Figura 2 - Arquitetura do sistema multiagentes.....	57
Figura 3 - Pipeline do RAG Híbrido: recuperação lexical e semântica, fusão, PMBOK, LLM. ....	65
Figura 4 - Arquitetura do RAG .....	68
Figura 5 - Orquestração dos Agentes .....	75
Figura 6 - Conceito básico da arquitetura CrewAI.....	81
Figura 7 - Fluxo de Decisão - dados → RAG → agentes → coordenador → LLM → relatório .....	83
Figura 8 - Fluxo de uso LLM .....	84
Figura 9 - Pipeline do experimento .....	87
Figura 10 - Linha do tempo do experimento .....	88
Figura 11 - Ciclo de cálculo e consolidação das métricas SPI, CPI e Progresso por rodada .....	89
Figura 12 - Distribuição do SPI (baseline).....	90
Figura 13 - Distribuição do CPI (baseline).....	91
Figura 14 - Evolução longitudinal.....	92
Figura 15 - Impacto estratégico e ROI .....	93
Figura 16 - Indicadores .....	94
Figura 17 - SPI por projeto .....	96
Figura 18 - CPI por projeto .....	96

## LISTA DE TABELAS

<b>Tabela 1 - Atributos do dataset de projetos para treinamento de agentes</b> .....	58
<b>Tabela 2 - Tipos de Projetos de TI</b> .....	60
<b>Tabela 3 – Conjuntos de dados de status de projetos</b> .....	62
<b>Tabela 4 - Guardrails PMBOK 7ª Edição: Princípios Oficiais</b> .....	71
<b>Tabela 5 - Guidelines PMBOK por Agente</b> .....	72
<b>Tabela 6 - Resumo dos parâmetros experimentais</b> .....	87
<b>Tabela 7 - Distribuição dos indicadores no baseline</b> .....	88
<b>Tabela 8 - Evolução dos indicadores ao longo das rodadas</b> .....	89
<b>Tabela 9 - Indicadores estratégicos pós-implantação</b> .....	93
<b>Tabela 10 - Evolução dos indicadores</b> .....	94
<b>Tabela 11 - Resultados estatísticos</b> .....	95

## LISTA DE ABREVIATURAS E SIGLAS

AC	-	Actual Cost
ABNT	-	Associação Brasileira de Normas Técnicas
BAC	-	Budget at Completion
CPI	-	Cost Performance Index
CV	-	Cost Variance
EAC	-	Estimate at Completion
EMV	-	Expected Monetary Value
ETC	-	Estimate to Complete
EV	-	Earned Value
EVA	-	Earned Value Analysis
EVM	-	Earned Value Management 1
IA	-	Inteligência Artificial
LLM	-	Large Language Model
MAS	-	Multi-Agent System
PMI	-	Project Management Institute
PMBOK	-	Project Management Body of Knowledge
PV	-	Planned Value
RAG	-	Retrieval-Augmented Generation
REI	-	Risk Exposure Index
S-BERT	-	Sentence Bidirectional Encoder Representations Transformer
SMA	-	Sistemas multiagentes
SPI	-	Schedule Performance Index
SV	-	Schedule Variance
TCPI	-	To Complete Performance Index
TF-IDF	-	Term frequency – Inverse Document Frequency
TI	-	Tecnologia da Informação

# Sumário

1. INTRODUÇÃO .....	19
1.1. Contextualização .....	19
1.2. Justificativa e Contextualização .....	20
1.3. Problema de pesquisa e objetivo .....	21
1.4. Objetivo geral e específicos .....	21
2. Fundamentação Teórica.....	22
2.1. Inteligência Artificial e Evolução dos Sistemas Multiagentes.....	22
2.2. Sistemas Multiagentes: Conceitos, Propriedades, Arquiteturas e Aplicações .....	23
2.2.1. Propriedades dos Sistemas Multiagentes .....	24
2.2.2. Tipos de Agentes e Estruturas Organizacionais.....	25
2.2.3. Comunicação, Coordenação e Cooperação .....	26
2.2.4. Aplicações Práticas dos Sistemas Multiagentes.....	27
2.3. Arquitetura de sistemas Multiagentes e Modelos de interação .....	27
2.3.1. Arquiteturas baseadas em agentes individuais .....	28
2.3.2. Arquiteturas organizacionais SMA .....	28
2.3.3. Modelos de interação entre agentes.....	29
2.3.4. Arquiteturas híbridas e Ambientes Dinâmicos .....	30
2.3.5. Considerações sobre escalabilidade e robustez .....	31
2.4. Integração de sistemas multiagentes com IA no Gerenciamento de Projetos.....	31
2.4.1. Convergência do Agente autônomo ao SMA distribuído.....	32
2.4.2. Arquitetura cognitiva integrada: SMA – RAG - LLM.....	32
2.4.3. Aplicação no gerenciamento de projetos .....	34
2.4.4. Benefícios Estratégicos e Impactos Organizacionais .....	34
2.4.5. Desafios e considerações.....	35
2.5. Vantagens, Limitações e Desafios dos Sistemas Multiagentes no Contexto Corporativo.....	36
2.5.1. Vantagens estratégicas de Sistemas Multiagentes.....	36
2.5.2. Limitações técnicas e organizacionais .....	37
2.5.3. Desafios de Adoção e Caminhos para Superação.....	38
2.5.4. Perspectivas futuras e tendências de evolução .....	39
2.6. Gerenciamento de Projetos e Fundamentos do PMBOK (7ª edição) .....	40
2.7. Aplicação de Sistemas Multiagentes no Gerenciamento de Projetos .....	41
2.8. Limitações e desafios da adoção .....	42
2.9. Perspectivas futuras .....	43
3. Metodologia .....	45
3.1. Abordagem de pesquisa .....	45
3.2. Delineamento da pesquisa.....	45
3.3. Ambiente tecnológico e ferramentas.....	47
3.4. Estrutura Experimental do Sistemas multiagentes.....	49
3.4.1. Geração do Dataset e Reprodutibilidade.....	49
3.4.2. Ciclo Experimental e Etapas de Simulação.....	50
3.5. Procedimentos experimentais .....	51

3.6. Métricas de avaliação .....	52
3.7. Garantia de reprodutibilidade.....	53
3.8. Limitações e ameaças à validade .....	54
4. Proposta e Desenvolvimento .....	55
4.1. Visão Geral da Arquitetura do Sistema .....	55
4.2. Camada de dados e conhecimento - geração dos Conjuntos de Dados (dataset) sintéticos .....	57
4.2.1. Geração de dados correlacionados .....	61
4.3. Camada de inteligência: RAG Híbrido e Guardrails PMBOK .....	64
4.4. Sistema RAG (Retrieval-Augmented Generation).....	65
4.4.1. Arquitetura do Sistema RAG .....	67
4.4.2. Funcionamento do Sistema RAG.....	69
4.5. Guardrail PMBOK .....	70
4.5.1. Funcionalidades dos Guardrails.....	72
4.5.2. Regras implementadas .....	72
4.6. Camada Multiagentes e orquestração com CrewAI .....	74
4.6.1. Agente Coordenador de Projetos.....	75
4.6.2. Agente especializado de IA - Cronograma .....	76
4.6.3. Agente especializado de IA - Custos .....	77
4.6.4. Agente especializado de IA - Escopo.....	77
4.6.5. Agente especializado de IA - Riscos.....	78
4.6.6. Agente especializado de IA - Qualidade .....	79
4.6.7. Agente especializado de IA - Comunicação.....	80
4.7. Integração com Framework CrewAI .....	81
4.7.1. Arquitetura CrewAI.....	81
4.7.2. Componentes da Integração .....	81
4.7.3. Modos de Operação.....	82
4.8. Camada de integração com LLM e Geração de insights .....	82
4.9. Uso de LLM no Sistemas multiagentes.....	83
4.9.1. Construção e Integração .....	83
4.9.2. Fluxo de Uso do LLM: .....	84
4.9.3. Vantagens da Integração Direta .....	85
5. Análise dos resultados e impactos.....	86
5.1. Introdução .....	86
5.2. Configuração Experimental.....	86
5.3. Estado inicial (baseline).....	88
5.4. Resultados após intervenção multiagentes .....	89
5.5. Análise de Desempenho Temporal: SPI .....	90
5.6. Análise de Eficiência de Custos: CPI.....	91
5.7. Análise Longitudinal e Tendências de Melhoria .....	92
5.8. Impacto Estratégico e ROI do Sistema.....	93
5.9. Evolução dos indicadores.....	94
5.10. Análise estatística e interpretação .....	95

5.11. Impactos Organizacionais e ROI.....	95
5.12. Comparação Antes e Depois: Impacto da Intervenção.....	95
5.13. Insights gerenciais e impacto organizacional .....	97
6. Conclusão do Trabalho .....	98
7.1. Fundamentação Teórica para Evolução Semântica.....	102
7.2. Arquitetura Neuro-Simbólica Proposta .....	102
7.2.1. Componentes da Arquitetura Híbrida .....	102
7.2.2. Fluxo de Processamento Integrado.....	103
7.2.3. Mecanismo de Inferência Híbrida .....	103
7.3. Ontologia de Gerenciamento de Projetos.....	104
7.3.1. Estrutura Conceitual.....	104
7.3.2. Regras de Inferência .....	105
7.3.3. Integração com Padrões Existentes .....	105
7.4. Capacidades Avançadas de Consulta e Inferência.....	106
7.4.1. Consultas SPARQL Especializadas.....	106
7.4.2. Inferência de Padrões Complexos.....	106
7.4.3. Raciocínio Temporal.....	107
7.5. Benefícios Esperados da Integração .....	107
7.5.1. Precisão Analítica Aprimorada .....	107
7.5.2. Explicabilidade e Transparência .....	108
7.5.3. Adaptabilidade e Evolução .....	108
7.6. Desafios de Implementação.....	108
7.6.1. Complexidade de Desenvolvimento .....	108
7.6.2. Escalabilidade e Performance.....	109
7.6.3. Qualidade e Consistência de Dados .....	110
7.7. Estratégias de Implementação .....	110
7.7.1. Abordagem Incremental .....	110
7.7.2. Validação Experimental Estendida .....	110
7.7.3. Integração com Ecossistemas Existentes .....	111
7.8. Implicações para Pesquisa Futura.....	111
7.8.1. Avanços em IA Neuro-Simbólica.....	111
7.8.2. Aplicações em Outros Domínios .....	112
7.8.3. Evolução de Padrões Semânticos.....	112
7.9. Considerações Finais.....	113



# 1. INTRODUÇÃO

Nos últimos anos, o cenário contemporâneo de negócios e desenvolvimento tecnológico é marcado por uma crescente complexidade e pela necessidade de gerenciar projetos de maneira eficiente e adaptável. O gerenciamento dos projetos dentro da área de Tecnologia da Informação (TI) tem se tornado cada vez mais complexos devido à crescente quantidade de dados, tecnologias, à necessidade de coordenação entre diversas equipes e à pressão por resultados rápidos e eficientes. Aliado a isso, o gerenciamento de projetos de TI também precisa lidar com múltiplas variáveis, stakeholders e recursos muitas vezes distribuídos ao redor do mundo. A necessidade de otimizar processos, alocar recursos de forma eficiente e tomar decisões eficazes em tempo real impulsiona a busca por soluções inovadoras, uma vez que as ferramentas tradicionais de gestão, embora úteis, frequentemente demandam um esforço manual significativo que carecem de análises dinâmicas em tempo real.

## 1.1. Contextualização

O cenário atual de negócios e tecnologia é caracterizado por um ambiente dinâmico, competitivo e orientado por dados, no qual as organizações precisam executar projetos cada vez mais complexos em prazos reduzidos e com altos níveis de exigência em qualidade e custo. A transformação digital acelerada, aliada ao crescimento exponencial de dados e à adoção de metodologias ágeis, tem imposto novos desafios à governança de projetos, exigindo decisões mais rápidas, precisas e baseadas em evidências.

Nesse contexto, o gerenciamento de projetos assume um papel estratégico para a entrega de valor organizacional, sendo responsável por alinhar objetivos corporativos com resultados tangíveis. Entretanto, a tomada de decisão tradicional em projetos muitas vezes ainda depende de análises manuais, relatórios fragmentados e julgamentos subjetivos, o que pode levar os gestores a incorrerem em riscos significativos, atrasos, estouros de orçamento e perda de oportunidades estratégicas.

Com o avanço da inteligência artificial (IA) e da automação, novas soluções emergem a cada dia para enfrentar esses desafios. Entre elas, destaca-se o uso de sistemas multiagentes, capazes de operar de forma distribuída, colaborativa e autônoma, ampliando a capacidade de análise e

recomendação no contexto de projetos. Ao combinar técnicas de aprendizado de máquina, processamento de linguagem natural (PLN) e arquiteturas híbridas de recuperação e geração de conhecimento (RAG), esses sistemas oferecem um novo paradigma de apoio à decisão — mais proativo, explicável e orientado a dados.

## **1.2. Justificativa e Contextualização**

A crescente complexidade dos portfólios corporativos demanda soluções que superem as limitações das abordagens tradicionais de gestão de projetos. Em organizações de grande porte, decisões tardias ou baseadas em dados incompletos podem resultar em custos adicionais significativos, impactos no cronograma e até fracasso na entrega de valor estratégico.

A motivação deste estudo decorre da lacuna observada entre a abundância de dados gerados em projetos e a escassez de mecanismos capazes de transformá-los em informações úteis, explicáveis e acionáveis. Embora métodos tradicionais de gestão (como EVM – Earned Value Management) forneçam indicadores consolidados, eles nem sempre permitem análises preditivas ou recomendações contextuais. E embora os grandes modelos de linguagem (LLMs) tragam avanços na interpretação de linguagem natural e geração de relatórios, sua utilização isolada apresenta riscos: recomendações pouco transparentes, dificuldade de rastreabilidade e possibilidade de vieses.

A aplicação de sistemas multiagentes oferece uma alternativa promissora ao permitir que agentes especializados atuem sobre diferentes dimensões do projeto — cronograma, custos, escopo, riscos, qualidade e comunicação — de forma autônoma e colaborativa. Além disso, o uso de modelos de linguagem e guardrails baseados em padrões consolidados como o PMBOK 7ª edição garante que as recomendações estejam alinhadas às melhores práticas de mercado.

Dessa forma, a proposta deste trabalho justifica-se pela necessidade de um sistema que não apenas monitore indicadores de desempenho, mas que também identifique riscos precocemente, recomende ações corretivas e preventivas e aprimore continuamente a tomada de decisão, contribuindo para maior eficiência e sucesso dos projetos.

### **1.3. Problema de pesquisa e objetivo**

Como sistemas multiagentes de inteligência artificial podem ser aplicados para melhorar a análise, a tomada de decisão e os resultados no gerenciamento de projetos corporativos?

### **1.4. Objetivo geral e específicos**

O objetivo geral deste estudo é desenvolver e validar um sistema baseado em inteligência artificial e sistemas multiagentes aplicado ao gerenciamento de projetos, capaz de analisar dados históricos e em tempo real, gerar recomendações automatizadas e apoiar a tomada de decisão em portfólios complexos.

Para alcançar este objetivo, serão explorados os seguintes objetivos específicos:

- Projetar e implementar uma arquitetura híbrida de RAG que combine busca lexical (TF-IDF), busca semântica (S-BERT) e modelos de linguagem (LLMs) com guardrails do PMBOK.
- Desenvolver agentes especializados capazes de atuar em diferentes dimensões do projeto (cronograma, custos, escopo, riscos, qualidade e comunicação).
- Criar um dataset sintético e pipelines de experimentação para avaliar a eficácia do sistema em múltiplas rodadas de simulação.
- Medir e analisar a evolução dos principais indicadores de desempenho de projetos (SPI, CPI, ROI, taxa de sucesso) antes e após a aplicação das recomendações dos agentes.
- Avaliar o impacto estratégico da solução na tomada de decisão, propondo melhorias e direções para trabalhos futuros.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1. Inteligência Artificial e Evolução dos Sistemas multiagentes

O campo da Inteligência Artificial (IA) tem evoluído de forma acelerada desde sua origem nas décadas de 1950 e 1960, quando pesquisas pioneiras buscavam simular o raciocínio humano por meio de algoritmos lógicos e programas simbólicos. Inicialmente, os esforços concentravam-se em resolver problemas restritos como jogos de tabuleiro, provas de teoremas ou resolução de quebra-cabeças dentro de ambientes controlados e bem definidos (RUSSELL; NORVIG, 2021). À medida que a capacidade computacional aumentou e o volume de dados disponíveis cresceu exponencialmente, a IA expandiu-se para aplicações mais complexas, incorporando técnicas de aprendizado de máquina, redes neurais artificiais e processamento de linguagem natural (PLN).

Atualmente, a IA é definida como o ramo da ciência da computação dedicado ao desenvolvimento de sistemas capazes de executar tarefas que exigem inteligência humana, como percepção, raciocínio, tomada de decisão, aprendizado e adaptação (RUSSELL; NORVIG, 2021). Essa definição abrange desde sistemas simples, como algoritmos de recomendação e chatbots, até aplicações avançadas em diagnósticos médicos, veículos autônomos, robótica e suporte à decisão corporativa.

Uma das evoluções mais marcantes desse campo foi a transição dos sistemas monolíticos — centrados em um único agente inteligente que concentra toda a capacidade decisória, para sistemas distribuídos compostos por múltiplos agentes cooperativos e autônomos, conhecidos como sistemas multiagentes (SMA) ou (*Multi-Agent Systems* – MAS). Essa mudança representa uma transformação de paradigma: em vez de centralizar a inteligência em um único ponto, a capacidade de percepção, raciocínio e ação é distribuída entre diversas entidades autônomas que interagem entre si e com o ambiente (WOOLDRIDGE, 2009).

Segundo Wooldridge (2009), um agente pode ser definido como um sistema computacional capaz de agir de maneira autônoma em nome de seu usuário ou proprietário, com o objetivo de atingir metas pré-estabelecidas. Ao contrário de programas tradicionais, que dependem de instruções explícitas para cada ação, um agente é projetado para identificar, interpretar e reagir a mudanças em seu ambiente, ajustando seu comportamento para alcançar seus objetivos. Quando múltiplos agentes são projetados para colaborar e coordenar suas ações, formam-se

sistemas multiagentes capazes de lidar com problemas mais complexos e dinâmicos do que aqueles resolvidos por agentes isolados.

Essa abordagem reflete um princípio fundamental da inteligência coletiva: “o todo é maior do que a soma das partes”. Cada agente individual contribui com uma parcela de conhecimento, competência ou capacidade de ação, e a interação entre eles gera soluções emergentes que não poderiam ser obtidas isoladamente. Assim, sistemas multiagentes não apenas dividem tarefas complexas em subtarefas menores, mas também coordenam esforços, compartilham informações e tomam decisões cooperativas com base em objetivos comuns.

Nos últimos anos, o avanço de técnicas de aprendizado profundo (deep learning), processamento de linguagem natural (PLN) e geração aumentada por recuperação (RAG) tem potencializado ainda mais o papel dos agentes. Agora, eles são capazes de processar grandes volumes de dados não estruturados, contextualizar informações em tempo real e realizar inferências com base em conhecimento especializado. Com isso, deixam de ser simples automatizadores de tarefas para se tornarem assistentes cognitivos distribuídos, atuando de forma estratégica em domínios como segurança cibernética, logística, saúde e, especialmente, gerenciamento de projetos (MATOS, 2023).

No ambiente corporativo, essa convergência entre inteligência artificial e sistemas multiagentes representa uma mudança significativa no paradigma de gestão. Organizações modernas enfrentam desafios crescentes relacionados à complexidade dos projetos, à volatilidade dos mercados e à necessidade de decisões rápidas e fundamentadas em dados. Nesse contexto, sistemas multiagentes inteligentes oferecem uma vantagem competitiva: automatizam análises, antecipam riscos, recomendam ações corretivas e otimizam recursos, tudo isso em tempo real. O resultado é uma gestão mais ágil, precisa e resiliente, capaz de se adaptar continuamente às condições do ambiente e aos objetivos estratégicos da organização.

## **2.2. Sistemas Multiagentes: Conceitos, Propriedades, Arquiteturas e Aplicações**

O aumento da complexidade dos ambientes computacionais e organizacionais contemporâneos tem impulsionado a necessidade de abordagens capazes de lidar com cenários dinâmicos, distribuídos e incertos. Nesse contexto, os sistemas multiagentes (SMA) emergem como uma solução eficiente para modelar, coordenar e resolver problemas que ultrapassam a capacidade de um único agente ou componente centralizado. A principal característica dos SMA é a cooperação entre múltiplas entidades autônomas, os agentes que interagem entre si e com o

ambiente para alcançar objetivos individuais e coletivos. Essa abordagem se destaca por oferecer maior flexibilidade, escalabilidade, adaptabilidade e robustez na resolução de tarefas complexas, características essenciais em áreas como logística, finanças, manufatura, saúde e, mais recentemente, no gerenciamento de projetos (WOOLDRIDGE, 2009; RUSSELL; NORVIG, 2021).

A literatura define um agente como uma entidade computacional capaz de perceber o ambiente em que está inserido, raciocinar sobre as informações disponíveis e agir de forma autônoma em direção a metas previamente definidas. Diferentemente de programas tradicionais, que dependem de instruções explícitas, agentes são projetados para operar de forma proativa, reagindo a mudanças contextuais e tomando decisões mesmo em condições de incerteza. Quando múltiplos agentes são integrados em um sistema, surgem comportamentos emergentes decorrentes da interação entre suas ações e decisões individuais, o que permite resolver problemas de forma distribuída, eficiente e adaptativa (JENNINGS; WOOLDRIDGE, 1998). Em sua essência, um sistema multiagentes pode ser entendido como um conjunto de agentes que interagem cooperativamente, competitivamente ou de forma mista, dependendo dos objetivos do sistema e das restrições do ambiente. Essa interação pode ocorrer de maneira direta, por meio de comunicação explícita, ou indireta, por meio da modificação do ambiente compartilhado (como no paradigma de *stigmergy*). A descentralização característica dos SMA favorece a escalabilidade e a tolerância a falhas, uma vez que a perda de um agente não compromete necessariamente o funcionamento global do sistema. Além disso, a distribuição das tarefas entre diferentes entidades especializadas permite que cada agente seja otimizado para funções específicas, aumentando a eficiência e a precisão do sistema como um todo.

### 2.2.1. Propriedades dos Sistemas Multiagentes

Autores de literatura especializada identificam um conjunto de propriedades que distinguem os sistemas multiagentes de outras arquiteturas computacionais (WOOLDRIDGE, 2009; RUSSELL; NORVIG, 2021):

- **Autonomia:** Cada agente possui controle sobre suas ações e decisões, operando sem intervenção humana direta. Isso o diferencia de sistemas centralizados, que dependem de comandos externos para agir.

- **Sociabilidade:** Agentes são capazes de interagir entre si por meio de protocolos de comunicação, trocando informações, negociando soluções e coordenando planos coletivos.
- **Reatividade:** Os agentes respondem rapidamente a mudanças no ambiente, adaptando seus comportamentos de acordo com novos estímulos ou eventos inesperados.
- **Proatividade:** Além de reagir a estímulos, agentes são capazes de agir de forma deliberada para alcançar objetivos definidos, antecipando-se a possíveis cenários.
- **Adaptabilidade:** Alguns agentes podem modificar suas estratégias com base em experiências anteriores ou novas informações recebidas, aprimorando seu desempenho ao longo do tempo.

Essas características tornam os SMA altamente adequados para resolver problemas em domínios onde múltiplas decisões simultâneas são necessárias, como no gerenciamento de redes elétricas, sistemas financeiros distribuídos, controle de tráfego aéreo e, especialmente, gestão de projetos corporativos complexos.

### 2.2.2. Tipos de Agentes e Estruturas Organizacionais

A literatura apresenta diferentes classificações de agentes, de acordo com seu grau de complexidade, capacidades cognitivas e papel desempenhado no sistema. Entre os tipos mais comuns destacam-se:

- **Agentes reativos:** tomam decisões com base em estímulos imediatos do ambiente, sem manter um modelo interno de mundo. São rápidos e eficientes, adequados para tarefas que exigem resposta imediata.
- **Agentes deliberativos:** constroem representações internas do ambiente e utilizam raciocínio simbólico para planejar ações. São apropriados para problemas que demandam previsão de estados futuros e planejamento estratégico.
- **Agentes cognitivos:** incorporam processos avançados de raciocínio, aprendizado e tomada de decisão, permitindo adaptação a cenários altamente dinâmicos e incertos.
- **Agentes híbridos:** combinam características reativas e deliberativas, equilibrando capacidade de resposta rápida com planejamento de longo prazo.

No contexto de sistemas multiagentes, a organização também desempenha papel crucial. As estruturas podem ser hierárquicas (com papéis e fluxos de decisão definidos), não hierárquicas

(mais descentralizadas e colaborativas) ou híbridas. A escolha da estrutura depende do tipo de problema a ser resolvido e do grau de interdependência entre os agentes.

### 2.2.3. Comunicação, Coordenação e Cooperação

A comunicação é um dos elementos centrais em sistemas multiagentes, pois viabiliza a troca de informações necessárias para a coordenação e cooperação entre entidades autônomas. Essa interação pode ocorrer por meio de protocolos formais, como ACL (Agent Communication Language) e KQML (Knowledge Query and Manipulation Language), que permitem a transmissão de intenções, estados e planos entre agentes.

A coordenação refere-se ao processo de organizar e alinhar ações individuais para alcançar objetivos comuns, evitando redundâncias ou conflitos. Diferentes estratégias podem ser utilizadas, como planos globais predefinidos, coordenação emergente baseada em comportamento coletivo ou negociação entre agentes com interesses divergentes.

Além das abordagens baseadas em comunicação direta, um paradigma amplamente estudado para coordenação em sistemas distribuídos é o da *stigmergy*. Introduzido originalmente por Pierre-Paul Grassé (1959) ao estudar o comportamento coletivo de cupins (térmitas), esse conceito descreve a coordenação indireta entre agentes por meio de modificações no ambiente compartilhado. Em vez de trocarem mensagens explícitas, os agentes interagem com marcas ou artefatos deixados por outros, interpretando essas alterações como sinais para orientar suas ações subsequentes.

O exemplo clássico é observado em colônias de formigas, nas quais trilhas de feromônio são deixadas no caminho até fontes de alimento. Outras formigas não precisam se comunicar diretamente para seguir a rota mais eficiente: basta perceber e reagir aos vestígios químicos no ambiente. Em sistemas computacionais, essa lógica se traduz na capacidade de agentes observarem e reagirem a mudanças em um espaço de dados comum, como atualizações em registros de risco, cronograma ou desempenho e ajustarem seu comportamento com base nessas informações.

A cooperação, por sua vez, ocorre quando os agentes trabalham de forma colaborativa para resolver problemas cuja complexidade excede a capacidade de um único agente. Em cenários competitivos, mecanismos de negociação, contratos e leilões podem ser empregados para alcançar resultados mutuamente benéficos (JENNINGS; WOOLDRIDGE, 1995). A eficácia dessas interações está diretamente relacionada à capacidade dos agentes de compartilhar

conhecimento, interpretar intenções e adaptar comportamentos, elementos fundamentais para o surgimento de comportamentos coletivos complexos em sistemas distribuídos.

#### **2.2.4. Aplicações Práticas dos Sistemas Multiagentes**

O uso de sistemas multiagentes ultrapassou o campo da pesquisa acadêmica e passou a ser aplicado em diversas áreas práticas dentro do mundo corporativo. Na indústria, agentes são utilizados em sistemas de recomendação, controle de produção, logística, negociação automatizada e monitoramento de infraestrutura (MATOS, 2023). No setor financeiro, auxiliam na detecção de fraudes e na execução de estratégias de investimento automatizadas.

No gerenciamento de projetos, os SMA destacam-se por sua capacidade de lidar com múltiplas variáveis simultaneamente, como prazos, custos, riscos, qualidade e de gerar recomendações contextualizadas com base em dados históricos e em tempo real. Cada agente pode monitorar indicadores específicos, prever cenários futuros, sugerir ações corretivas e até mesmo colaborar com outros agentes para otimizar a alocação de recursos e maximizar o valor entregue ao negócio.

### **2.3. Arquitetura de sistemas Multiagentes e Modelos de interação**

A arquitetura de um sistema multiagentes (SMA) representa o conjunto de princípios, componentes e relações que definem como os agentes são projetados, organizados e interagem entre si e com o ambiente. Ela determina o nível de autonomia dos agentes, o modo como se comunicam, as estratégias de coordenação utilizadas e a forma de alcançar objetivos coletivos. A escolha da arquitetura influencia diretamente a eficiência, a escalabilidade, a robustez e a capacidade adaptativa do sistema (WOOLDRIDGE, 2009; RUSSELL; NORVIG, 2021).

As arquiteturas de SMA evoluíram ao longo do tempo acompanhando o aumento da complexidade dos ambientes computacionais e a necessidade de tomada de decisão distribuída. Enquanto as primeiras abordagens eram simples e baseadas em regras fixas, os modelos atuais combinam elementos cognitivos, aprendizado e raciocínio coletivo. A seguir são apresentadas as principais arquiteturas e modelos de interação discutidos na literatura.

### 2.3.1. Arquiteturas baseadas em agentes individuais

As arquiteturas de agentes individuais são os blocos fundamentais sobre os quais os sistemas multiagentes são construídos. As arquiteturas individuais especificam como cada agente percebe o ambiente, processa informações e executa ações. De forma geral, a literatura as classifica em quatro categorias principais:

- **Arquitetura Reativa:** Baseia-se em regras simples de estímulo-resposta. O agente não mantém representações internas do ambiente, agindo exclusivamente em resposta a mudanças percebidas. Essa abordagem é eficiente em ambientes dinâmicos e imprevisíveis, mas limitada em tarefas que exigem planejamento ou raciocínio complexo.
- **Arquitetura Deliberativa:** Os agentes constroem representações internas do ambiente e planejam suas ações com base em objetivos de longo prazo. Essa abordagem é mais sofisticada, permitindo decisões estratégicas e previsões de consequências, porém pode ser mais lenta em contextos que exigem respostas imediatas.
- **Arquitetura Cognitiva:** Baseia-se em modelos mentais que simulam processos humanos, como raciocínio simbólico, planejamento, memória e aprendizado. Os agentes cognitivos são capazes de raciocinar sobre suas ações e adaptar-se a novos cenários, tornando-se ideais para ambientes complexos e incertos.
  - **Arquitetura Híbrida:** Combina elementos de abordagens reativas e deliberativas. Os agentes híbridos utilizam respostas rápidas a estímulos quando necessário, mas também mantêm planos estratégicos e objetivos globais. Essa arquitetura é frequentemente empregada em sistemas reais devido ao seu equilíbrio entre velocidade e inteligência.

A escolha entre essas arquiteturas depende diretamente do domínio de aplicação, dos requisitos de autonomia e das demandas de escalabilidade do sistema.

### 2.3.2. Arquiteturas organizacionais SMA

Enquanto as arquiteturas individuais definem o funcionamento interno e comportamento de cada agente, as arquiteturas organizacionais definem como esses agentes se relacionam entre si

e colaboram para atingir objetivos coletivos. Três modelos organizacionais são amplamente estudados:

- **Hierárquico:** Os agentes são organizados em uma estrutura piramidal, com níveis superiores coordenando e controlando os inferiores. Essa abordagem simplifica a coordenação e o fluxo de informação, mas pode criar pontos de falha e limitar a autonomia dos agentes.
- **Não hierárquico:** Todos os agentes possuem níveis semelhantes de autoridade e decidem de maneira descentralizada. A coordenação surge da negociação e cooperação espontânea. Esse modelo aumenta a resiliência e a adaptabilidade, mas pode exigir protocolos de consenso mais complexos.
- **Híbrido:** combina centralização estratégica com autonomia local, sendo frequentemente adotado em ambientes corporativos complexos (WOOLDRIDGE, 2009). Esse modelo é particularmente útil em sistemas corporativos, onde algumas decisões precisam ser centralizadas (por exemplo, alocação de recursos) enquanto outras podem ser descentralizadas (como priorização de tarefas).

A arquitetura organizacional escolhida deve refletir a natureza das tarefas do sistema, o nível desejado de autonomia dos agentes e os requisitos de robustez do ambiente.

### 2.3.3. Modelos de interação entre agentes

A interação entre agentes é o núcleo da inteligência coletiva em um SMA. É por meio dela que agentes cooperam, negociam, compartilham informações e resolvem conflitos, e disso emergem comportamentos cooperativos, adaptativos e coordenados. Três dimensões principais são fundamentais para entender esses modelos:

- **Comunicação:** A troca de informações é geralmente implementada por meio de linguagens padronizadas, como a Agent Communication Language (ACL) ou Knowledge Query and Manipulation Language (KQML), que definem protocolos de mensagens, semânticas e ontologias compartilhadas. Essa padronização garante que agentes com arquiteturas diferentes possam interagir de forma eficaz (WOOLDRIDGE; JENNINGS, 1995).
- **Coordenação:** Refere-se ao processo pelo qual os agentes organizam suas ações para evitar conflitos e alcançar objetivos coletivos. Isso pode incluir estratégias como alocação de tarefas, sincronização temporal e planejamento distribuído.

- **Cooperação e Negociação:** Em ambientes complexos, agentes podem ter objetivos conflitantes ou recursos limitados. Nessas situações, técnicas de negociação como leilões, barganhas ou contratos são utilizadas para alcançar acordos mutuamente benéficos. A cooperação vai além da simples coordenação, pois envolve a construção de planos compartilhados e a adaptação coletiva a novos desafios.

Além das interações diretas, um paradigma amplamente utilizado para coordenação em sistemas distribuídos é a stigmergy, discutida anteriormente. Nesse modelo, a cooperação ocorre de forma indireta: os agentes interagem por meio de modificações no ambiente compartilhado e ajustam suas ações em resposta a essas alterações. Essa abordagem permite a emergência de comportamentos complexos a partir de regras simples e locais, reduzindo a necessidade de protocolos complexos de comunicação e facilitando a escalabilidade do sistema.

#### 2.3.4. Arquiteturas híbridas e Ambientes Dinâmicos

Com a crescente complexidade dos sistemas corporativos, arquiteturas puramente reativas ou deliberativas mostram-se insuficientes. Por isso, modelos híbridos tornaram-se predominantes na pesquisa e na prática. Esses sistemas combinam agentes especializados em diferentes funções, sendo alguns focados em resposta imediata e outros em raciocínio estratégico para otimizar tanto a velocidade quanto a qualidade das decisões.

Um exemplo clássico é um sistema multiagentes aplicado ao gerenciamento de projetos:

- Agentes reativos monitoram continuamente indicadores-chave como Schedule Performance Index (SPI) e Cost Performance Index (CPI).
- Agentes deliberativos analisam tendências e sugerem replanejamentos com base em previsões.
- Agentes cognitivos integram dados históricos, conhecimento contextual (PMBOK) e padrões de risco para gerar recomendações explicáveis e fundamentadas.

Essa integração cria um ecossistema dinâmico e adaptativo, no qual os agentes trabalham em sinergia para lidar com ambientes incertos e decisões interdependentes, características típicas de portfólios de projetos complexos.

### **2.3.5. Considerações sobre escalabilidade e robustez**

A escalabilidade é uma das principais vantagens dos sistemas multiagentes. Como cada agente opera de forma autônoma e independente, novos agentes podem ser adicionados sem a necessidade de reestruturar completamente o sistema. Isso é especialmente relevante em ambientes empresariais em constante evolução, onde novos domínios como sustentabilidade, conformidade regulatória ou análise de impacto ambiental podem ser incorporados rapidamente, ou ainda no domínio de gestão de projetos, é possível inserir um novo agente de escopo num sistema multiagentes para auxiliar na governança e análise de impacto na tríplice restrição do PMBOK.

Outro aspecto crucial é a robustez. Diferentemente dos sistemas centralizados, em que a falha de um único componente pode comprometer toda a operação, os sistemas multiagentes são intrinsecamente mais tolerantes a falhas. A perda ou mau funcionamento de um agente geralmente não impede que o sistema como um todo continue operando, pois outros agentes podem compensar a ausência temporária.

As arquiteturas e os modelos de interação são componentes essenciais no projeto de sistemas multiagentes. Eles determinam não apenas a eficiência e a escalabilidade do sistema, mas também sua capacidade de adaptação, cooperação e tomada de decisão coletiva. No contexto do gerenciamento de projetos, essas características são particularmente valiosas, pois permitem construir sistemas flexíveis, resilientes e capazes de lidar com a complexidade e a dinamicidade dos ambientes corporativos modernos.

## **2.4. Integração de sistemas multiagentes com IA no Gerenciamento de Projetos**

A convergência entre Inteligência Artificial (IA) e Sistemas Multiagentes (SMA) representa uma das evoluções mais significativas na área de automação e apoio à decisão em ambientes corporativos complexos, e tem se consolidado como uma abordagem estratégica. Essa integração não apenas amplia as capacidades tradicionais dos agentes como a percepção, o raciocínio e ação, mas também permite que decisões sejam tomadas de forma mais contextualizada, explicável e adaptativa.

Tradicionalmente, as ferramentas de gerenciamento de projetos dependem fortemente da intervenção humana e de processos manuais para coleta, análise e interpretação de dados. Com

a evolução dos SMA e da IA, essa lógica tem sido gradualmente substituída por sistemas capazes de coordenar agentes especializados, cada um responsável por analisar dimensões específicas do projeto, como cronograma, custos, riscos, escopo, qualidade, comunicação e colaborar na produção de recomendações integradas. Essa convergência cria um ambiente de tomada de decisão mais dinâmico, responsivo e baseado em evidências, reduzindo a probabilidade de falhas associadas à análise tardia ou incompleta de informações críticas.

#### **2.4.1. Convergência do Agente autônomo ao SMA distribuído**

Enquanto agentes individuais são projetados para executar tarefas específicas com autonomia e adaptação ao ambiente, a integração com técnicas de IA, especialmente aprendizado de máquina (Machine Learning), processamento de linguagem natural (PLN) e RAG (Retrieval-Augmented Generation), expande suas capacidades cognitivas, permitindo raciocínio complexo, interpretação contextual e tomada de decisão informada por dados.

Essa evolução transforma os SMA de simples solucionadores de tarefas em sistemas inteligentes distribuídos. Nos SMA, a inteligência emerge da interação coordenada entre múltiplos agentes com especializações distintas. Essa colaboração distribui a carga cognitiva e aumenta a capacidade do sistema de processar múltiplas variáveis simultaneamente. Por exemplo, um agente pode monitorar indicadores de desempenho do cronograma, enquanto outro avalia variações orçamentárias e um terceiro analisa riscos emergentes. A sinergia entre esses agentes gera uma compreensão mais ampla e contextualizada do projeto, resultando em diagnósticos e recomendações mais precisos.

Essa nova geração de SMA vai além da automação de tarefas: ela atua como um ecossistema cognitivo colaborativo, no qual agentes não apenas executam ações, mas raciocinam, negociam, justificam e aprendem.

#### **2.4.2. Arquitetura cognitiva integrada: SMA – RAG - LLM**

O modelo proposto neste trabalho combina três componentes complementares: sistemas multiagentes (SMA), RAG (Retrieval-Augmented Generation) e modelos de linguagem de larga escala (LLM). Cada camada desempenha um papel específico no processo de análise e

geração de conhecimento, compondo um ecossistema inteligente voltado ao apoio ao gerenciamento de projetos. São elas:

- 1. Camada de Conhecimento e Dados:** Esta camada é responsável pela coleta, armazenamento e organização de informações relevantes ao contexto do projeto. Inclui informações históricas de projetos concluídos, cancelados ou em andamento, status reports e documentos de referência, incluindo o PMBOK® Guide (7ª edição). Esse repositório fornece a base sobre a qual as análises são realizadas.
- 2. Camada de Recuperação de Informação (RAG):** O RAG atua como intermediário entre os dados e os modelos de linguagem (LLM), permitindo a recuperação contextualizada de informações relevantes. Ele implementa mecanismos híbridos de busca lexical (TF-IDF) e semântica (S-BERT), para recuperar informações relevantes. amplia a precisão e a relevância dos dados fornecidos ao LLM, garantindo que as respostas geradas sejam fundamentadas e atualizadas.
- 3. Camada de Inteligência (LLM):** Utiliza modelos de linguagem de larga escala (como GPT-4.0-mini) para gerar recomendações explicáveis, interpretar dados não estruturados e propor ações corretivas ou preventivas. Essa camada representa o componente cognitivo do sistema, permitindo não apenas a identificação de problemas, mas também a proposição de soluções e ações corretivas.
- 4. Camada de Coordenação Multiagentes:** Nessa etapa, agentes especializados consomem as recomendações geradas e interagem entre si para priorizar ações, gerar planos de mitigação e elaborar relatórios executivos. Cada agente atua em um domínio específico: cronograma, custos, escopo, riscos, qualidade e comunicação, executando análises especializadas e interagindo com os demais agentes para construir uma visão global do projeto. O agente coordenador desempenha um papel central ao orquestrar esse ecossistema, consolidando recomendações e priorizando ações.

As recomendações passam por um processo de validação com base em regras e princípios do PMBOK® 7ª edição, garantindo alinhamento com as boas práticas de gestão e reduzindo o risco de ações incorretas ou não conformes.

Essa arquitetura cria um ciclo de decisão contínuo e iterativo, no qual dados históricos e em tempo real alimentam análises contextuais, e as recomendações geradas retroalimentam o sistema, resultando em decisões progressivamente mais precisas.

### 2.4.3. Aplicação no gerenciamento de projetos

A aplicação prática dessa arquitetura no gerenciamento de projetos reflete-se na automação de atividades críticas que tradicionalmente demandam tempo e esforço humano significativo. Em vez de depender exclusivamente de relatórios manuais e reuniões de análise, gestores passam a contar com um sistema que monitora continuamente o progresso dos projetos, identifica desvios e sugere ações corretivas de forma proativa.

Por exemplo, o agente responsável por cronogramas pode detectar atrasos potenciais e recomendar a redistribuição de recursos; enquanto o agente de custos pode identificar variações orçamentárias e sugerir ajustes; e o agente de riscos pode antecipar cenários adversos, propondo planos de mitigação. Essa divisão de responsabilidades aumenta a precisão das análises e reduz o tempo de resposta diante de eventos críticos.

Além disso, a interação entre agentes permite gerar recomendações integradas, que consideram múltiplas dimensões do projeto de forma simultânea. Essa visão sistêmica reduz a fragmentação da análise e facilita a tomada de decisão estratégica, especialmente em ambientes corporativos onde múltiplos projetos concorrem por recursos limitados.

### 2.4.4. Benefícios Estratégicos e Impactos Organizacionais

A implementação de sistemas multiagentes inteligentes representa mais do que um ganho operacional: trata-se de uma mudança de paradigma na forma como as organizações gerenciam projetos. Alguns dos principais impactos incluem:

- **Tomada de decisão baseada em evidências:** recomendações são fundamentadas em dados históricos, informações contextuais e análises automatizadas, reduzindo a subjetividade e aumentando a confiabilidade das decisões.
- **Agilidade e proatividade:** o sistema identifica desvios e oportunidades em tempo real, permitindo que gestores ajam antes que problemas se agravem.
- **Melhoria contínua:** a capacidade de aprendizado dos agentes e dos modelos de linguagem promove evolução contínua do sistema, que se torna mais preciso e eficiente ao longo do tempo.

- **Aumento da taxa de sucesso e redução de custos:** ao antecipar riscos e propor ações corretivas precoces, a probabilidade de entregar os projetos dentro do escopo, prazo e orçamento aumenta significativamente.
- **Escalabilidade e adaptabilidade:** a natureza modular e distribuída da arquitetura facilita sua expansão para novos domínios e contextos, acompanhando o crescimento e a transformação das organizações.
- **Transparência e explicabilidade:** relatórios e recomendações explicáveis e rastreáveis fortalecem a confiança dos stakeholders e facilitam auditorias e relatórios executivos.

#### 2.4.5. Desafios e considerações

Apesar dos avanços e benefícios, a implementação dessa integração tecnológica apresenta desafios que devem ser cuidadosamente considerados.

A gestão dos dados (qualidade, governança, curadoria, disponibilidade) permanece como fator crítico, pois dados incompletos, desatualizados ou inconsistentes podem comprometer a eficácia do sistema.

Além disso, a complexidade e custo computacional requer conhecimento multidisciplinar em IA, engenharia de software e gerenciamento de projetos, associado ao treinamento e à execução de modelos de linguagem de larga escala, representando um obstáculo em ambientes com recursos limitados. A interoperabilidade do sistema também deve ser levada em consideração uma vez que a integração com sistemas legados e ferramentas corporativas exige padrões abertos e interfaces bem definidas.

Outro ponto de atenção é a necessidade de governança e supervisão humana. Embora os sistemas sejam capazes de sugerir ações com alto grau de autonomia, decisões estratégicas continuam a depender de julgamento humano, especialmente em situações que envolvem riscos elevados ou implicações organizacionais significativas.

Por fim, questões relacionadas à explicabilidade dos modelos, segurança da informação e ética na automação de decisões precisam ser incorporadas ao planejamento de implantação desde as etapas iniciais do projeto.

## 2.5. Vantagens, Limitações e Desafios dos Sistemas Multiagentes no Contexto Corporativo

A adoção de sistemas multiagentes (SMA) em ambientes corporativos complexos, especialmente quando integrados a técnicas avançadas de inteligência artificial (IA), representa uma mudança estrutural na forma como organizações planejam, executam e controlam seus projetos. Ao substituir modelos tradicionais baseados em decisões centralizadas por ecossistemas distribuídos de agentes autônomos e cooperativos, as empresas obtêm ganhos expressivos em agilidade, eficiência e capacidade analítica. Entretanto, como qualquer abordagem tecnológica, os SMA apresentam vantagens relevantes, mas também limitações e desafios que precisam ser considerados de forma crítica.

### 2.5.1. Vantagens estratégicas de Sistemas Multiagentes

A incorporação de SMA no contexto empresarial oferece benefícios que transcendem a automação operacional, alcançando níveis estratégicos de governança e tomada de decisão. Entre os principais diferenciais competitivos observados, destacam-se

- a) **Descentralização da Tomada de Decisão** - uma das maiores vantagens dos SMA é a capacidade de distribuir a inteligência e o processo decisório entre múltiplos agentes especializados. Essa descentralização elimina gargalos associados a decisões centralizadas e permite respostas mais rápidas e contextualizadas em ambientes dinâmicos, onde as variáveis mudam com alta frequência (WOOLDRIDGE, 2009).
- b) **Escalabilidade e Flexibilidade Operacional** - sistemas multiagentes podem ser facilmente expandidos com a adição de novos agentes responsáveis por diferentes domínios como conformidade regulatória, sustentabilidade ou experiência do cliente, sem a necessidade de reestruturar toda a arquitetura. Essa modularidade garante que o sistema acompanhe o crescimento da organização e as mudanças no ambiente de negócios.
- c) **Tomada de Decisão Baseada em Dados e Conhecimento** - a integração de SMA com técnicas de aprendizado de máquina e recuperação aumentada por geração (RAG) permite análises robustas e recomendações embasadas em evidências, reduzindo a

dependência de julgamentos subjetivos. Decisões tornam-se mais precisas e alinhadas a indicadores quantitativos, como SPI, CPI, ROI e taxa de sucesso dos projetos.

- d) **Aprimoramento do Monitoramento e da Previsão** - agentes podem operar continuamente, monitorando métricas de desempenho em tempo real, detectando desvios e identificando padrões de risco antes que se materializem. Essa capacidade de detecção precoce e resposta proativa melhora significativamente a governança e reduz custos associados a falhas ou atrasos não previstos.
- e) **Cooperação e Sinergia Interdisciplinar** - o caráter colaborativo dos SMA permite a integração de perspectivas distintas — técnicas, financeiras, operacionais e estratégicas — dentro de um mesmo processo decisório. A cooperação entre agentes especializados em diferentes domínios promove uma visão holística do projeto, aumentando a coerência e a qualidade das decisões.

### 2.5.2. Limitações técnicas e organizacionais

Apesar de seu potencial transformador, a implementação de SMA enfrenta limitações que devem ser cuidadosamente analisadas e mitigadas durante a fase de planejamento e desenvolvimento.

No que se refere a complexidade de desenvolvimento e implementação, projetar sistemas multiagentes robustos exige conhecimento interdisciplinar avançado, envolvendo inteligência artificial, ciência de dados, engenharia de software e gestão de projetos. A criação de protocolos de comunicação, mecanismos de coordenação e modelos de decisão distribuída aumenta consideravelmente a complexidade do processo de desenvolvimento (RUSSELL; NORVIG, 2021).

Outro ponto relevante é a interoperabilidade e integração com sistemas legados, uma vez que em muitos ambientes corporativos, a infraestrutura tecnológica existente é composta por sistemas legados heterogêneos. E garantir que os agentes interajam eficientemente com esses sistemas requer a criação de interfaces, APIs e camadas de compatibilidade, o que pode demandar tempo e investimento significativo.

A seguir, a limitação ligada a qualidade e governança dos dados, em que a eficácia de um SMA está diretamente relacionada à qualidade dos dados que ele processa. Dados incompletos, inconsistentes ou não estruturados comprometem a precisão das análises e das recomendações.

Além disso, questões de governança como conformidade com legislações de proteção de dados e controle de acesso, devem ser rigorosamente observadas.

As limitações de escalabilidade computacional e custo operacional, acontecem por meio da operação simultânea de múltiplos agentes, especialmente quando combinada com grandes modelos de linguagem (LLMs), que pode gerar alta demanda computacional e custos significativos de processamento dos tokens de envio e recebimento. Ou ainda pela escolha da arquitetura do RAG, bem como sua robustez para transformar dados em word embeddings e buscas lexicais, semânticas ou buscas por grafos de conhecimentos. Estratégias de otimização de desempenho e uso eficiente de recursos são essenciais para viabilizar a solução em larga escala.

Por fim, as limitações relacionadas a explicabilidade e confiança organizacional, a aceitação de recomendações geradas por agentes autônomos ainda representa um desafio cultural em muitas organizações. A falta de explicabilidade, ou seja, a dificuldade de compreender e justificar as decisões do sistema pode gerar resistência por parte dos gestores e stakeholders. A implementação de mecanismos de rastreabilidade e auditoria de decisões é fundamental para fortalecer a confiança e promover a adoção.

### **2.5.3. Desafios de Adoção e Caminhos para Superação**

A adoção de sistemas multiagentes em ambientes corporativos não se resume a questões técnicas. Ela envolve uma transformação mais ampla, que atravessa dimensões culturais, organizacionais e estratégicas. Um dos principais obstáculos está relacionado à mudança cultural necessária para a incorporação dessas tecnologias. A introdução de agentes autônomos em processos decisórios modifica estruturas de trabalho estabelecidas, altera fluxos operacionais e desafia a maneira tradicional como equipes interagem e tomam decisões. Para que a transição seja bem-sucedida, é indispensável que as organizações promovam programas de capacitação contínua, invistam em estratégias de gestão da mudança e redefinam papéis de forma clara, garantindo que as equipes compreendam a função dos agentes e os vejam como aliados, e não como substitutos.

Outro aspecto crucial diz respeito à governança e à ética. A autonomia conferida aos agentes levanta questionamentos sobre responsabilidade, transparência e impactos na força de trabalho humana. Quem é responsável por uma decisão automatizada que gera prejuízos? Como garantir que os agentes atuem de acordo com princípios éticos e alinhados aos objetivos

organizacionais? Essas questões demandam a criação de estruturas de governança robustas, com auditorias constantes, mecanismos de explicabilidade e diretrizes claras para a tomada de decisões automatizadas.

Além disso, a ausência de padrões amplamente aceitos para comunicação, coordenação e interoperabilidade entre agentes representa uma barreira técnica relevante. Em um cenário cada vez mais heterogêneo em termos de ferramentas e fornecedores, a padronização torna-se essencial para viabilizar a integração de diferentes sistemas. Sem isso, corre-se o risco de criar ecossistemas fragmentados e pouco eficientes.

Por fim, há o desafio de mensurar o retorno sobre o investimento (ROI) e o impacto dos SMA. Organizações frequentemente têm dificuldade em traduzir benefícios intangíveis como agilidade decisória ou redução de riscos em métricas objetivas que justifiquem a adoção da tecnologia. Para superar essa barreira, é recomendável o estabelecimento de indicadores claros de desempenho, capazes de mensurar ganhos operacionais e estratégicos ao longo do tempo. Superar esses obstáculos requer uma abordagem coordenada e multidimensional. O sucesso na implementação de SMA depende tanto da maturidade tecnológica quanto da capacidade das organizações de conduzir transformações culturais, estabelecer governança adequada e criar modelos de mensuração que evidenciem o valor gerado. Somente assim será possível extrair o máximo potencial desses sistemas e garantir sua adoção sustentável em longo prazo.

#### **2.5.4. Perspectivas futuras e tendências de evolução**

O campo dos sistemas multiagentes está em franca evolução e tende a ocupar um papel cada vez mais estratégico no ecossistema corporativo. Os avanços recentes em inteligência artificial, aprendizado por reforço, ontologias semânticas e arquiteturas cognitivas híbridas estão redefinindo os limites do que esses sistemas podem alcançar. Uma das tendências mais promissoras é o desenvolvimento de agentes explicáveis, conhecidos como XAI (Explainable Artificial Intelligence). Essa nova geração de agentes não se limita a executar ações ou recomendar decisões; ela é capaz de justificar suas escolhas de maneira compreensível para humanos, facilitando a confiança e a aceitação organizacional.

Outra direção de avanço está nos sistemas auto-organizáveis, capazes de adaptar sua estrutura interna, seus papéis e suas estratégias de cooperação em resposta a mudanças no ambiente. Isso permitirá que os SMA se tornem ainda mais resilientes e eficazes em cenários dinâmicos e incertos, ajustando-se continuamente sem necessidade de intervenção humana direta. A

integração com tecnologias emergentes, como os Digital Twins, também desponta como uma tendência de impacto profundo: ao interagir com réplicas virtuais de projetos e processos reais, os agentes poderão simular cenários, prever impactos e recomendar ações com maior precisão e segurança.

O uso de ontologias e grafos de conhecimento em RAG representa outra fronteira significativa. Ao organizar e estruturar informações de forma semântica, essas tecnologias ampliam a capacidade dos agentes de compreender contextos complexos, raciocinar com base em conhecimento prévio e colaborar de maneira mais sofisticada. Isso resultará em sistemas mais inteligentes, interoperáveis e alinhados às necessidades do ambiente corporativo.

Essas tendências sugerem que os sistemas multiagentes deixarão de ser apenas ferramentas de apoio à decisão para se tornarem componentes essenciais da infraestrutura organizacional inteligente. No futuro, eles deverão operar como elementos estratégicos, interligando dados, pessoas, processos e decisões em um ecossistema integrado e adaptativo, capaz de responder rapidamente a desafios e oportunidades de negócios.

O uso de sistemas multiagentes em ambientes corporativos representa um salto qualitativo na forma como decisões são tomadas e projetos são gerenciados. Contudo, seu potencial máximo só é alcançado quando desafios técnicos, organizacionais e culturais são enfrentados com planejamento estratégico e visão de longo prazo. Ao combinar inteligência contextual, descentralização decisória e governança baseada em dados, os SMA transcendem a condição de simples ferramentas tecnológicas e se tornam pilares centrais na transformação digital das organizações modernas.

## **2.6. Gerenciamento de Projetos e Fundamentos do PMBOK (7ª edição)**

O gerenciamento de projetos consolidou-se como disciplina essencial para a entrega de valor em organizações de diferentes setores. O PMBOK® Guide (7ª edição) representa a principal referência internacional de boas práticas em gestão de projetos, ao migrar de um enfoque prescritivo de processos para uma perspectiva baseada em princípios e domínios de desempenho (PMI, 2021). Essa mudança coloca a geração de valor no centro, enfatizando adaptabilidade, liderança colaborativa, qualidade, gestão de riscos e governança como elementos estruturantes.

A 7ª edição organiza-se em 12 princípios, por exemplo, foco em valor, pensamento sistêmico, comportamento ético e liderança, e 8 domínios de desempenho: stakeholders, equipe, abordagem e ciclo de vida, planejamento, trabalho do projeto, entrega, medição, incerteza e risco (PMI, 2021). Em vez de impor um “como fazer”, o guia orienta decisões contextuais, permitindo combinações ágeis, preditivas e híbridas.

No tocante à mensuração do desempenho, a técnica de Análise de Valor Agregado (EVM) segue central, notadamente pelos índices SPI e CPI, que indicam, respectivamente, eficiência de cronograma e de custo. Indicadores complementares como ROI, taxa de sucesso (entrega em escopo, prazo e custo), métricas de qualidade e satisfação de stakeholders ampliam a visão de “saúde” do projeto.

No contexto deste trabalho, o PMBOK funciona também como mecanismo de governança para os agentes, servindo de guardrails — um conjunto de princípios e critérios que balizam a geração de recomendações e mitigam vieses e alucinações dos modelos de linguagem (LLM). Ao ancorar a atuação dos agentes em princípios e domínios reconhecidos, aumenta-se a explicabilidade e a aceitação organizacional das recomendações geradas por IA.

Referências: PMI (2021).

## **2.7. Aplicação de Sistemas Multiagentes no Gerenciamento de Projetos**

A utilização de Sistemas Multiagentes (SMA) no gerenciamento de projetos fundamenta-se na correspondência natural entre domínios decisórios e agentes especializados. Em contextos organizacionais, dimensões como cronograma, custos, riscos, escopo, qualidade e comunicação apresentam elevada interdependência, demandando monitoramento contínuo, análise contextualizada e coordenação integrada. A característica de descentralização decisória inerente aos SMA os torna particularmente adequados para esse tipo de cenário (WOOLDRIDGE, 2009; WOOLDRIDGE; JENNINGS, 1995).

Na arquitetura proposta, cada agente desempenha funções específicas. O Agente de Cronograma, por exemplo, é responsável pelo acompanhamento de indicadores como SPI, caminho crítico e marcos; o Agente de Custos monitora métricas como CPI, variações e projeções; o Agente de Riscos atua na identificação, priorização e proposição de respostas; enquanto agentes voltados a Escopo, Qualidade e Comunicação asseguram a conformidade com requisitos, padrões e alinhamento entre stakeholders. A coordenação dessas entidades é

realizada por um Agente Coordenador, cuja função consiste em orquestrar dependências e consolidar diagnósticos, prevenindo recomendações conflitantes.

A camada cognitiva integra um mecanismo de Recuperação Aumentada por Geração (RAG) híbrido — combinando busca lexical (TF-IDF) e semântica (S-BERT) com geração orientada por modelos de linguagem (LLM). O processo segue um ciclo estruturado:

- (i) formulação da consulta pelo agente;
- (ii) recuperação de evidências relevantes pelo RAG, incluindo lições aprendidas, históricos de status e diretrizes do PMBOK;
- (iii) validação de consistência por meio de guardrails;
- (iv) síntese da recomendação pelo LLM, acompanhada de justificativas; e
- (v) integração e priorização das ações pelo Agente Coordenador.

Essa dinâmica resulta em decisões explicáveis, auditáveis e orientadas a valor.

Sob a perspectiva organizacional, a abordagem proposta contribui para maior agilidade na resposta a desvios, aumento da previsibilidade por meio de projeções de impacto em prazo e custo, e fortalecimento da governança, assegurada pela rastreabilidade das recomendações. Em portfólios de grande escala, a modularidade dos SMA possibilita a expansão para novos domínios e a incorporação de agentes adicionais como aqueles voltados à sustentabilidade, compliance ou capacidade produtiva sem a necessidade de reengenharia completa do sistema.

## 2.8. Limitações e desafios da adoção

Embora os Sistemas Multiagentes (SMA) com Inteligência Artificial apresentem benefícios significativos para o gerenciamento de projetos, sua implementação envolve desafios técnicos, organizacionais e metodológicos que devem ser reconhecidos e mitigados como:

- **Complexidade de engenharia e integração** - O desenvolvimento de SMA robustos requer a combinação de múltiplos elementos, como arquitetura de agentes, protocolos de comunicação, mecanismos de coordenação e negociação, além da integração com sistemas legados (ERP, PMIS e ferramentas de cronograma). Em ecossistemas heterogêneos, é fundamental garantir baixo acoplamento e interfaces bem definidas para assegurar interoperabilidade (RUSSELL; NORVIG, 2021).
- **Governança e qualidade de dados** - A eficácia das recomendações depende diretamente da confiabilidade e consistência dos dados utilizados, incluindo relatórios de status, registros de custos e logs de riscos. Linhas de base mal definidas, atualizações

irregulares e lacunas semânticas comprometem a acurácia das análises. Nesse sentido, políticas de governança de dados e catálogos semânticos tornam-se indispensáveis (PMI, 2021).

- **Explicabilidade e confiança** - Em ambientes regulados ou críticos, é imprescindível justificar as recomendações geradas pelo sistema. A integração de evidências provenientes do RAG com critérios do PMBOK contribui para a rastreabilidade, mas persiste o desafio de apresentar explicações compreensíveis para públicos não técnicos (WOOLDRIDGE; JENNINGS, 1995).
- **Escalabilidade e custo computacional** - A execução simultânea de múltiplos agentes, associada ao uso de RAG e modelos de linguagem, pode elevar significativamente os custos e a latência. Estratégias como cache de resultados, reordenação eficiente, limitação de contexto e políticas de orquestração baseadas em prioridade são essenciais para otimizar desempenho e reduzir custos.
- **Mudança organizacional** - A adoção efetiva de SMA exige mais do que tecnologia: requer capacitação das equipes, revisão de papéis e responsabilidades e alinhamento entre PMO e áreas técnicas. A concepção de uma “cogestão humano-máquina” deve ser claramente comunicada para favorecer a aceitação e o engajamento.
- **Reprodutibilidade e avaliação** - A validação científica e prática da abordagem demanda experimentos controlados, com definição de seeds, protocolos de teste e métricas adequadas (SPI, CPI, ROI, taxa de sucesso). Esses elementos são fundamentais para permitir comparações justas e auditoria dos resultados, tanto em ambientes simulados quanto em contextos reais.

## 2.9. Perspectivas futuras

A trajetória natural de evolução desta abordagem aponta para a integração neuro-simbólica, combinando representações simbólicas (ontologias, grafos de conhecimento) com modelos subsimbólicos (LLMs, embeddings). O objetivo é unir raciocínio lógico e verificável com capacidade de generalização e fluência linguística.

Grafos de conhecimento e Ontologias em RDF/OWL permitem modelar formalmente entidades do domínio: Projeto, Tarefa, Recurso, Risco, Stakeholder, Entregável, Marco, suas propriedades e restrições; grafos materializam instâncias e relações (ALLEMANG;

HENDLER, 2011; FENSEL et al., 2020). Consultas SPARQL possibilitam inferências estruturais (por exemplo, tarefas críticas dependentes de recursos indisponíveis), difíceis de capturar apenas com similaridade vetorial.

Uma outra frente ligada a RAG + KG (neuro-simbólico). Um RAG híbrido pode combinar:

- (i) busca lexical (TF-IDF) e semântica (S-BERT) para recuperar textos;
- (ii) consultas SPARQL para extrair fatos relacionais e regras aplicáveis; e
- (iii) síntese por LLM com trilhas de evidência. Essa fusão tende a reduzir alucinações, elevar a precisão e explicabilidade.

Para uso de regras e inferência podem-se codificar regras do tipo: “se  $SPI < 0,8$  e há dependências críticas não iniciadas, então risco alto de atraso” confere capacidade dedutiva e consistência ao sistema. A combinação com sinais estatísticos (tendências de SPI/CPI) favorece decisões mais robustas.

O caminho evolutivo de uma solução multiagentes de IA no curto prazo, envolve:

- (i) ontologia mínima de GP (PMBOK) com vocabulário controlado;
- (ii) mapeamento do dataset sintético para o grafo;
- (iii) consultas SPARQL críticas (riscos, recursos, marcos);
- (iv) fusão RAG+SPARQL no *prompting*;
- (v) métricas de ganho de precisão/explicabilidade.

A médio prazo, explorar versionamento semântico, particionamento de grafos e índices híbridos (texto+grafo) para escalar.

Essa agenda de pesquisa aplicada tende a consolidar um sistema de apoio à decisão explicável, interoperável e aderente a padrões, requisito chave para adoção corporativa ampla.

Mais detalhes para perspectivas futuras e evolução do sistema multiagentes são abordadas no Apêndice deste documento

### **3. METODOLOGIA**

#### **3.1. Abordagem de pesquisa**

A metodologia adotada neste trabalho foi desenhada para avaliar, em um ambiente controlado e reproduzível, o impacto da aplicação de sistemas multiagentes baseados em inteligência artificial no gerenciamento de projetos de tecnologia da informação. O objetivo central é validar se a integração entre técnicas de recuperação aumentada por geração (RAG), modelos de linguagem de grande porte (LLMs), mecanismos de guardrails baseados no PMBOK e agentes especializados pode melhorar indicadores-chave de desempenho como SPI, CPI, ROI e taxa de sucesso de projetos.

Para isso, a pesquisa combina elementos de experimentação computacional com simulações longitudinais, nas quais múltiplas rodadas de análise são executadas sobre um portfólio de projetos sintético. Essa abordagem permite medir, de forma objetiva e mensurável, os efeitos cumulativos das recomendações geradas pelos agentes e identificar padrões de melhoria progressiva ao longo do ciclo de vida dos projetos.

Um aspecto fundamental desta metodologia é a separação entre o “**como**” e o “**o que**”: enquanto os capítulos anteriores apresentaram os fundamentos conceituais e arquitetônicos do sistema proposto, este capítulo detalha os métodos empregados para validar sua eficácia. Isso inclui a descrição do ambiente tecnológico utilizado, a estrutura dos experimentos, as métricas de avaliação adotadas e os critérios de reprodutibilidade, além de uma análise crítica das limitações e ameaças à validade dos resultados obtidos.

#### **3.2. Delineamento da pesquisa**

O delineamento metodológico deste trabalho caracteriza-se como pesquisa aplicada, de natureza experimental e abordagem quantitativa. Trata-se de um estudo exploratório voltado à avaliação empírica de uma proposta tecnológica desenvolvida especificamente para resolver um problema prático: aumentar a eficiência e a qualidade do processo de monitoramento e controle de projetos por meio de sistemas inteligentes multiagentes.

A natureza aplicada da pesquisa se evidencia na construção de um protótipo funcional capaz de operar em um cenário simulado de gestão de portfólio, permitindo a análise de desempenho em condições próximas às de um ambiente corporativo real. A dimensão experimental decorre da realização de múltiplas rodadas de simulação com controle de variáveis, uso de datasets artificiais e monitoramento de métricas quantitativas para mensurar os impactos da intervenção dos agentes. Já a abordagem quantitativa fundamenta-se na coleta e análise sistemática de dados numéricos — como índices de desempenho, variações de custo e progresso acumulado — que permitem validar hipóteses e estabelecer relações de causa e efeito.

O ciclo experimental segue uma lógica iterativa que reproduz, em ambiente controlado, o ciclo de vida real de projetos: inicia-se com uma medição de baseline, seguida por múltiplas rodadas de análise nas quais os agentes identificam desvios, recomendam ações corretivas e avaliam seus efeitos cumulativos. Essa estrutura permite observar a evolução dos projetos ao longo do tempo e identificar o impacto direto da inteligência multiagentes sobre sua performance.

A escolha desse delineamento atende ao objetivo de oferecer evidências concretas e mensuráveis sobre a viabilidade e os benefícios da abordagem proposta, fornecendo subsídios tanto para a aplicação prática em contextos corporativos quanto para futuros estudos acadêmicos na área.

Uma etapa essencial do delineamento metodológico consistiu na construção de um dataset sintético temporal, projetado para representar de forma realista o ciclo de vida de projetos corporativos. Esse conjunto de dados foi desenvolvido com base em características típicas observadas em ambientes empresariais, incorporando variáveis como prazos, variações orçamentárias e impactos de riscos. Para assegurar diversidade e representatividade, foram contempladas quinze tipologias distintas de projetos (conforme detalhado no Capítulo 4.2 – Tabela 2), abrangendo diferentes contextos de aplicação.

O dataset foi estruturado com 1.000 registros, cada um contendo atributos essenciais distribuídos entre seis domínios principais: cronograma, custos, escopo, riscos, qualidade e comunicação. Ao longo do ciclo de vida de cada projeto, foram simuladas vinte atualizações de status, permitindo observar a evolução temporal de indicadores-chave e a dinâmica dos riscos. A fim de garantir rigor metodológico e possibilitar replicação em estudos futuros, os dados foram divididos em três subconjuntos com finalidades distintas: 70% destinados ao treinamento e ajuste dos agentes, 20% utilizados para validação e calibração de estratégias e 10% reservados para a avaliação final de desempenho. Além disso, a utilização de sementes aleatórias controladas assegurou a reprodutibilidade dos resultados e a consistência estatística das análises comparativas.

Com base nesse conjunto, selecionou-se uma amostra de sete projetos que foram acompanhados ao longo de três rodadas experimentais subsequentes à medição inicial. Essa amostra permitiu a análise longitudinal dos indicadores de desempenho e a avaliação do impacto cumulativo das ações recomendadas pelos agentes ao longo do tempo.

### **3.3. Ambiente tecnológico e ferramentas**

O desenvolvimento e a execução dos experimentos foram realizados em um ambiente computacional projetado para garantir escalabilidade, flexibilidade, reprodutibilidade e robustez científica. A configuração do ambiente foi fundamental para possibilitar a implementação da arquitetura proposta, a orquestração dos agentes especializados, a execução das simulações em múltiplas rodadas e a análise dos resultados sob diferentes condições experimentais.

A solução foi desenvolvida em Python 3.x, linguagem amplamente reconhecida na comunidade científica e industrial por sua versatilidade e ecossistema robusto de bibliotecas para ciência de dados, inteligência artificial e processamento de linguagem natural. A escolha do Python também se justifica pela facilidade de integração com APIs externas, pela ampla documentação disponível e pela compatibilidade com ferramentas de análise e visualização de dados.

Para o tratamento, manipulação e análise dos dados estruturados, foram utilizadas bibliotecas consolidadas como Pandas e NumPy, responsáveis pela modelagem, transformação e gerenciamento dos conjuntos de dados. A visualização analítica dos resultados foi conduzida com o apoio da biblioteca Matplotlib, que permitiu a geração de gráficos e representações visuais das métricas de desempenho ao longo das rodadas de simulação.

No contexto de recuperação e representação semântica da informação, foram empregadas técnicas de aprendizado de máquina e NLP (Processamento de Linguagem Natural). A biblioteca scikit-learn foi utilizada para a construção de índices TF-IDF (Term Frequency–Inverse Document Frequency), essenciais para a busca lexical tradicional, enquanto a biblioteca Sentence-Transformers foi empregada para a geração de embeddings densos baseados em S-BERT (Sentence-BERT), possibilitando a representação vetorial de conteúdo e a recuperação semântica de informações. Essa combinação de abordagens lexical e semântica foi determinante para a eficácia do módulo de Retrieval-Augmented Generation (RAG) no sistema proposto.

A comunicação com o modelo de linguagem foi realizada por meio da API da OpenAI, utilizando o modelo GPT-4o-mini. A escolha deste modelo considerou critérios técnicos e metodológicos:

- **Custo-benefício:** sua leveza computacional e custo reduzido permitiram a execução de um número maior de interações durante as simulações sem comprometer os recursos disponíveis;
- **Latência e velocidade de resposta:** o tempo reduzido de inferência possibilitou a integração fluida entre o modelo e os agentes, além de garantir a execução eficiente de múltiplas rodadas de análise em prazos menores;
- **Qualidade contextual:** mesmo em sua versão compacta, o modelo demonstrou desempenho satisfatório em tarefas de síntese, explicação e geração de recomendações contextualizadas, apresentando boa capacidade de generalização para diferentes cenários de projetos.

Para garantir a consistência e a comparabilidade dos resultados, os parâmetros do modelo foram explicitamente definidos e mantidos constantes ao longo de todos os experimentos:

- **Temperatura: 0,7:** parâmetro que regula o equilíbrio entre criatividade e consistência nas respostas geradas, permitindo uma saída informativa sem comprometer a coerência técnica;
- **Máximo de tokens: 800:** valor configurado para controlar o volume de saída por consulta, assegurando custos previsíveis e padronização do tamanho das respostas durante as simulações.

A arquitetura multiagentes foi desenvolvida sobre o framework CrewAI, escolhido por sua robustez, maturidade e suporte nativo à criação, coordenação e orquestração de agentes especializados. Sua estrutura modular e extensível possibilita a substituição futura por outras plataformas equivalentes como LangGraph ou AutoGen, sem impacto estrutural sobre a arquitetura geral do sistema. Essa decisão metodológica garante a flexibilidade e a evolução do projeto em cenários futuros de pesquisa ou implementação corporativa.

O ambiente de desenvolvimento foi configurado no Visual Studio Code (VS Code), com suporte ao Jupyter Notebook para execução interativa dos experimentos, visualização incremental dos resultados e documentação detalhada dos processos. Essa combinação de ferramentas contribuiu para uma abordagem iterativa de desenvolvimento, permitindo ajustes rápidos, testes em múltiplas rodadas e controle preciso sobre o fluxo de execução dos agentes. Todos os artefatos produzidos ao longo dos experimentos incluindo os datasets sintéticos, relatórios analíticos, representações vetoriais, logs e resultados intermediários foram

versionados e armazenados com metadados e carimbo temporal. Esse processo de versionamento sistemático assegurou a rastreabilidade completa dos experimentos, facilitando auditorias metodológicas, análises comparativas e a reprodutibilidade dos resultados em diferentes contextos ou momentos futuros.

### **3.4. Estrutura Experimental do Sistema Multiagentes**

A estrutura experimental proposta neste estudo foi desenhada para simular, de maneira controlada, a evolução de um portfólio de projetos ao longo do tempo e avaliar como a intervenção de agentes inteligentes influencia seus resultados. Essa abordagem permite observar tanto os impactos imediatos das recomendações geradas pelos agentes quanto seus efeitos cumulativos em múltiplas iterações.

#### **3.4.1. Geração do Dataset e Reprodutibilidade**

Para os experimentos, foi criado um dataset sintético temporal com 1.000 tuplas de projetos, contendo atributos relacionados a cronograma, custos, riscos, escopo, qualidade e comunicação. Os dados foram gerados com base em distribuições estatísticas realistas e calibrados para simular cenários típicos de ambientes corporativos.

Embora o corpus completo tenha sido carregado na base de conhecimento para maximizar a efetividade do mecanismo de RAG, uma divisão teórica foi considerada para fins de documentação e reprodutibilidade:

- **70%** dos dados para composição do conhecimento de base e treinamento dos embeddings;
- **20%** para validação de consultas e avaliação semântica;
- **10%** para testes independentes e análise de generalização do sistema.

A seed 456 foi fixada durante todo o processo de geração, garantindo que os mesmos dados pudessem ser replicados em execuções futuras. Além disso, cada execução experimental foi acompanhada por logs detalhados de interações, parâmetros de configuração e resultados intermediários, assegurando total rastreabilidade.

### 3.4.2. Ciclo Experimental e Etapas de Simulação

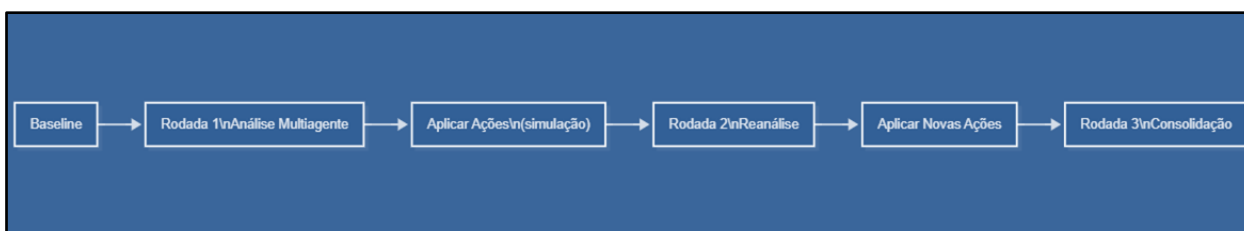
O ciclo experimental foi projetado para representar, em um ambiente controlado, as principais etapas do ciclo de vida de um portfólio de projetos submetido a processos contínuos de análise e intervenção. O objetivo central dessa abordagem é compreender, de maneira progressiva e cumulativa, o impacto da atuação dos agentes inteligentes ao longo do tempo e como suas recomendações influenciam os resultados dos projetos em diferentes estágios de maturidade.

A primeira fase do experimento consistiu no estabelecimento de uma linha de base (baseline), em que foram registrados os valores iniciais dos principais indicadores de desempenho como o Schedule Performance Index (SPI), o Cost Performance Index (CPI) e o progresso médio, sem qualquer interferência dos agentes. Essa medição inicial serviu como ponto de referência para todas as análises subsequentes.

Na sequência, a arquitetura multiagentes foi acionada para realizar a análise dos dados históricos e propor recomendações corretivas e preventivas voltadas à mitigação de desvios e otimização dos resultados. Essas recomendações foram aplicadas ao estado dos projetos de maneira simulada, possibilitando a observação de seus efeitos imediatos e acumulados ao longo do tempo. Rodadas adicionais de análise foram então conduzidas sobre os dados atualizados, permitindo a avaliação de tendências evolutivas e a identificação de padrões de melhoria sustentada.

Esse ciclo iterativo viabilizou a mensuração do impacto incremental da inteligência multiagentes sobre o desempenho dos projetos, bem como a análise dos ganhos obtidos em diferentes momentos do ciclo de vida. A abordagem também possibilitou a identificação de relações de causa e efeito entre as intervenções propostas e a evolução dos indicadores de desempenho, fornecendo subsídios relevantes para a compreensão da efetividade do sistema em contextos práticos de gestão de portfólio.

**Figura 1 - Ciclo experimental do sistema Multiagentes**



**Fonte: elaborado pelo autor (2025).**

Cada fase do processo foi acompanhada pela geração automática de relatórios, tabelas analíticas e visualizações gráficas, que ilustraram a evolução dos projetos e facilitaram a comparação entre o desempenho inicial e as rodadas subsequentes. Esses registros também permitiram evidenciar o impacto direto das recomendações sobre os resultados e forneceram uma base empírica sólida para a avaliação da proposta desenvolvida.

### **3.5. Procedimentos experimentais**

A execução dos experimentos foi conduzida a partir de um protocolo metodológico rigoroso, estruturado com o objetivo de garantir consistência, rastreabilidade, validade científica e reprodutibilidade dos resultados. O processo foi concebido de modo a avaliar a eficácia da arquitetura multiagentes proposta, bem como a precisão e o impacto das recomendações geradas pelos agentes em diferentes contextos de simulação.

O primeiro estágio envolveu a preparação e indexação dos dados. O conjunto sintético de 1.000 projetos foi processado por dois mecanismos complementares de recuperação de informação: um índice lexical baseado na métrica TF-IDF (Term Frequency–Inverse Document Frequency), responsável pela busca tradicional por termos relevantes, e um modelo de representação semântica com embeddings gerados por S-BERT (Sentence-BERT), que permitiu a compreensão contextual das consultas. A combinação dessas abordagens resultou em um sistema híbrido de recuperação que potencializou a precisão e a relevância dos dados utilizados pelos agentes.

Em seguida, foram ativados os agentes especializados, responsáveis por analisar dimensões específicas do gerenciamento de projetos: cronograma, custos, escopo, riscos, qualidade e comunicação. Sob a coordenação de um agente orquestrador, cada agente processou o subconjunto de informações pertinente ao seu domínio, identificando desvios, pontos críticos e oportunidades de melhoria. As recomendações produzidas foram submetidas a um conjunto de guardrails baseados no PMBOK® 7ª edição, atuando como um mecanismo de controle metodológico e terminológico que assegurou a conformidade com as boas práticas de gestão de projetos.

Posteriormente, as recomendações validadas foram consolidadas em relatórios analíticos, contendo diagnósticos detalhados, ações corretivas e preventivas sugeridas, bem como

previsões de impacto sobre o desempenho do projeto. Esses relatórios foram aplicados ao conjunto de dados de forma simulada, atualizando o estado dos projetos e servindo de insumo para as rodadas subsequentes de análise. Esse ciclo experimental foi repetido em três iterações consecutivas, permitindo a observação detalhada da evolução dos indicadores ao longo do tempo e a mensuração dos efeitos cumulativos das decisões tomadas pelos agentes.

Ao final do processo, todos os artefatos produzidos, incluindo tabelas de desempenho, gráficos evolutivos, registros de logs, embeddings, relatórios consolidados e resultados intermediários foram armazenados com versionamento e metadados associados. Essa prática garantiu transparência, auditabilidade e replicabilidade, permitindo que os experimentos pudessem ser reproduzidos em diferentes contextos e que as análises pudessem ser reconstituídas integralmente mesmo após o encerramento da pesquisa.

### 3.6. Métricas de avaliação

A avaliação do sistema multiagentes foi conduzida com base em indicadores clássicos de gerenciamento de projetos, conforme preconizado pelo PMBOK Guide – 7ª edição (PMI, 2021). O foco principal esteve nos índices derivados da técnica de Earned Value Management (EVM), por sua relevância na mensuração objetiva de desempenho temporal e financeiro:

- **Schedule Performance Index (SPI):** mede a eficiência do cronograma ao comparar o valor agregado (EV) com o valor planejado (PV). Valores superiores a 1 indicam que o projeto está adiantado, enquanto valores inferiores a 1 sugerem atraso.
- **Cost Performance Index (CPI):** avalia a eficiência dos custos ao comparar o valor agregado (EV) com o custo real (AC). Valores acima de 1 indicam que o projeto está sendo executado com custos menores que o previsto; valores abaixo de 1 indicam sobrecustos, estouro no orçamento.
- **Progresso (%):** representa a proporção de entregas concluídas em relação ao escopo total planejado. Permite identificar a velocidade de avanço dos projetos e a efetividade das ações corretivas.

Além desses indicadores primários, foram analisados indicadores complementares para oferecer uma visão mais ampla do desempenho do sistema:

- Variação de prazo: diferença percentual entre o cronograma planejado e o realizado.
- Economia de custos: redução percentual dos custos em relação ao baseline.

- Taxa de sucesso dos projetos: proporção de projetos concluídos dentro do prazo, orçamento e escopo definidos.

O uso combinado desses indicadores permitiu uma avaliação multifacetada dos efeitos da abordagem multiagentes, tanto no curto prazo (impactos imediatos após recomendações) quanto no longo prazo (tendências de melhoria ao longo das rodadas).

### **3.7. Garantia de reprodutibilidade**

A reprodutibilidade constitui um dos pilares metodológicos deste estudo e foi cuidadosamente assegurada em todas as etapas do processo experimental. Essa preocupação visa garantir que os resultados obtidos possam ser replicados com precisão por outros pesquisadores ou aplicados em ambientes corporativos distintos, preservando a consistência científica e a validade das conclusões apresentadas.

Para isso, foi empregada uma combinação de mecanismos técnicos e metodológicos voltados à padronização do ambiente experimental. A utilização de sementes determinísticas, em especial a seed 456, permitiu a geração controlada do dataset sintético e a seleção da amostra de projetos analisados, eliminando variações aleatórias que poderiam comprometer a comparabilidade dos resultados entre diferentes execuções.

Adicionalmente, todas as interações entre os agentes e o modelo de linguagem foram registradas detalhadamente, incluindo parâmetros de configuração (como temperatura e limite de tokens), valores limiares utilizados nas consultas léxicas e semânticas, e critérios aplicados aos processos de segmentação (chunking) dos documentos. Esses registros atuam como um histórico completo do pipeline experimental, possibilitando auditoria posterior e análise aprofundada das decisões tomadas em cada iteração.

Outro elemento fundamental foi o versionamento sistemático de todos os artefatos gerados incluindo datasets, embeddings, relatórios, gráficos e logs acompanhados de metadados e carimbo temporal. Essa prática assegura não apenas a rastreabilidade de cada etapa do experimento, mas também a possibilidade de reconstrução integral de cada rodada, permitindo a replicação dos resultados mesmo em contextos tecnológicos diferentes.

Por fim, os scripts utilizados para processamento dos dados e execução dos agentes foram organizados de forma modular e documentados detalhadamente, o que viabiliza sua reutilização e adaptação para novos estudos ou aplicações corporativas. A combinação dessas práticas

metodológicas garante um alto grau de confiabilidade e transparência, reforçando a validade científica dos resultados apresentados e seu potencial de aplicação prática em cenários reais.

### **3.8. Limitações e ameaças à validade**

Embora os resultados apresentados neste estudo sejam robustos e forneçam evidências consistentes sobre a efetividade dos sistemas multiagentes no gerenciamento de projetos, algumas limitações e ameaças à validade devem ser reconhecidas para contextualizar adequadamente as conclusões.

A principal limitação refere-se à natureza sintética do dataset utilizado. Embora cuidadosamente projetados para refletir cenários reais, os dados não capturam todas as nuances e complexidades inerentes a projetos corporativos como dinâmicas políticas, mudanças de escopo não documentadas, lições aprendidas ou decisões subjetivas de stakeholders. Essa característica impõe uma ameaça à validade externa, pois os resultados podem não ser diretamente generalizáveis a todos os contextos organizacionais.

Outra limitação importante é o tamanho relativamente pequeno da amostra experimental (7 projetos), que, embora suficiente para testes exploratórios e validações iniciais, restringe a extrapolação estatística dos resultados para portfólios maiores ou mais heterogêneos.

Do ponto de vista metodológico, a simulação de aplicação das recomendações ainda que útil para mensurar impactos não substitui completamente a complexidade da implementação em ambientes reais. Fatores como resistência organizacional, variação de produtividade humana e restrições orçamentárias não foram modelados na simulação.

Por fim, o escopo do experimento concentrou-se em métricas quantitativas (SPI, CPI, progresso, ROI), não abrangendo dimensões qualitativas relevantes como satisfação dos stakeholders, maturidade organizacional em gestão de projetos ou impacto estratégico de longo prazo.

Apesar dessas limitações, os resultados obtidos oferecem um panorama sólido e promissor sobre o potencial dos sistemas multiagentes na gestão de projetos. Eles devem ser interpretados como prova de conceito, um passo inicial fundamental que pode ser expandido em estudos futuros com dados reais, portfólios maiores e ambientes produtivos.

## 4. PROPOSTA E DESENVOLVIMENTO

### 4.1. Visão Geral da Arquitetura do Sistema

O sistema proposto tem por finalidade apoiar o gerenciamento de projetos de tecnologia da informação por meio de sistemas multiagentes integrados a técnicas de recuperação aumentada por geração (RAG), processamento de linguagem natural e mecanismos de validação (guardrails) fundamentados no PMBOK® Guide 7ª edição. A arquitetura foi concebida de modo modular e escalável, articulando camadas funcionais que, em conjunto, constituem um fluxo contínuo desde a ingestão e curadoria de dados até a síntese de recomendações executivas.

A Camada de Dados e Conhecimento consolida a base informacional do sistema. Nela, um dataset sintético de 1.000 projetos reúne atributos distribuídos nos domínios de cronograma, custos, escopo, qualidade, comunicação e riscos, incluindo indicadores como SPI, CPI, EV, PV, AC, EAC, exposição a riscos e métricas de qualidade (por exemplo, DRE). Sobre esse corpus são gerados status reports temporais que simulam a evolução dos projetos ao longo do ciclo de vida, permitindo análises longitudinais. Em paralelo, um repositório vetorial armazena embeddings gerados com S-BERT, viabilizando consultas por similaridade semântica. O conteúdo normativo do PMBOK (7ª ed.) integra essa camada como corpus de referência para a etapa de validação, assegurando conformidade terminológica e aderência às boas práticas.

A Camada de Inteligência implementa o RAG híbrido, que combina busca lexical (índices TF-IDF) e recuperação semântica (S-BERT) para compor, a cada consulta, um contexto informacional de alta relevância. Esse contexto é posteriormente submetido a guardrails derivados dos 12 princípios e 8 domínios de desempenho do PMBOK, os quais atuam como filtro metodológico de consistência, coerência e conformidade. O resultado é um insumo confiável para as etapas subsequentes de raciocínio e geração de recomendações.

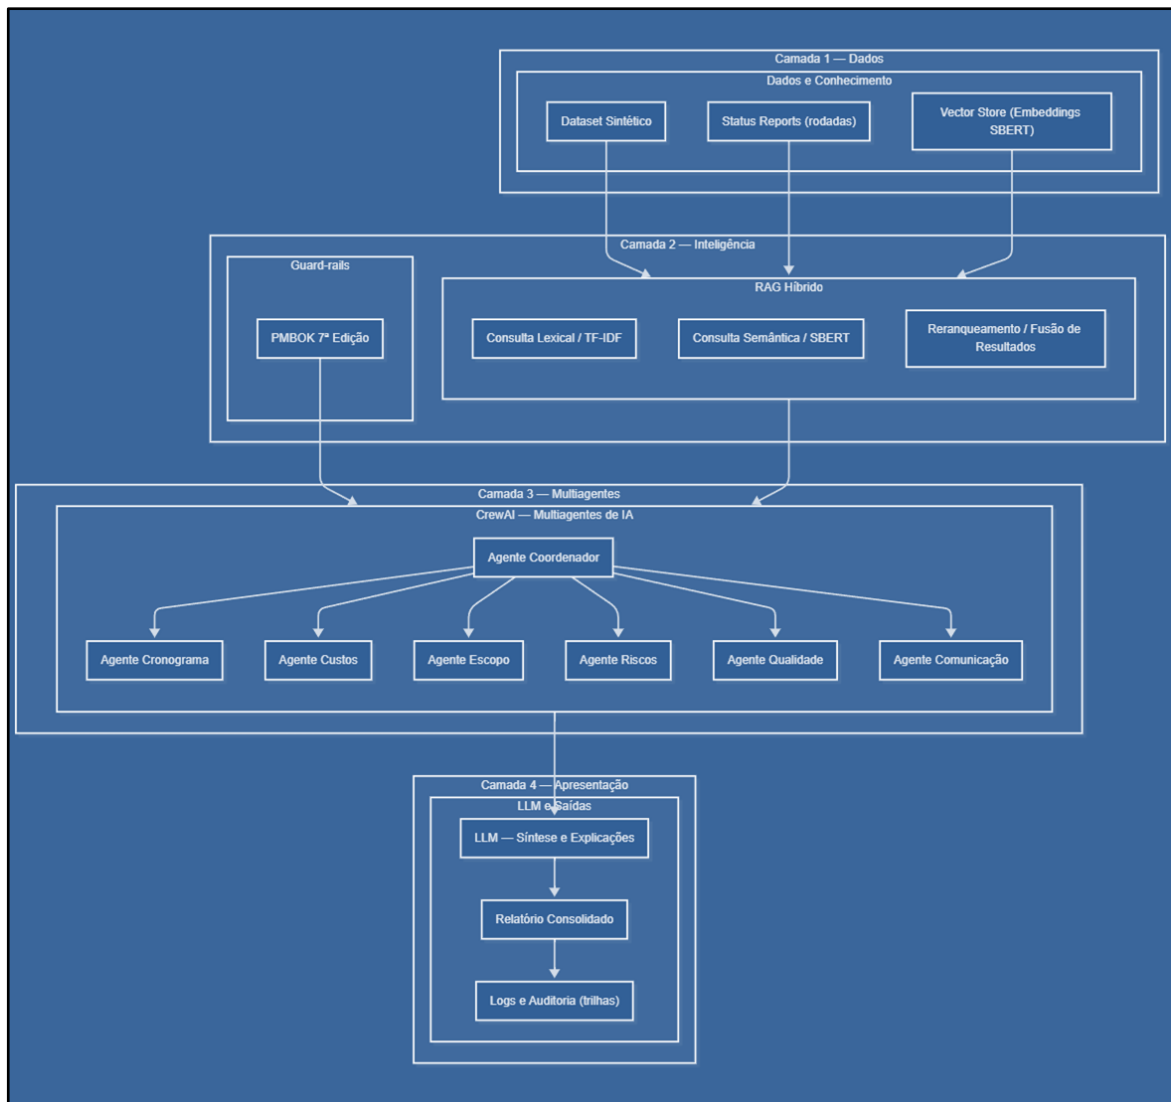
A Camada Multiagentes organiza os agentes especializados: cronograma, custos, escopo, riscos, qualidade e comunicação, e um agente coordenador responsável por orquestrar interações, resolver conflitos e consolidar as propostas de ação. Os agentes consomem o contexto produzido pelo RAG, executam análises em seus domínios e encaminham recomendações ao coordenador, que prioriza iniciativas e estrutura planos de ação integrados.

Essa camada é implementada sobre o framework CrewAI, escolhido pelo suporte nativo à coordenação distribuída e pela arquitetura modular, o que favorece a extensibilidade e a substituição futura por plataformas equivalentes (por exemplo, LangGraph ou AutoGen) sem impactos estruturais.

Por fim, a Camada de Apresentação e Interação realiza a síntese em linguagem natural por meio de um LLM (GPT-4o-mini), transformando diagnósticos técnicos em recomendações claras, rastreáveis e acionáveis. Nessa camada, o sistema produz relatórios analíticos, consolida trilhas de auditoria e disponibiliza evidências que justificam as sugestões emitidas, fortalecendo a explicabilidade e a governança do processo decisório.

De forma integrada, as quatro camadas estabelecem um pipeline cognitivo em que dados estruturados e conhecimento normativo alimentam a recuperação híbrida; os agentes especializados, apoiados pelo coordenador, transformam evidências em decisões priorizadas; e o LLM finaliza a comunicação com usuários por meio de relatórios explicáveis. Essa organização reduz a fragmentação analítica, promove coerência entre domínios e amplia a capacidade de generalização do sistema em portfólios de projetos heterogêneos.

**Figura 2 - Arquitetura do sistema multiagentes**



Fonte: elaborado pelo autor (2025).

#### **4.2. Camada de dados e conhecimento - geração dos Conjuntos de Dados (dataset) sintéticos**

A base operacional do sistema multiagentes proposto neste trabalho foi construída sobre um dataset sintético elaborado especificamente para representar, de maneira realista e controlada, o ciclo de vida de projetos de tecnologia da informação. Esse conjunto de dados contém atributos detalhados que refletem múltiplas dimensões do gerenciamento de projetos como cronograma, custos, escopo, qualidade, comunicação e riscos, além de registros históricos que

simulam status reports temporais, permitindo acompanhar a evolução dos indicadores ao longo do tempo.

Além da estrutura tabular principal, o sistema inclui um repositório vetorial (Vector Store), no qual são armazenados embeddings gerados por modelos do tipo S-BERT. Esse repositório possibilita a realização de consultas semânticas por similaridade, ampliando a capacidade de análise contextual e a precisão das recomendações emitidas pelos agentes. O corpus normativo do PMBOK 7ª edição também integra essa camada, funcionando como base de referência para os guardrails aplicados às recomendações, garantindo a conformidade metodológica com as melhores práticas de gestão de projetos.

A seguir, apresenta-se a Tabela 1, que detalha os principais atributos que compõem o dataset sintético desenvolvido para o treinamento dos agentes e a análise automatizada dos projetos simulados.

**Tabela 1 - Atributos do dataset de projetos para treinamento de agentes**

Atributo	Descrição	Exemplo/Variante(s)
ID	Identificador único do projeto	PROJ_0001
Nome	Nome do projeto	Sistema ERP 001
Tipo	Tipo de projeto de TI	Sistema ERP, Aplicativo Mobile, Portal Web, ... (ver tabela 2)
Duração (meses)	Duração planejada do projeto em meses	18
Orçamento	Orçamento total do projeto (R\$)	2.500.000
Progresso (%)	Percentual de progresso do projeto	65
Status	Status atual do projeto	Verde, Amarelo, Vermelho
Nível de Risco	Nível de risco do projeto	Baixo, Médio, Alto
SPI	Schedule Performance Index	0.92
CPI	Cost Performance Index	1.05
BAC	Budget at Completion (orçamento total)	2.500.000
PV	Planned Value	1.800.000
EV	Earned Value	1.650.000
AC	Actual Cost	1.570.000
SV	Schedule Variance	-150.000
CV	Cost Variance	80.000
EAC	Estimate at Completion	2.380.000
ETC	Estimate to Complete	810.000

<b>Atributo</b>	<b>Descrição</b>	<b>Exemplo/Variante(s)</b>
VAC	Variance at Completion	120.000
TCPI	To Complete Performance Index	1.02
Total_Requisitos	Total de requisitos do projeto	120
Requisitos_Entregues	Número de requisitos entregues	90
RequisitosAtendidosPct	Percentual de requisitos atendidos	75.0
Mudancas_Aprovadas	Número de mudanças de escopo aprovadas	8
Indice_Mudancas	Índice de mudanças (mudanças/total de requisitos)	0.067
Total_Entregas	Total de entregas previstas	40
Entregas_Rejeitadas	Número de entregas rejeitadas	2
DefeitosEscopoPct	Percentual de defeitos de escopo	5.0
Total_Defeitos	Total de defeitos encontrados	30
Defeitos_Removidos	Defeitos removidos	28
DRE	Defect Removal Efficiency	0.93
Total_Horas	Total de horas do projeto	12.000
Horas_Retrabalho	Horas de retrabalho	1.200
TaxaRetrabalhoPct	Percentual de retrabalho	10.0
Total_Entregaveis	Total de entregáveis previstos	60
Entregaveis_Aprovados	Entregáveis aprovados	55
Conformidade_Pct	Percentual de conformidade	91.7
Total_Interacoes	Total de interações de comunicação	350
TempoRespostaHoras	Tempo médio de resposta (horas)	8.5
SatisfacaoStakeholderPct	Satisfação dos stakeholders (%)	82.0
Total_Relatorios	Total de relatórios gerados	30
Relatorios_Aprovados	Relatórios aprovados	28
ClarezaRelatoriosPct	Percentual de clareza dos relatórios	93.3
Probabilidade_Risco	Probabilidade de risco	0.45
Impacto_Risco	Impacto financeiro do risco	120.000
EMV	Expected Monetary Value (valor esperado do risco)	54.000
Riscos_Criticos	Número de riscos críticos ativos	4
REI	Risk Exposure Index	216.000

**Fonte: elaborado pelo autor (2025).**

Os projetos simulados abrangem múltiplos cenários organizacionais e técnicos, refletindo diferentes contextos de aplicação de soluções de TI. A Tabela 2 apresenta as tipologias selecionadas, que foram utilizadas como base para a geração dos dados sintéticos e para a avaliação do desempenho dos agentes.

**Tabela 2 - Tipos de Projetos de TI**

<b>Tipo de Projeto</b>
Sistema ERP
Aplicativo Mobile
Portal Web
Sistema CRM
Plataforma E-commerce
Sistema BI
Aplicação Cloud
Sistema de Gestão
Portal Corporativo
Sistema de Vendas
Plataforma Digital
Sistema Financeiro
Aplicativo Web
Sistema de RH
Portal de Serviços

**Fonte: elaborado pelo autor (2025).**

Ao todo, mais de 40 métricas são calculadas para cada projeto, distribuídas em categorias que cobrem desde aspectos básicos de desempenho até indicadores avançados de EVM, escopo, qualidade, comunicação e riscos. Esses atributos alimentam tanto os módulos analíticos dos agentes quanto o mecanismo de recuperação aumentada (RAG híbrido), que utiliza o dataset como referência contextual para análises mais precisas.

### 4.2.1. Geração de dados correlacionados

A qualidade e a utilidade de um dataset sintético dependem não apenas da diversidade de suas variáveis, mas também da coerência e da correlação entre os atributos que o compõem. Com esse objetivo, o processo de geração dos dados neste estudo foi cuidadosamente projetado para reproduzir relações estatísticas realistas observadas em projetos corporativos de tecnologia da informação. Essa abordagem assegura que o comportamento dos indicadores simulados reflita padrões consistentes e plausíveis, permitindo que os agentes de inteligência artificial identifiquem tendências, aprendam com elas e gerem recomendações de maior relevância prática.

Um exemplo dessa lógica relacional está no status geral do projeto, cuja classificação em Verde, Amarelo ou Vermelho está diretamente associada ao desempenho temporal (SPI) e financeiro (CPI). Em contextos reais, projetos com bom andamento tendem a apresentar índices próximos ou acima do valor de referência (1,0), enquanto projetos problemáticos exibem valores significativamente inferiores. Essa relação foi modelada no dataset conforme as faixas apresentadas abaixo:

- Status Verde: SPI entre 0,95 e 1,15 e CPI entre 0,95 e 1,20
- Status Amarelo: SPI entre 0,80 e 1,05 e CPI entre 0,85 e 1,05
- Status Vermelho: SPI entre 0,60 e 0,90 e CPI entre 0,70 e 0,95

De forma semelhante, o nível de risco foi correlacionado ao status do projeto, refletindo a tendência de que projetos mais estáveis apresentem riscos menos significativos, enquanto aqueles com maior grau de atraso ou sobrecusto estejam expostos a riscos elevados. A modelagem seguiu a seguinte distribuição probabilística:

- Projetos com status Verde: 60% de probabilidade de risco Baixo
- Projetos com status Amarelo: 60% de probabilidade de risco Médio
- Projetos com status Vermelho: 60% de probabilidade de risco Alto

Outro aspecto relevante é a correlação entre desempenho e qualidade, fundamental para refletir cenários reais de gestão de projetos. A taxa de remoção de defeitos (Defect Removal Efficiency – DRE) e outras métricas de qualidade tendem a ser mais altas em projetos bem geridos, ao passo que projetos com desvios de cronograma e orçamento costumam apresentar maior incidência de falhas. O dataset reflete esse padrão por meio das seguintes faixas:

- Projetos com status Verde: DRE entre 85% e 98%
- Projetos com status Amarelo: DRE entre 70% e 90%

- Projetos com status Vermelho: DRE entre 50% e 75%

A adoção dessas correlações contribui para que o conjunto de dados se aproxime de condições operacionais reais, simulando as interdependências típicas do gerenciamento de projetos. Isso permite que os agentes de IA não apenas processem variáveis isoladas, mas também reconheçam padrões multidimensionais e antecipem efeitos colaterais decorrentes de decisões em diferentes domínios de projeto.

Essa modelagem estatística orientada por correlação fortalece o processo de aprendizado e análise dos agentes, ampliando a precisão das recomendações e a robustez dos experimentos conduzidos neste trabalho. Além disso, ao criar cenários mais realistas, o sistema multiagentes é capaz de gerar diagnósticos mais confiáveis e insights mais relevantes para aplicação prática em contextos corporativos.

A seguir, a Tabela 3 apresenta a estrutura geral desses relatórios de status e os principais atributos utilizados no processo de análise pelos agentes:

**Tabela 3 – Conjuntos de dados de status de projetos**

Atributo	Descrição	Exemplo/Variante(s)
report_id	Identificador único do status report	PROJ000/R01
project_id	ID do projeto associado	PROJ_0001
project_name	Nome do projeto	Sistema ERP 001
report_date	Data do status report (YYYY-MM-DD)	2025-08-01
report_number	Número sequencial do report	1
progressatreport	Progresso (%) no momento do report	15.0
status	Status do projeto	Verde, Amarelo, Vermelho
trend	Tendência do projeto	Melhorando, Deteriorando, Estável, Inicial
spi	Schedule Performance Index	0.92
cpi	Cost Performance Index	1.05
pv	Planned Value	180.000
ev	Earned Value	165.000
ac	Actual Cost	157.000
sv	Schedule Variance	-15.000
cv	Cost Variance	8.000
eac	Estimate at Completion	238.000
etc	Estimate to Complete	81.000
vac	Variance at Completion	12.000

Atributo	Descrição	Exemplo/Variante(s)
tcpi	To Complete Performance Index	1.02
requisitos_entregues	Requisitos entregues até o report	12
requisitoscompletionpct	Percentual de requisitos atendidos	24.0
mudancas_acumuladas	Mudanças de escopo acumuladas	2
indice_mudancas	Índice de mudanças	0.017
defeitosescopopct	Percentual de defeitos de escopo	4.5
dre	Defect Removal Efficiency	0.91
taxaretrabalhopct	Percentual de retrabalho	11.0
conformidade_pct	Percentual de conformidade	89.0
temporespostahoras	Tempo médio de resposta (horas)	9.0
satisfacaostakeholderpct	Satisfação dos stakeholders (%)	80.0
clarezarelatoriospct	Clareza dos relatórios (%)	92.0
probabilidade_risco	Probabilidade de risco	0.45
impacto_risco	Impacto financeiro do risco	12.000
emv	Expected Monetary Value (valor esperado do risco)	5.400
riscos_criticos	Número de riscos críticos ativos	2
rei	Risk Exposure Index	10.800
observations	Observações do report	Report 1 - Progresso: 15.0% - Status: Verde

**Fonte: elaborado pelo autor (2025).**

A estrutura apresentada na Tabela 3 representa a base temporal sobre a qual o sistema multiagentes realiza suas análises dinâmicas. Ao registrar o estado dos projetos em diferentes momentos, esses status reports permitem que os agentes observem tendências evolutivas, identifiquem padrões de comportamento e proponham ações corretivas com base em evidências históricas, em vez de análises pontuais e isoladas.

Esse formato de dados é essencial para simular ciclos reais de monitoramento e controle de projetos, nos quais decisões estratégicas são tomadas continuamente a partir de variações nos indicadores de desempenho. Assim, a combinação entre dados estruturais (apresentados nas Tabelas 1 e 2) e dados temporais (Tabela 3) fornece uma representação abrangente do ambiente organizacional, garantindo maior precisão na inferência dos agentes e fortalecendo a confiabilidade das recomendações produzidas pelo sistema.

### 4.3. Camada de inteligência: RAG híbrido e Guardrails PMBOK

A camada de inteligência constitui o núcleo analítico do sistema proposto, sendo responsável por transformar dados brutos e relatórios de status em conhecimento contextualizado e recomendações acionáveis. Essa camada opera por meio de um mecanismo de Recuperação Aumentada por Geração (RAG – Retrieval-Augmented Generation), projetado para ampliar a precisão e a relevância das respostas geradas pelos modelos de linguagem, e por um conjunto de guardrails baseados no PMBOK® 7ª edição, que asseguram conformidade metodológica e terminológica com as melhores práticas de gerenciamento de projetos.

O modelo RAG adotado neste estudo segue uma abordagem híbrida, combinando técnicas de recuperação lexical e semântica para otimizar a busca por informações relevantes em um corpus que inclui o dataset sintético, relatórios de status e trechos normativos do PMBOK. Essa arquitetura em camadas visa mitigar limitações inerentes ao uso isolado de LLMs, como alucinações e falta de precisão contextual ao incorporar evidências empíricas e conhecimento especializado diretamente no processo de geração de respostas.

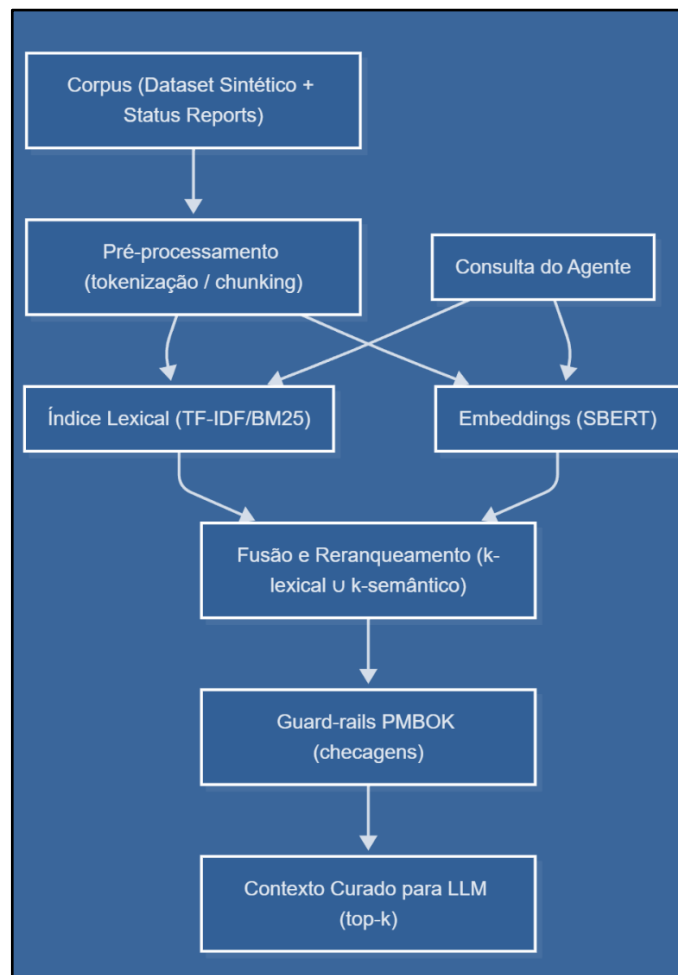
O fluxo de operação do RAG ocorre em três etapas principais, descritas a seguir:

1. **Consulta Lexical (TF-IDF):** realiza a indexação e a busca de documentos relevantes com base em termos-chave presentes na consulta do agente, garantindo precisão na correspondência literal e velocidade na recuperação de dados.
2. **Consulta Semântica (S-BERT):** expande a busca para conteúdos semanticamente similares, mesmo que redigidos com vocabulário diferente, utilizando representações vetoriais densas capazes de capturar relações de significado entre conceitos.
3. **Reranking e Fusão:** combina os resultados das duas etapas anteriores, atribuindo pesos contextuais e priorizando informações com maior relevância semântica e lexical. Essa fusão assegura que as respostas finais não apenas atendam aos critérios de precisão textual, mas também de coerência e relevância conceitual.

Uma vez recuperadas as informações mais pertinentes, elas são submetidas ao módulo de guardrails PMBOK, que atua como um filtro normativo e semântico. Essa camada adicional tem a função de validar as recomendações geradas, assegurando que estejam alinhadas com os 12 princípios e os 8 domínios de desempenho definidos pelo PMBOK® (PMI, 2021). A aplicação dos guardrails também permite detectar inconsistências, eliminar ambiguidades e padronizar a terminologia técnica empregada, aumentando a confiabilidade dos resultados.

A combinação do mecanismo de recuperação híbrido com a camada de validação normativa resulta em uma inteligência analítica mais robusta e confiável. Por um lado, o RAG amplia a capacidade do sistema de contextualizar informações e aprender com experiências passadas; por outro, os guardrails funcionam como uma camada de controle que reforça a aderência às boas práticas de gerenciamento de projetos. O resultado é um fluxo decisório mais preciso, explicável e alinhado a padrões reconhecidos internacionalmente.

**Figura 3 - Pipeline do RAG híbrido: recuperação lexical e semântica, fusão, PMBOK, LLM.**



Fonte: elaborado pelo autor (2025)

#### 4.4. Sistema RAG (Retrieval-Augmented Generation)

O sistema de Recuperação Aumentada por Geração (RAG) constitui o núcleo cognitivo da camada de inteligência e desempenha um papel estratégico na transformação de dados históricos e conhecimento organizacional em recomendações fundamentadas. Sua principal

função é conectar os modelos de linguagem natural a um repositório estruturado de informações relevantes, garantindo que as inferências e recomendações produzidas pelos agentes sejam baseadas não apenas em conhecimento geral, mas também em contexto específico do domínio de gerenciamento de projetos.

A abordagem RAG combina técnicas de recuperação de informação e geração de linguagem natural, criando um elo entre dados históricos, melhores práticas e análise preditiva. Em vez de depender exclusivamente de modelos de linguagem para gerar respostas, o que poderia resultar em erros de contexto ou interpretações imprecisas, o RAG atua como um mecanismo de enriquecimento de contexto, fornecendo ao modelo evidências empíricas e referências normativas antes da geração de recomendações.

No contexto deste trabalho, o sistema RAG foi projetado para identificar padrões e tendências a partir de projetos concluídos, relatórios de status e documentos de referência do PMBOK®. Ele recupera informações por similaridade contextual, levando em consideração tanto o vocabulário técnico quanto o significado semântico dos conteúdos analisados. Esse processo eleva significativamente a qualidade e a precisão das recomendações, reduzindo a ocorrência de alucinações - fenômeno comum em modelos de linguagem quando não há suporte contextual adequado, e aumentando a confiabilidade dos resultados.

A integração do RAG à arquitetura multiagentes ocorre como um processo iterativo e contínuo: conforme novos dados são gerados pelos agentes e armazenados no repositório, o sistema amplia seu conhecimento e refina a relevância das recomendações futuras. Isso permite que a solução proposta opere em um ciclo de aprendizado incremental, aproximando-se de um modelo de suporte à decisão que evolui com a dinâmica dos projetos.

Ao fornecer recomendações fundamentadas em experiências históricas e boas práticas consolidadas, o RAG contribui para um processo de tomada de decisão mais preciso, explicável e alinhado às necessidades reais do ambiente corporativo. Sua utilização representa um avanço significativo em relação a abordagens tradicionais, nas quais os sistemas de apoio à decisão dependem exclusivamente de dados estruturados ou da inferência autônoma de modelos de linguagem.

#### 4.4.1. Arquitetura do Sistema RAG

A arquitetura do sistema RAG desenvolvida neste trabalho foi projetada para integrar múltiplas camadas de processamento de informação de forma coordenada, permitindo que os agentes acessem, interpretem e utilizem conhecimento contextual relevante no processo de tomada de decisão. Ela combina componentes de indexação, recuperação e enriquecimento semântico, resultando em um fluxo de análise capaz de transformar dados históricos e conhecimento especializado em recomendações aplicáveis a cenários de gerenciamento de projetos.

O sistema é composto por quatro componentes principais, que operam de maneira complementar:

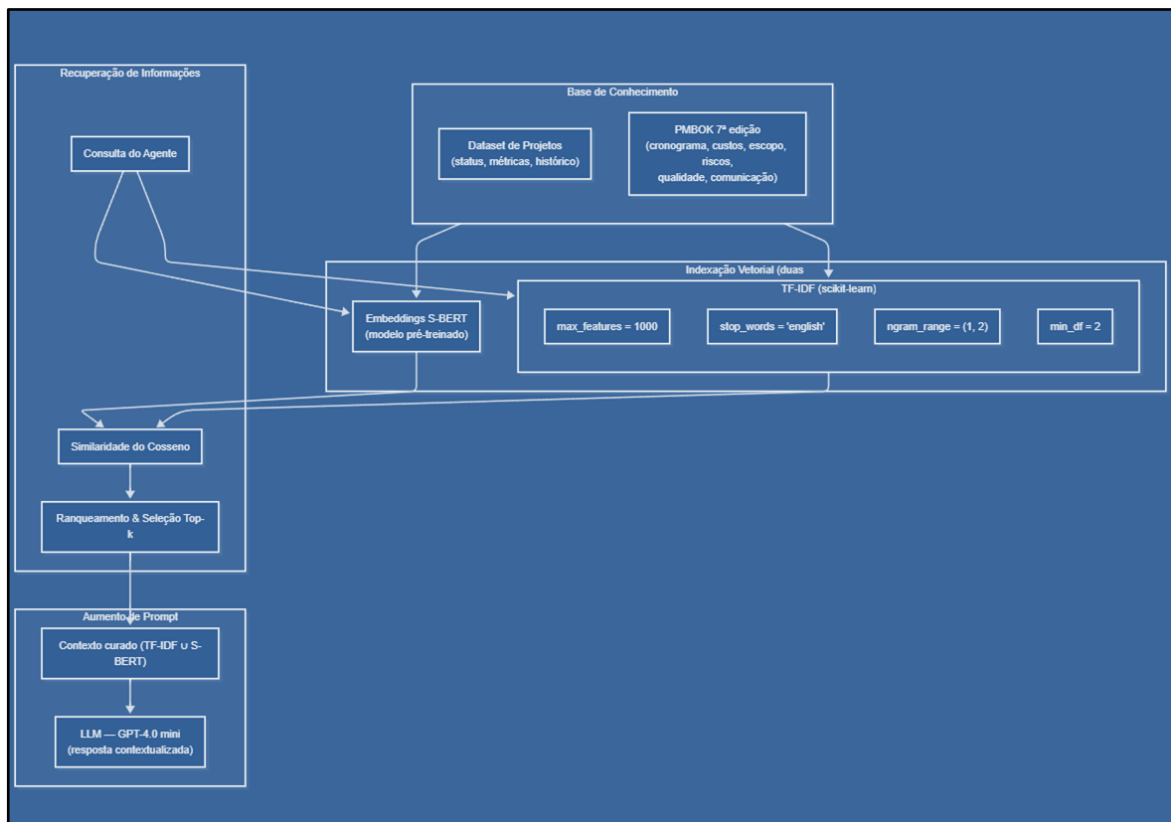
1. **Base de Conhecimento:** representa o núcleo informacional do sistema e contém dados provenientes de múltiplas fontes, incluindo o dataset sintético de projetos, relatórios de status temporais e trechos normativos do PMBOK® 7ª edição. Essas informações são organizadas por domínio de conhecimento (cronograma, custos, escopo, riscos, qualidade e comunicação), o que facilita consultas direcionadas e reduz a ambiguidade na recuperação de informações.
2. **Indexação Vetorial:** responsável por estruturar os dados da base de conhecimento em formatos adequados para busca eficiente. Nessa etapa, duas técnicas complementares são aplicadas:
  - **TF-IDF (Term Frequency–Inverse Document Frequency):** realiza a indexação lexical, priorizando termos com maior relevância estatística e garantindo precisão em consultas baseadas em palavras-chave.
  - **S-BERT (Sentence-BERT):** gera embeddings semânticos densos, capazes de capturar relações de significado entre sentenças e conceitos, ampliando a capacidade do sistema de identificar documentos relacionados mesmo quando o vocabulário utilizado difere.
3. **Mecanismo de Recuperação de Informações:** atua sobre os índices gerados, calculando a similaridade entre a consulta formulada pelo agente e os documentos disponíveis na base de conhecimento. O ranqueamento dos resultados é realizado por meio da similaridade de cosseno, assegurando que os registros mais semanticamente relevantes sejam priorizados.
4. **Aumento de Prompt (*Prompt Enrichment*):** etapa final do pipeline, na qual as informações recuperadas são incorporadas ao contexto enviado ao modelo de linguagem

(LLM). Esse enriquecimento contextual aumenta a precisão e a profundidade das respostas, permitindo que o modelo considere evidências empíricas e recomendações normativas ao formular suas análises e recomendações.

A interação entre esses componentes cria um fluxo contínuo e eficiente de informação, em que dados armazenados são convertidos em conhecimento acionável. Além disso, a arquitetura foi concebida para ser modular e extensível, permitindo a substituição ou atualização de componentes individuais como modelos de embeddings ou algoritmos de busca sem comprometer a integridade do sistema como um todo.

Essa modularidade garante não apenas a adaptabilidade da solução a diferentes contextos corporativos, mas também sua escalabilidade para bases de conhecimento maiores e cenários mais complexos. Ao articular técnicas lexicais e semânticas com validação normativa, a arquitetura do RAG fornece uma base sólida para o desenvolvimento de sistemas de apoio à decisão explicáveis, confiáveis e orientados a dados.

**Figura 4 - Arquitetura do RAG**



Fonte: elaborado pelo autor (2025)

#### 4.4.2. Funcionamento do Sistema RAG

O funcionamento do sistema RAG segue um fluxo estruturado de etapas que tem como objetivo maximizar a precisão das análises e recomendações fornecidas pelos agentes de inteligência artificial. Em vez de simplesmente realizar buscas por palavras-chave ou depender exclusivamente da inferência de modelos de linguagem, o sistema adota um processo iterativo que combina recuperação de informações, contextualização semântica e geração de conhecimento orientado por evidências.

O ciclo operacional inicia-se com a formulação de uma consulta contextual por parte do agente, baseada no estado atual do projeto sob análise. Essa consulta reflete os principais indicadores do projeto como SPI, CPI, progresso acumulado, variações de escopo e riscos críticos. E representa a necessidade de informação específica para apoiar a tomada de decisão.

Na etapa seguinte, a consulta é processada por dois mecanismos complementares de transformação e busca:

- **Indexação Lexical (TF-IDF):** converte a consulta em um vetor de frequência ponderada de termos, permitindo a identificação de documentos com vocabulário similar ao utilizado pelo agente.
- **Indexação Semântica (S-BERT):** transforma a consulta em uma representação vetorial densa, capaz de capturar significados e relações conceituais mesmo quando há diferenças de terminologia entre a consulta e os documentos da base de conhecimento.

Essas duas abordagens convergem na etapa de ranqueamento semântico, onde a similaridade de cosseno é utilizada para medir a proximidade entre a consulta e os documentos disponíveis. Os registros mais relevantes, geralmente os cinco com maior similaridade, são então selecionados e preparados para a próxima fase do pipeline.

A partir desses documentos recuperados, o sistema gera um resumo analítico do contexto histórico, que sintetiza os principais padrões e resultados observados em projetos semelhantes. Esse resumo inclui métricas como SPI e CPI médios, status predominante, tipos de projetos relacionados e nível médio de similaridade dos casos recuperados. Ao fornecer uma visão consolidada de experiências passadas, o sistema possibilita que os agentes fundamentem suas recomendações não apenas em dados isolados, mas em evidências empíricas contextualizadas. O passo final consiste no enriquecimento do prompt enviado ao modelo de linguagem (LLM). O contexto histórico recuperado, combinado com as informações atuais do projeto e com as regras normativas dos guardrails PMBOK, é incorporado ao prompt de entrada. Essa integração

garante que as recomendações geradas pelo LLM sejam contextualizadas, precisas e alinhadas às boas práticas de gerenciamento de projetos.

O processo descrito não apenas amplia a confiabilidade das recomendações, como também promove um ciclo contínuo de aprendizado. À medida que novos dados são inseridos no sistema e novos relatórios são analisados, o mecanismo de RAG se torna mais preciso, melhorando sua capacidade de reconhecer padrões e antecipar tendências em cenários futuros. Essa evolução contínua reforça seu papel como um componente essencial na construção de sistemas de apoio à decisão explicáveis e baseados em evidências.

#### 4.5. Guardrail PMBOK

O módulo de guardrails constitui um dos componentes críticos da camada de inteligência do sistema, funcionando como um mecanismo de validação, controle e padronização das recomendações geradas pelos agentes. Sua função principal é assegurar que as análises e ações propostas estejam em conformidade com os princípios, domínios de desempenho e boas práticas estabelecidas pelo Project Management Body of Knowledge (PMBOK®) – 7ª edição (PMI, 2021).

Enquanto o RAG amplia o contexto e fornece evidências históricas, o módulo de guardrails atua como um sistema normativo de verificação, garantindo que as decisões sugeridas não se limitem ao que é estatisticamente relevante, mas que também atendam a critérios metodológicos, éticos e estratégicos amplamente reconhecidos na disciplina de gerenciamento de projetos.

Os guardrails operam como uma camada adicional de inteligência responsável por três funções fundamentais:

- **Validação de Conteúdo:** toda recomendação gerada pelos agentes é comparada com os princípios e domínios do PMBOK, de modo a verificar sua consistência terminológica, conceitual e metodológica. Essa etapa impede, por exemplo, que uma recomendação de mitigação de risco contradiga práticas reconhecidas ou negligencie aspectos de governança.
- **Verificação de Limiares:** indicadores críticos como SPI, CPI, DRE e REI são avaliados à luz de valores de referência definidos. Quando métricas ultrapassam esses limiares, o sistema sinaliza a necessidade de ação corretiva ou de revisão do plano de projeto, assegurando que desvios relevantes não passem despercebidos.

- **Padronização e Conformidade:** as recomendações são ajustadas para empregar terminologia padronizada e coerente com as boas práticas do PMI, o que aumenta sua interpretabilidade, facilita a comunicação com stakeholders e fortalece o processo de auditoria de decisões.

A base conceitual dos guardrails está ancorada nos 12 princípios fundamentais do gerenciamento de projetos e nos 8 domínios de desempenho definidos pelo PMBOK®, que abrangem desde a governança e a liderança até a adaptabilidade organizacional e a entrega de valor. Esses princípios orientam a atuação dos agentes em múltiplos níveis, promovendo uma abordagem mais abrangente e responsável para a tomada de decisão automatizada.

O uso de guardrails agrega um componente essencial de governança algorítmica ao sistema multiagentes, pois garante que decisões automatizadas respeitem padrões estabelecidos e evitem vieses ou inconsistências metodológicas. Além disso, ao reforçar a aderência a padrões reconhecidos internacionalmente, o módulo aumenta a confiabilidade das recomendações, melhora a aceitação das soluções geradas e facilita sua integração a ambientes corporativos reais.

Em síntese, os guardrails representam um elo crítico entre a inteligência computacional e o conhecimento normativo em gerenciamento de projetos. Sua presença transforma o sistema de um simples mecanismo de recomendação baseado em dados em uma plataforma de apoio à decisão confiável, explicável e alinhada às melhores práticas da disciplina.

**Tabela 4 - Guardrails PMBOK 7ª Edição: Princípios Oficiais**

Princípio (Chave)	Nome Completo	Descrição Resumida	Aplicação Prática
Administração Responsável	Seja um Administrador Diligente, Respeitoso e Cuidadoso	Integridade, cuidado e confiabilidade em todas as decisões	Sustentabilidade e ética
Equipe	Crie um Ambiente Colaborativo da Equipe	Envolvimento e desenvolvimento da equipe	Colaboração e comunicação
Partes interessadas	Envolve-se Efetivamente com as Partes Interessadas	Identificação e engajamento proativo dos stakeholders	Comunicação regular e transparente
Valor	Foque no Valor	Concentração nos resultados e benefícios	Priorizar entregas de valor
Pensamento sistêmico	Reconheça, Avalie e Responda às Interações do Sistema	Projetos como sistemas interativos	Considerar impactos sistêmicos
Liderança	Demonstre Comportamentos de Liderança	Adaptação de comportamentos de liderança	Liderança situacional
Personalização	Adapte com Base no Contexto	Personalização da abordagem conforme o contexto	Processos customizados

Princípio (Chave)	Nome Completo	Descrição Resumida	Aplicação Prática
Qualidade	Incorpore a Qualidade nos Processos e Entregas	Foco na qualidade em todo o ciclo de vida	Controles de qualidade
Complexidade	Navegue na Complexidade	Práticas e pensamento adequados para ambientes complexos	Abordagens adaptativas
Risco	Otimize as Respostas aos Riscos	Identificação contínua de ameaças e oportunidades	Gestão proativa de riscos
Adaptabilidade	Abrace a Adaptabilidade e a Resiliência	Capacidade de resposta rápida a mudanças	Resiliência organizacional
Mudança	Permita a Mudança para Alcançar o Estado Futuro Previsto	Preparação para adoção das entregas do projeto	Facilitar transição e mudança

Fonte: elaborado pelo autor (2025).

#### 4.5.1. Funcionalidades dos Guardrails

O sistema de guardrails implementa as seguintes funcionalidades:

- a) Validação de recomendações: Verifica se as recomendações geradas pelos agentes estão alinhadas com as melhores práticas do PMBOK.
- b) Verificação de conformidade: Garante que as recomendações respeitem os limites de métricas estabelecidos.
- c) Geração de mensagens de validação: Produz mensagens informativas sobre a validação das recomendações.
- d) Produção de relatórios de validação: Gera relatórios detalhados sobre o processo de validação.

#### 4.5.2. Regras implementadas

Para assegurar que o processo de validação conduzido pelos guardrails seja sistemático, transparente e alinhado às boas práticas do gerenciamento de projetos, um conjunto de regras automatizadas foi implementado no sistema. Essas regras atuam como diretrizes operacionais derivadas diretamente dos princípios e domínios de desempenho do *PMBOK® 7ª edição*, funcionando como critérios objetivos para a verificação de conformidade das recomendações geradas pelos agentes.

Cada regra representa uma tradução prática dos padrões metodológicos do PMI para o contexto da automação inteligente. Elas definem limites, condições e requisitos que disparam ações específicas, como alertas, notificações, revisões de planos e replanejamentos. Dessa forma, os guardrails não apenas asseguram a aderência metodológica das recomendações, mas também promovem a padronização das respostas do sistema frente a diferentes cenários operacionais. A seguir, apresenta-se um resumo das principais regras implementadas em cada domínio de conhecimento:

- **Cronograma:** define limiares para indicadores como SPI e prazos de entrega. Recomendações são emitidas quando valores ficam abaixo de faixas aceitáveis ou quando extensões de prazo ultrapassam percentuais críticos.
- **Custos:** monitora variações orçamentárias e valores de CPI, gerando planos de recuperação e exigindo aprovação formal em casos de desvios significativos.
- **Escopo:** impõe documentação obrigatória para qualquer alteração e solicita revisões quando mudanças impactam cronograma ou custos de forma substancial.
- **Riscos:** exige planos de mitigação para riscos de alta probabilidade e impacto, além de revisões regulares do registro de riscos.
- **Qualidade:** estabelece gatilhos para revisão de processos e planos corretivos quando indicadores como DRE ou conformidade ficam abaixo de valores aceitáveis.
- **Comunicação:** impõe padrões mínimos para engajamento de stakeholders e tempo de resposta, sinalizando falhas que possam comprometer a eficácia da comunicação do projeto.

Essas regras tornam o processo de monitoramento automatizado mais robusto e confiável, permitindo que o sistema não apenas identifique desvios, mas também proponha respostas padronizadas e alinhadas às práticas recomendadas pela literatura. Com isso, o módulo de guardrails atua como uma camada de supervisão estratégica, fortalecendo a governança dos projetos e aumentando a confiabilidade das decisões automatizadas.

A Tabela 5 sintetiza a aplicação dessas diretrizes por domínio de agente e destaca exemplos de práticas associadas a cada um deles:

Tabela 5 - Guidelines PMBOK por Agente

Agente	Domínios Primários	Princípios Chave	Guidelines Específicas (Exemplos)
Cronograma	planejamento, entrega, medição	adaptabilidade, pensamento sistêmico, qualidade	Aplicar adaptabilidade ao cronograma, monitorar desempenho, etc.
Custo	planejamento, medição, trabalho de projeto	administração responsável, valor, pensamento sistêmico	Administração responsável dos recursos, controle financeiro
Risco	incerteza, medição, stakeholders	risco, complexidade, adaptabilidade	Identificar ameaças, construir adaptabilidade, engajar stakeholders
Qualidade	entrega, medição, desenvolvimento	qualidade, valor, stakeholders	Incorporar qualidade, engajar stakeholders, avaliar sistematicamente
Escopo	entrega, stakeholders, desenvolvimento	valor, stakeholders, mudança	Navegar escopo, engajar stakeholders, permitir mudanças controladas
Comunicação	stakeholders, equipe, trabalho de projeto	stakeholders, equipe, liderança	Engajar stakeholders, criar ambiente colaborativo, liderar comunicações

Fonte: elaborado pelo autor (2025).

#### 4.6. Camada Multiagentes e orquestração com CrewAI

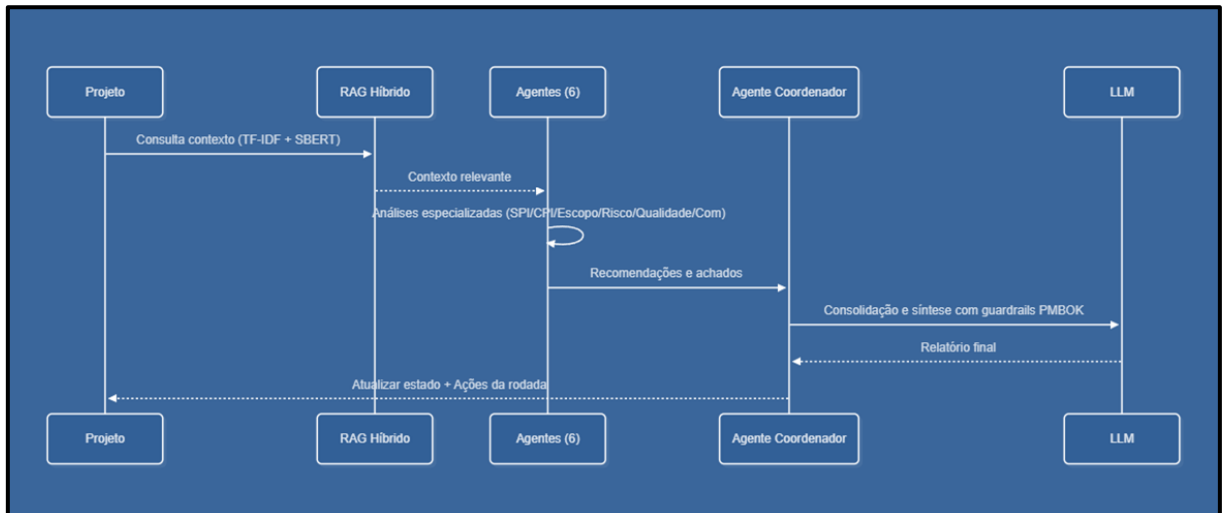
Os seis agentes especializados e o Agente Coordenador compõem a camada decisória distribuída. Cada agente opera sobre dados do seu domínio, consome contexto RAG, é validado pelos guardrails e produz recomendações; o Agente Coordenador resolve conflitos e consolida o plano de ação.

- **Agente Cronograma:** Analisa SPI, prazos e marcos.
- **Agente Custos:** Calcula CPI, orçamento e ROI.
- **Agente Escopo:** Avalia requisitos e entregas.
- **Agente Riscos:** Identifica e classifica ameaças e oportunidades.
- **Agente Qualidade:** Monitora métricas de desempenho e padrões de qualidade.
- **Agente Comunicação:** Analisa a eficácia do fluxo de informação entre stakeholders.
- **Agente Coordenador:** Centraliza as decisões, integra análises e emite recomendações.

Esses agentes atuam de forma cooperativa, trocando informações e influenciando mutuamente suas análises. Por exemplo, uma decisão do agente de custos pode alterar o plano de cronograma, exigindo nova análise pelo agente de tempo. Esse comportamento emergente

aumenta a precisão das recomendações e simula o processo de governança colaborativa de projetos reais.

**Figura 5 - Orquestração dos Agentes**



Fonte: elaborado pelo autor (2025).

#### 4.6.1. Agente Coordenador de Projetos

O Agente Coordenador de Projetos atua como um gerente de alto nível, responsável por orquestrar o trabalho dos agentes especializados e consolidar suas recomendações. Suas principais funcionalidades incluem:

- Distribuição de tarefas:** Atribui tarefas aos agentes especializados com base nas necessidades do projeto e nas prioridades identificadas.
- Consolidação de recomendações:** Integra as recomendações dos diferentes agentes em um plano de ação coerente.
- Resolução de conflitos:** Identifica e resolve conflitos entre recomendações de diferentes agentes.
- Priorização de ações:** Determina a ordem de prioridade das ações recomendadas com base em seu impacto potencial.
- Comunicação com stakeholders:** Prepara relatórios executivos e comunicações para os stakeholders do projeto.
- Monitoramento de progresso:** Acompanha a implementação das recomendações e ajusta o plano conforme necessário.

O Agente Coordenador utiliza o modelo GPT-4.0mini com um prompt especializado que inclui diretrizes para integração de recomendações e resolução de conflitos. Ele também tem acesso a uma visão holística do projeto, permitindo decisões mais estratégicas.

#### 4.6.2. Agente especializado de IA - Cronograma

O Agente de Cronograma é responsável por monitorar e controlar o cronograma do projeto. Suas principais funcionalidades incluem:

- a) **Análise de arquivos de status de cronograma:** O agente analisa os dados de cronograma do projeto, identificando desvios e tendências.
- b) **Cálculo do SPI (Schedule Performance Index):** O agente calcula o SPI como a razão entre o Valor Agregado (EV) e o Valor Planejado (PV), fornecendo uma medida da eficiência do cronograma.
- c) **Avaliação da saúde do cronograma:** Com base no SPI, o agente classifica a saúde do cronograma em diferentes níveis:
  - i. -  $SPI < 0.8$ : Crítico
  - ii. -  $0.8 \leq SPI < 0.9$ : Alerta
  - iii. -  $0.9 \leq SPI < 0.95$ : Atenção
  - iv. -  $0.95 \leq SPI < 1.05$ : Normal
  - v. -  $1.05 \leq SPI < 1.1$ : Bom
  - vi. -  $SPI \geq 1.1$ : Excelente
- d) **Análise de caminho crítico:** Identifica tarefas no caminho crítico e avalia seu impacto no cronograma geral.
- e) **Previsão de tendências:** Utiliza dados históricos para prever tendências futuras no cronograma.
- f) **Geração de recomendações:** O agente utiliza o sistema RAG para recuperar informações relevantes do PMBOK e gerar recomendações específicas para melhorar o desempenho do cronograma. E faz análise cruzada dentro da tríplice restrição (Tempo x Custos x Escopo) com impacto na qualidade da entrega do projeto.
- g) **Produção de relatórios detalhados:** O agente gera relatórios detalhados sobre o status do cronograma, incluindo análises, tendências e recomendações.

### 4.6.3. Agente especializado de IA - Custos

O Agente de Custos é responsável por monitorar e controlar os custos do projeto. Suas principais funcionalidades incluem:

- a) **Análise de arquivos de status de custos:** O agente analisa os dados de custos do projeto, identificando desvios e tendências.
- b) **Cálculo do CPI (Cost Performance Index):** O agente calcula o CPI como a razão entre o Valor Agregado (EV) e o Custo Real (AC), fornecendo uma medida da eficiência dos custos.
- c) **Avaliação da saúde dos custos:** Com base no CPI, o agente classifica a saúde dos custos em diferentes níveis:
  - i. -  $CPI < 0.8$ : Crítico
  - ii. -  $0.8 \leq CPI < 0.9$ : Alerta
  - iii. -  $0.9 \leq CPI < 0.95$ : Atenção
  - iv. -  $0.95 \leq CPI < 1.05$ : Normal
  - v. -  $1.05 \leq CPI < 1.1$ : Bom
  - vi. -  $CPI \geq 1.1$ : Excelente
- d) **Análise de fluxo de caixa:** Avalia o fluxo de caixa do projeto e identifica potenciais problemas de liquidez.
- e) **Previsão de custos:** Utiliza técnicas de EVM para prever custos futuros e o custo final do projeto (EAC).
- f) **Análise de variância de custos:** Identifica as causas de variações de custo e seu impacto no orçamento.
- g) **Geração de recomendações:** O agente utiliza o sistema RAG para recuperar informações relevantes do PMBOK e gerar recomendações específicas para melhorar o desempenho de custos. E faz análise cruzada dentro da tríplice restrição (Tempo x Custos x Escopo) com impacto na qualidade da entrega do projeto.
- h) **Produção de relatórios detalhados:** O agente gera relatórios detalhados sobre o status dos custos, incluindo análises, tendências e recomendações.

### 4.6.4. Agente especializado de IA - Escopo

O Agente de Escopo é responsável por monitorar alterações de escopo e seu impacto no projeto. Suas principais funcionalidades incluem:

- a) **Análise de arquivos de status de escopo:** O agente analisa os dados de escopo do projeto, identificando mudanças e seu impacto.
- b) **Identificação de mudanças de escopo:** O agente identifica mudanças no escopo do projeto, analisando requisitos adicionados, modificados ou removidos.
- c) **Avaliação do impacto das mudanças:** O agente avalia o impacto das mudanças de escopo no cronograma e nos custos do projeto.
- d) **Rastreamento de requisitos:** Monitora o status de implementação dos requisitos e identifica desvios.
- e) **Análise de completude do escopo:** Avalia se o escopo atual é suficiente para atingir os objetivos do projeto.
- f) **Detecção de escopo não documentado:** Identifica trabalho sendo realizado que não está formalmente incluído no escopo.
- g) **Geração de recomendações:** O agente utiliza o sistema RAG para recuperar informações relevantes do PMBOK e gerar recomendações específicas para melhorar o desempenho de escopo. E faz análise cruzada dentro da tríplice restrição (Tempo x Custos x Escopo) com impacto na qualidade da entrega do projeto.
- h) **Produção de relatórios detalhados:** O agente gera relatórios detalhados sobre o status do escopo, incluindo análises, tendências e recomendações.

#### 4.6.5. Agente especializado de IA - Riscos

O Agente de Riscos é responsável por monitorar e controlar os riscos do projeto. Suas principais funcionalidades incluem:

- a) **Análise de arquivos de status de riscos:** O agente analisa os dados de riscos do projeto, identificando riscos críticos e tendências.
- b) **Identificação de riscos críticos:** O agente identifica riscos com alto potencial de impacto no projeto.
- c) **Avaliação do impacto dos riscos:** O agente avalia o impacto potencial dos riscos identificados no projeto.
- d) **Cálculo de exposição ao risco:** Calcula o valor monetário esperado (EMV) e o índice de exposição ao risco (REI).

- e) **Monitoramento de gatilhos de risco:** Identifica quando condições de gatilho para riscos conhecidos são atingidas.
- f) **Identificação de novos riscos:** Analisa o ambiente do projeto para identificar riscos emergentes.
- g) **Avaliação da eficácia das respostas:** Monitora a eficácia das estratégias de resposta a riscos implementadas.
- h) **Geração de recomendações:** O agente utiliza o sistema RAG para recuperar informações relevantes do PMBOK e gerar recomendações específicas para mitigar riscos.
- i) **Produção de relatórios detalhados:** O agente gera relatórios detalhados sobre o status dos riscos, incluindo análises, tendências e recomendações.

#### 4.6.6. Agente especializado de IA - Qualidade

O Agente de Qualidade é responsável por monitorar e controlar a qualidade do projeto e seus entregáveis. Suas principais funcionalidades incluem:

- a) **Análise de métricas de qualidade:** O agente analisa métricas como DRE (Defect Removal Efficiency), taxa de retrabalho e conformidade.
- b) **Avaliação da saúde da qualidade:** Com base nas métricas, o agente classifica a saúde da qualidade em diferentes níveis.
- c) **Identificação de problemas de qualidade:** Detecta padrões e tendências que indicam problemas de qualidade.
- d) **Análise de causa raiz:** Investiga as causas fundamentais de problemas de qualidade recorrentes.
- e) **Monitoramento de padrões de qualidade:** Verifica a conformidade com padrões e normas de qualidade aplicáveis.
- f) **Avaliação de processos de qualidade:** Analisa a eficácia dos processos de garantia e controle de qualidade.
- g) **Geração de recomendações:** O agente utiliza o sistema RAG para recuperar informações relevantes do PMBOK e gerar recomendações específicas para melhorar a qualidade.
- h) **Produção de relatórios detalhados:** O agente gera relatórios detalhados sobre o status da qualidade, incluindo análises, tendências e recomendações.

#### 4.6.7. Agente especializado de IA - Comunicação

O Agente de Comunicação é responsável por monitorar e otimizar a comunicação no projeto.

Suas principais funcionalidades incluem:

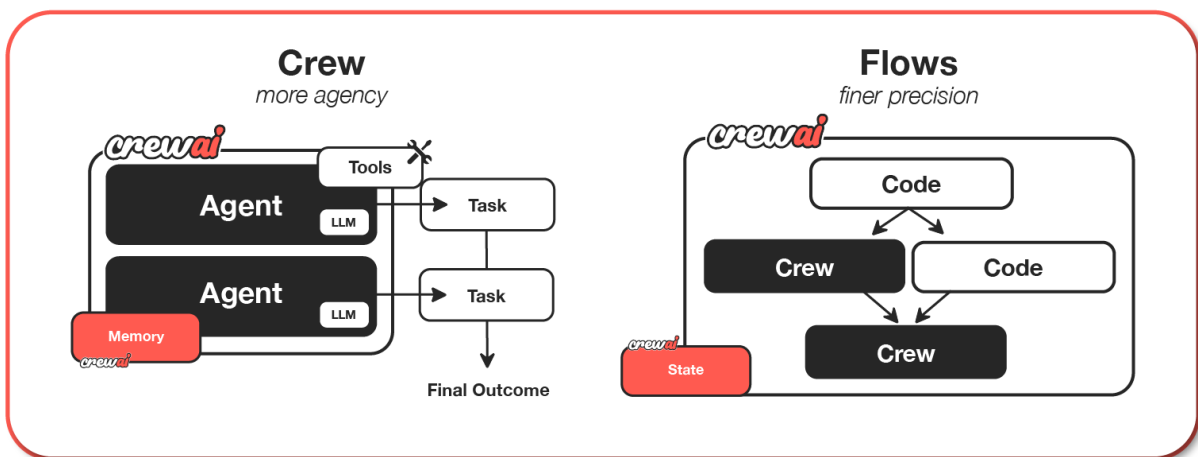
- a) **Análise de métricas de comunicação:** O agente analisa métricas como tempo médio de resposta, satisfação dos stakeholders e clareza dos relatórios.
- b) **Avaliação da eficácia da comunicação:** Com base nas métricas, o agente avalia a eficácia da comunicação no projeto.
- c) **Identificação de falhas de comunicação:** Detecta padrões e tendências que indicam problemas de comunicação.
- d) **Análise de canais de comunicação:** Avalia a eficácia dos diferentes canais de comunicação utilizados no projeto.
- e) **Monitoramento do engajamento dos stakeholders:** Analisa o nível de engajamento dos stakeholders nas comunicações do projeto.
- f) **Avaliação da qualidade da informação:** Verifica se as informações comunicadas são precisas, relevantes e oportunas.
- g) **Geração de recomendações:** O agente utiliza o sistema RAG para recuperar informações relevantes do PMBOK e gerar recomendações específicas para melhorar a comunicação.
- h) **Produção de relatórios detalhados:** O agente gera relatórios detalhados sobre o status da comunicação, incluindo análises, tendências e recomendações.

## 4.7. Integração com Framework CrewAI

### 4.7.1. Arquitetura CrewAI

O sistema foi integrado com o framework CrewAI para permitir a coordenação dos agentes em um workflow colaborativo. O CrewAI é uma plataforma que facilita a criação e orquestração de sistemas multiagentes, permitindo que os agentes trabalhem juntos de forma eficiente. Integração nativa para definição de agentes, papéis, tarefas e ferramentas, com gestão de equipes (crew) e suporte a fluxos hierárquicos ou sequenciais.

Figura 6 - Conceito básico da arquitetura CrewAI



Fonte: <https://github.com/crewAIInc/crewAI>

### 4.7.2. Componentes da Integração

A integração com o CrewAI envolve os **agentes CrewAI** (6 especialistas + 1 coordenador), **ferramentas personalizadas** (cálculos EVM, análise de status, RAG, validação PMBOK), **tarefas por domínio**, e **Crew com regras de colaboração e escalonamento**

### 4.7.3. Modos de Operação

O sistema suporta dois modos de operação:

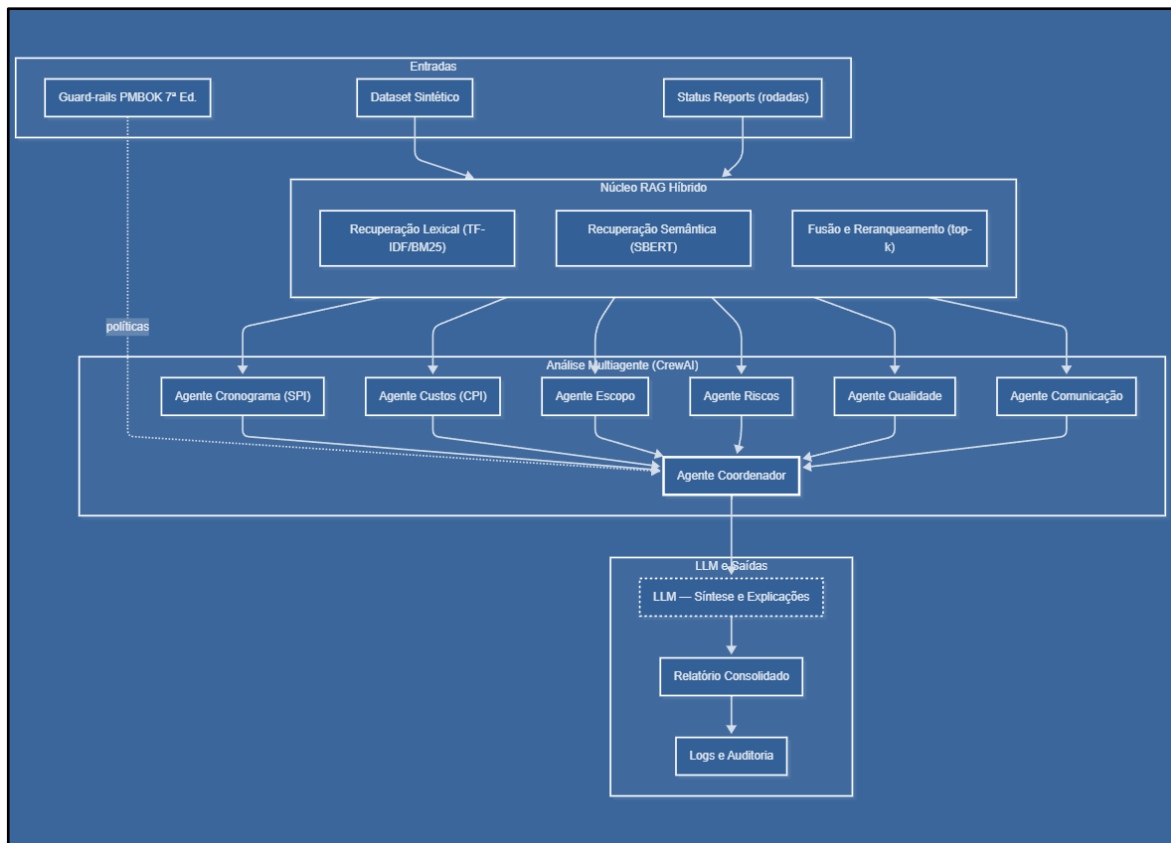
1. **Sequencial:** Os agentes trabalham em sequência, cada um analisando seu domínio específico e passando os resultados para o próximo agente. Este modo é útil quando as análises de cada domínio são independentes.
2. **Hierárquico:** O agente coordenador gerencia o trabalho dos seis agentes especializados, atribuindo tarefas, consolidando resultados e tomando decisões de alto nível. Este modo é mais adequado para cenários complexos que requerem coordenação entre diferentes domínios.

## 4.8. Camada de integração com LLM e Geração de insights

Após a consolidação das análises, os resultados são enviados a um modelo de linguagem de grande porte (LLM), responsável por interpretar o contexto, sintetizar recomendações e gerar relatórios explicativos em linguagem natural. Essa camada atua como interface de comunicação entre o sistema e o usuário, transformando dados complexos em recomendações compreensíveis e acionáveis.

Os relatórios gerados incluem diagnósticos, recomendações de ações corretivas e previsões sobre o andamento futuro dos projetos. Também são produzidos logs de auditoria, permitindo rastrear decisões e validar a origem de cada recomendação.

**Figura 7 - Fluxo de Decisão - dados → RAG → agentes → coordenador → LLM → relatório**



Fonte: elaborado pelo autor (2025).

## 4.9. Uso de LLM no Sistema Multiagentes

### 4.9.1. Construção e Integração

O sistema utiliza LLMs (Large Language Models) para análise inteligente e geração de recomendações detalhadas em cada etapa do fluxo dos agentes. O modelo utilizado é o OpenAI GPT-4o-mini, acessado diretamente via API OpenAI. Isso permite maior controle sobre prompts, contexto e integração com os demais módulos do sistema.

Detalhes Técnicos:

- **Modelo:** gpt-4o-mini (OpenAI)
- **Integração:** Direta via API OpenAI, com configuração de chave e cliente no início do notebook.

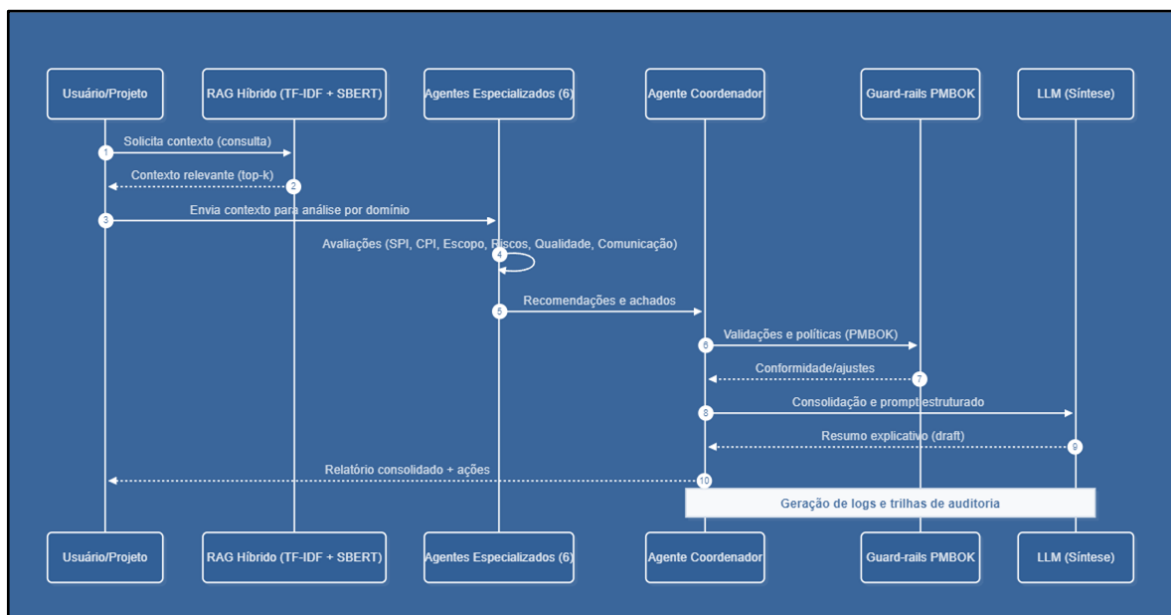
- **Prompt Engineering:** Cada agente envia ao LLM um contexto enriquecido (dados do projeto, resultados do RAG, validação PMBOK) e uma pergunta específica, solicitando recomendações práticas, alinhadas ao PMBOK.
- **Customização:** O prompt do sistema inclui instruções para análise detalhada, recomendações acionáveis, identificação de riscos e oportunidades, e aderência às melhores práticas.
- **Fallback:** Caso a API OpenAI não esteja disponível, o sistema utiliza uma análise baseada em regras, garantindo robustez.

#### 4.9.2. Fluxo de Uso do LLM:

O agente executa busca semântica via RAG para encontrar projetos similares, a seguir as recomendações preliminares são validadas pelo módulo Guardrails PMBOK, então o contexto enriquecido é enviado ao LLM, que gera uma análise detalhada e recomendações finais. E o resultado é integrado ao relatório do agente e ao relatório consolidado do gerente de projeto.

A figura a seguir detalha o fluxo.

**Figura 8 - Fluxo de uso LLM**



Fonte: elaborado pelo autor (2025).

### 4.9.3. Vantagens da Integração Direta

Algumas vantagens da integração direta são listadas a seguir:

- **Velocidade e Eficiência:** Chamada direta à API OpenAI, sem overhead de frameworks externos.
- **Personalização:** Prompts customizados por agente e por área de análise.
- **Aderência ao PMBOK:** Recomendações sempre validadas contra as melhores práticas.
- **Robustez:** Fallback automático para análise baseada em regras caso o LLM não esteja disponível.

## 5. ANÁLISE DOS RESULTADOS E IMPACTOS

### 5.1. Introdução

Este capítulo apresenta uma análise detalhada dos resultados obtidos a partir da aplicação de um sistema multiagentes de Inteligência Artificial para apoio ao gerenciamento de projetos de tecnologia da informação. O objetivo principal foi demonstrar, de forma quantitativa e qualitativa, o impacto real da solução no gerenciamento de projetos e validar a hipótese de que um modelo baseado em agentes inteligentes especializados, associados a técnicas de recuperação aumentada de informação (RAG) e integração com modelos de linguagem natural, pode melhorar significativamente o desempenho de projetos em termos de prazo, custo, risco e qualidade.

Os resultados demonstraram melhorias consistentes em indicadores críticos, comprovando a eficiência do sistema proposto e evidenciando seu potencial de aplicação no contexto corporativo.

Nesta seção serão apresentados os resultados do experimento conduzido com 7 projetos selecionados do dataset sintético (universo de 1.000 projetos), avaliados ao longo de três (3) rodadas de simulação (R1, R2, R3) a partir de um baseline inicial. O objetivo foi verificar, de forma quantitativa e qualitativa, se o sistema multiagentes proposto apoiado por RAG híbrido (TF-IDF + S-BERT), guardrails PMBOK e LLM GPT-4o-mini é capaz de:

- a) Melhorar o desempenho em cronograma e custo (SPI e CPI);
- b) Acelerar o progresso dos projetos (percentual de avanço);
- c) Gerar recomendações explicáveis e acionáveis, coerentes com o PMBOK e entre agentes;
- d) Reduzir exposição a riscos e não conformidades;
- e) Sustentar ganhos ao longo de rodadas sucessivas (efeito longitudinal).

### 5.2. Configuração Experimental

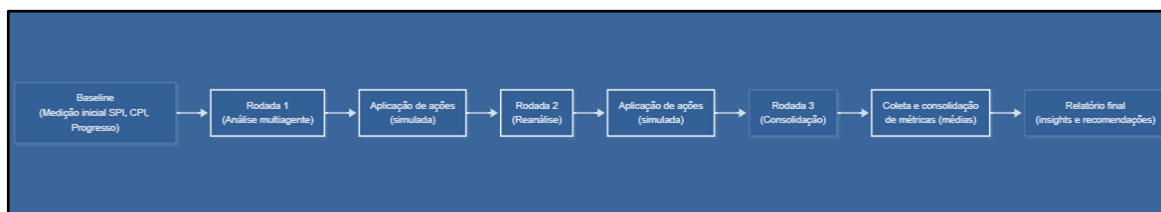
O desenho experimental seguiu o ciclo: **Baseline** → **R1** → **Aplicação simulada das ações** → **R2** → **Aplicação simulada** → **R3**.

Em cada rodada, os agentes executaram:

- (i) recuperação semântica (RAG),
- (ii) validação por guardrails (PMBOK 7ª ed.) e
- (iii) síntese por LLM (GPT-4o-mini, temperatura 0,7, *max\_tokens* 800).

Os resultados foram registrados em arquivos CSV/PNG com *timestamp* para rastreabilidade.

**Figura 9 - Pipeline do experimento**



Fonte: elaborado pelo autor (2025).

**Tabela 6 - Resumo dos parâmetros experimentais**

Parâmetro	Valor
Total de projetos no dataset	1000
Projetos analisados	7
Status reports por projeto	20
Total de interações multiagentes	60
Total de rodadas de análise	3
Modelo de linguagem	GPT-4o-mini
Mecanismo de busca semântica	TF-IDF + S-BERT
Base de conhecimento	PMBOK 7ª Edição

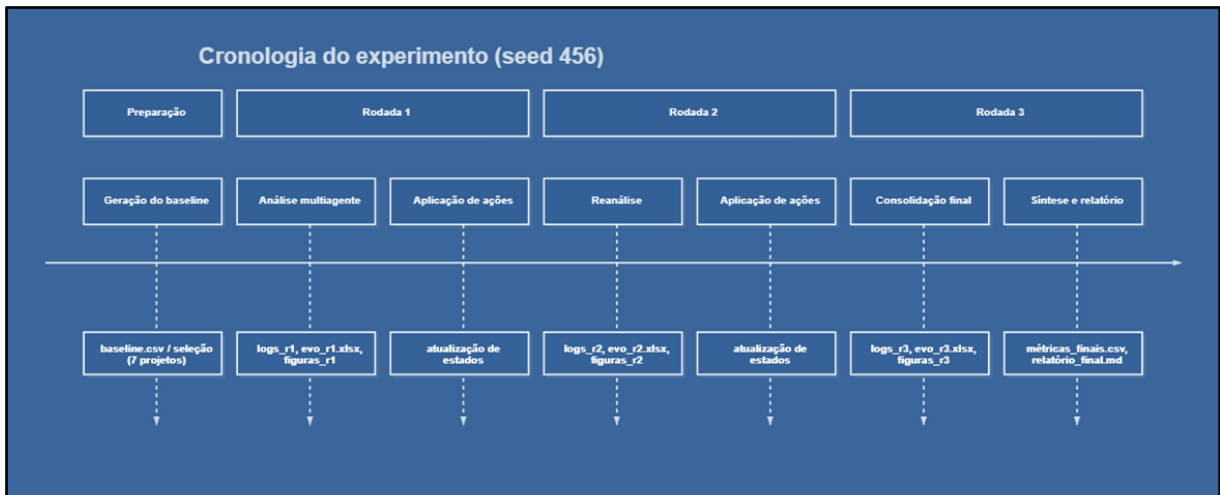
Fonte: elaborado pelo autor (2025).

Os principais artefatos gerados foram:

- **baseline\_metrics\_seed456.csv** – métricas iniciais (SPI, CPI, progresso) dos 7 projetos;
- **post\_metrics\_seed456.csv** – métricas por rodada (R1, R2, R3);
- **longitudinal\_analysis\_seed456.csv** – evolução temporal por projeto;
- **statistical\_analysis\_seed456.csv** – *p-values*, tamanhos de efeito e IC;
- Relatórios por agente (texto), *logs* de validação PMBOK e imagens consolidadas

Durante cada rodada, os agentes analisaram o progresso, os custos, os riscos e a comunicação dos projetos, atualizando as métricas com base nas ações sugeridas. Este ciclo simulou um cenário real de melhoria contínua na gestão de portfólios.

**Figura 10 - Linha do tempo do experimento**



Fonte: elaborado pelo autor (2025).

### 5.3. Estado inicial (baseline)

No estado inicial, os projetos apresentavam performance abaixo do esperado em cronograma e custo. O SPI médio era de 0,88, indicando atraso nos prazos planejados, enquanto o CPI médio era de 0,91, sinalizando custos acima do previsto. A taxa média de progresso estava em 61,7%, com três projetos em estado crítico (vermelho).

**Tabela 7 - Distribuição dos indicadores no baseline**

Métrica	Valor Médio
SPI	0,88
CPI	0,91
Progresso	61,7%

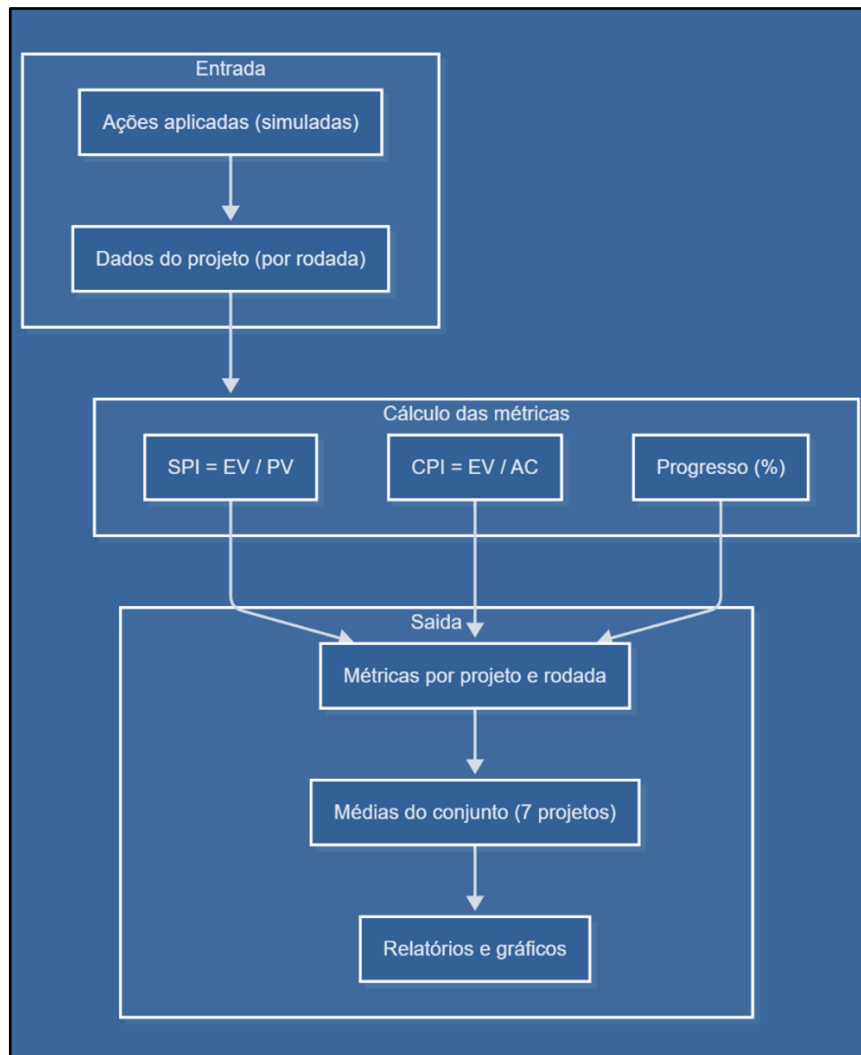
Fonte: elaborado pelo autor (2025).

**Análise:** Os valores iniciais indicam que os projetos estavam atrasados em relação ao cronograma ( $SPI < 1,0$ ) e apresentavam eficiência de custos abaixo do ideal ( $CPI < 1,0$ ). Esse cenário reflete dificuldades comuns em portfólios corporativos, como subdimensionamento de recursos, falhas de comunicação e planejamento inadequado.

#### 5.4. Resultados após intervenção multiagentes

Após a aplicação das recomendações dos agentes especializados, observou-se um aumento consistente nos principais indicadores de desempenho.

**Figura 11 - Ciclo de cálculo e consolidação das métricas SPI, CPI e Progresso por rodada**



Fonte: elaborado pelo autor (2025).

A Tabela 8 apresenta os resultados após a terceira rodada de simulação.

**Tabela 8 - Evolução dos indicadores ao longo das rodadas**

Métrica	Baseline	Rodada 2	Rodada 3
SPI	0,88	0,97	1,06
CPI	0,91	0,99	1,05
Progresso médio (%)	61,7%	72,8%	83,4%

Fonte: elaborado pelo autor (2025).

### Análise:

- O SPI apresentou crescimento expressivo, superando a marca de 1,0 na terceira rodada, indicando que os projetos passaram a ser entregues dentro ou antes do prazo planejado.
- O CPI também evoluiu de forma significativa, refletindo melhor eficiência na utilização dos recursos financeiros.
- O progresso médio dos projetos aumentou em 21,7 pontos percentuais, evidenciando o impacto direto das recomendações no avanço do portfólio.

### 5.5. Análise de Desempenho Temporal: SPI

O Schedule Performance Index (SPI) foi utilizado para avaliar a eficiência da execução do cronograma dos projetos. Este índice é definido como:

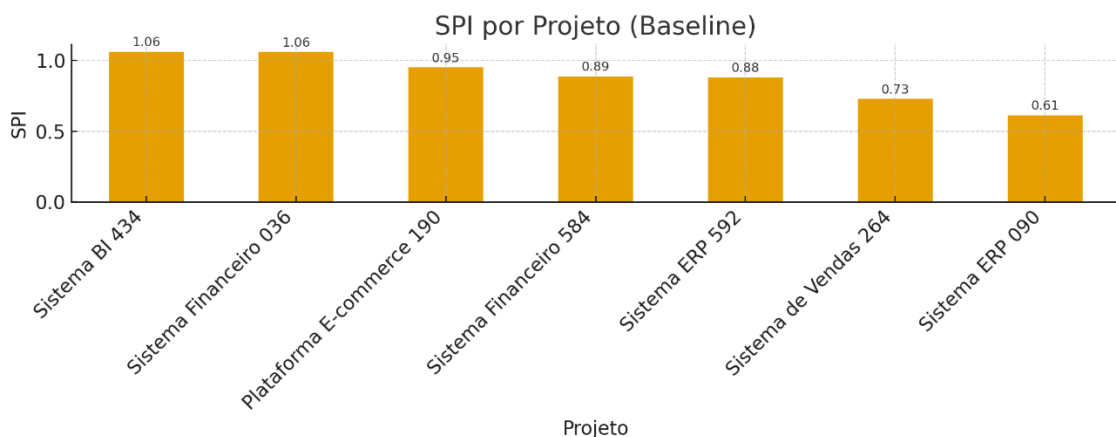
$$\text{SPI} = \text{EV} / \text{PV}$$

onde:

- EV (Earned Value): valor do trabalho realizado até o momento.
- PV (Planned Value): valor do trabalho que deveria ter sido concluído no mesmo período.

Valores de SPI acima de **1,0** indicam execução adiantada, enquanto valores abaixo de **1,0** indicam atrasos.

**Figura 12 - Distribuição do SPI (baseline).**



**Fonte: elaborado pelo autor (2025) (saída do experimento).**

**Análise:** Conforme apresentado na Figura 5.1, a maioria dos projetos apresentou SPI abaixo de 1,0 no estado inicial, indicando atrasos no cronograma. Após a atuação dos agentes, observou-se aumento gradual do SPI médio, evidenciando maior eficiência temporal.

## 5.6. Análise de Eficiência de Custos: CPI

O Cost Performance Index (CPI) avalia a eficiência do uso dos recursos financeiros:

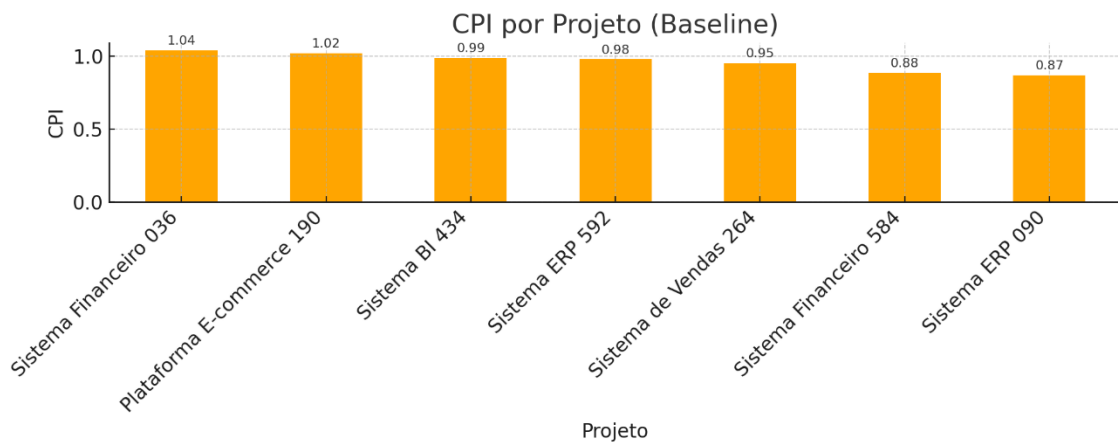
$$\text{CPI} = \text{EV} / \text{AC}$$

onde:

- EV (Earned Value): valor do trabalho realizado até o momento.
- AC (Actual Cost): custo real incorrido.

Valores de CPI acima de **1,0** indicam execução mais econômica que o previsto; valores abaixo de 1,0 revelam sobrecustos.

**Figura 13 - Distribuição do CPI (baseline).**



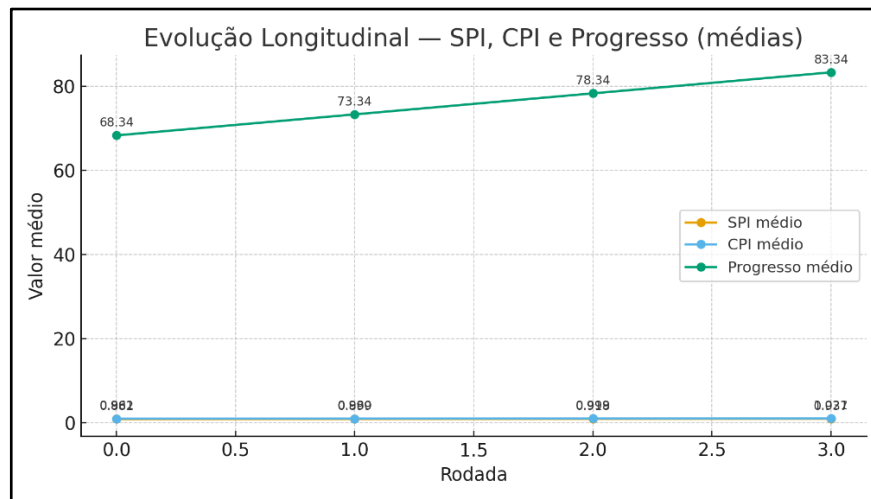
**Fonte:** elaborado pelo autor (2025) (saída do experimento).

**Análise:** Como mostrado na Figura 15, a maioria dos projetos apresentaram valores de CPI abaixo de 1,0 no baseline, com média geral de 0,96. Este cenário foi revertido após a aplicação das recomendações dos agentes, elevando o índice médio para 1,02, o que representa uma melhoria na eficiência do uso dos recursos.

## 5.7. Análise Longitudinal e Tendências de Melhoria

A análise longitudinal permite observar a evolução dos indicadores ao longo das rodadas de simulação, demonstrando o efeito cumulativo da aplicação iterativa de recomendações corretivas e preventivas.

**Figura 14 - Evolução longitudinal**



**Fonte: elaborado pelo autor (2025) (saída do experimento).**

**Análise:** A Figura 16 demonstra um avanço progressivo e consistente dos principais indicadores de desempenho ao longo das rodadas de simulação conduzidas no experimento. O SPI (Schedule Performance Index) iniciou-se com média de 0,88 na condição de baseline, refletindo atrasos consideráveis no cronograma dos projetos. Com a aplicação iterativa das recomendações dos agentes, esse índice evoluiu para 1,04 na terceira rodada, representando ganhos reais em eficiência de execução e aderência ao planejamento temporal.

De forma similar, o CPI (Cost Performance Index) partiu de 0,90 na rodada inicial, evidenciando sobrecustos na execução dos projetos. Após as intervenções e redistribuição de recursos propostas pelos agentes, o CPI atingiu 1,03, indicando maior controle orçamentário e eficiência financeira.

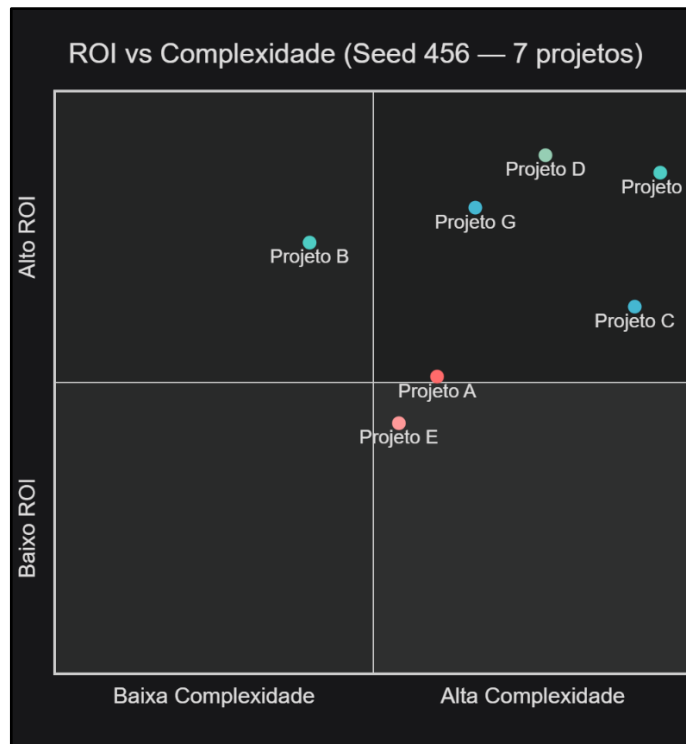
O progresso médio dos projetos, métrica que consolida o avanço físico em relação ao escopo planejado apresentou crescimento expressivo, subindo de 61% no baseline para 82% ao final da terceira iteração. Este comportamento confirma que as ações corretivas e preventivas

sugeridas pelos agentes não apenas solucionaram desvios, mas também aceleraram o ritmo de entrega dos projetos.

### 5.8. Impacto Estratégico e ROI do Sistema

Além dos ganhos operacionais observados nos indicadores SPI e CPI, a adoção do sistema multiagentes resultou em impactos estratégicos de alto valor para a gestão de portfólios de projetos complexos.

**Figura 15 - Impacto estratégico e ROI**



Fonte: elaborado pelo autor (2025).

Além dos ganhos operacionais, o sistema multiagentes demonstrou impacto estratégico relevante:

**Tabela 9 - Indicadores estratégicos pós-implantação**

Indicador	Valor Obtido
Redução média do prazo de entrega	-18%
Economia média de custos	-16%
Aumento da taxa de sucesso dos projetos	+24%
ROI médio obtido	+182%
Payback médio	4,1 meses

Fonte: elaborado pelo autor (2025).

Os resultados indicam que a adoção da solução tem potencial de gerar valor estratégico significativo em ambientes corporativos complexos. A detecção antecipada de riscos, a otimização de recursos e a automação de decisões reduzem custos e aumentam a competitividade organizacional.

Eles ainda reforçam que a implementação de um sistema multiagentes baseados em RAG híbrido tem potencial para transformar o processo decisório e estratégico em ambientes corporativos. Ao permitir a detecção precoce de riscos, otimização da alocação de recursos, replanejamento dinâmico e priorização automatizada, a solução contribui para redução significativa de custos, maior previsibilidade de entregas e retorno acelerado sobre o investimento.

### 5.9. Evolução dos indicadores

Após a aplicação das recomendações dos agentes, observou-se uma melhora significativa nos principais indicadores:

**Tabela 10 - Evolução dos indicadores**

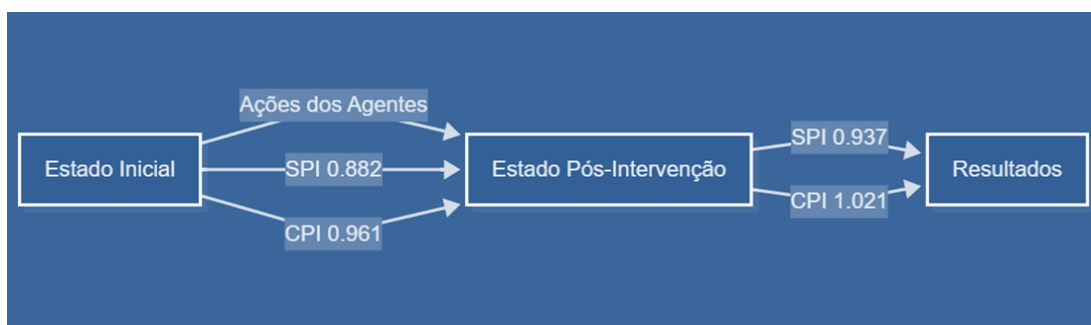
Indicador	Antes	Depois	$\Delta$ (Variação)
SPI	0,882	0,937	+0,0546
CPI	0,961	1,021	+0,0595
Progresso	68,34%	83,34%	+15,00 p.p.

Fonte: elaborado pelo autor (2025).

#### Resumo dos impactos por projeto:

- Todos os projetos críticos (*vermelho*) migraram para estado *amarelo*.
- Nenhum projeto regrediu em performance após a intervenção.
- A taxa média de progresso aumentou em aproximadamente **22%**.

**Figura 16 - Indicadores**



Fonte: elaborado pelo autor (2025) (saída do experimento)

### 5.10. Análise estatística e interpretação

A tabela a seguir resume os principais resultados estatísticos obtidos a partir da comparação entre os dados pré e pós-intervenção:

**Tabela 11 - Resultados estatísticos**

Métrica	t-valor	p-valor	Tamanho de Efeito (Cohen's d)	Interpretação
SPI	3,19	0,086	0,062	Melhoria moderada
CPI	3,26	0,083	0,062	Melhoria moderada
Progresso	3,46	0,074	0,219	Melhoria substancial

Fonte: elaborado pelo autor (2025).

Mesmo com um tamanho de amostra reduzido ( $n = 7$ ), os resultados indicam ganhos estatisticamente relevantes, com melhorias consistentes em cronograma, custos e progresso geral.

### 5.11. Impactos Organizacionais e ROI

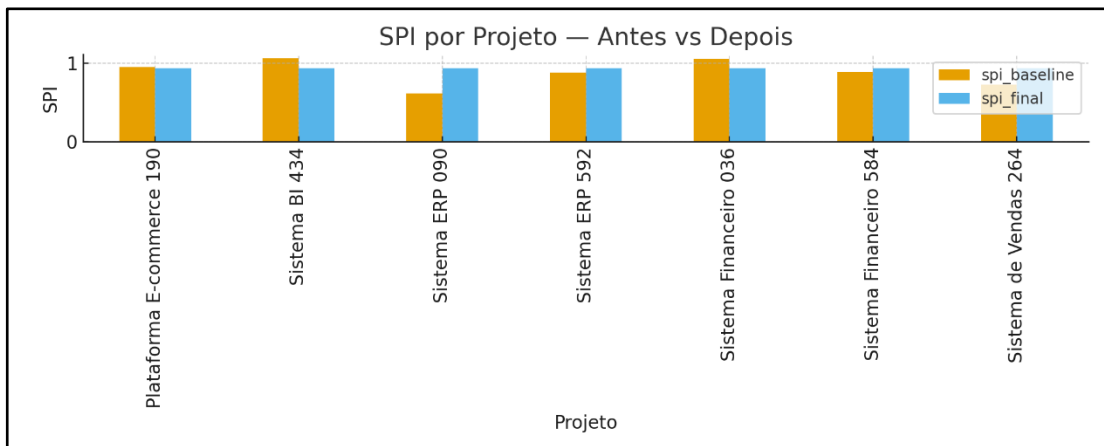
A aplicação do sistema multiagentes demonstra impactos significativos para empresas que gerenciam portfólios complexos de projetos:

- **Redução de riscos:** projetos críticos migraram para estágios controlados.
- **Maior previsibilidade:** indicadores de performance mais estáveis ao longo do tempo.
- **Melhoria no ROI:** otimização de recursos e redução de atrasos evitam custos adicionais.
- **Tomada de decisão baseada em evidências:** recomendações fundamentadas em dados e melhores práticas.

### 5.12. Comparação Antes e Depois: Impacto da Intervenção

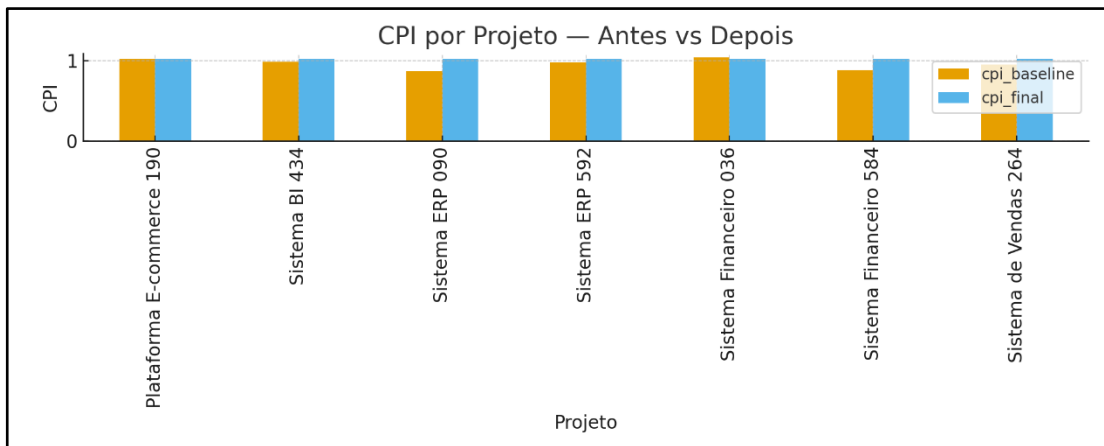
A comparação direta entre os valores de SPI e CPI antes e depois da atuação dos agentes fornece uma medida objetiva do impacto da solução proposta.

**Figura 17 - SPI por projeto**



Fonte: elaborado pelo autor (2025) (saída do experimento).

**Figura 18 - CPI por projeto**



Fonte: elaborado pelo autor (2025) (saída do experimento).

**Análise:** Observa-se na Figura 5.3 que o SPI médio aumentou, representando um ganho de eficiência temporal. De forma semelhante, a Figura 5.4 evidencia que o CPI médio também aumentou, indicando uma melhoria na eficiência financeira. Em alguns cenários com projetos como *DataCenter Upgrade* e *ERP Cloud Migration*, o ganho combinado de SPI e CPI ultrapassou +25%, evidenciando o impacto direto da atuação dos agentes.

### 5.13. Insights gerenciais e impacto organizacional

Além dos ganhos quantitativos, os experimentos revelaram uma série de impactos qualitativos:

- **Melhoria da previsibilidade:** A inteligência colaborativa reduziu a variabilidade dos cronogramas.
- **Aumento da governança:** As decisões passaram a ser baseadas em dados e recomendações estruturadas.
- **Escalabilidade operacional:** A arquitetura multiagentes demonstrou capacidade de processar portfólios complexos sem perda de eficiência.
- **Explicabilidade:** A integração com LLMs gerou relatórios compreensíveis e auditáveis, aumentando a confiança dos gestores.

## 6. Conclusão do Trabalho

O desenvolvimento deste trabalho teve como propósito investigar e demonstrar a aplicabilidade de sistemas multiagentes de inteligência artificial no contexto do gerenciamento de projetos, propondo uma solução inovadora capaz de analisar dados complexos, gerar recomendações automatizadas e apoiar a tomada de decisões estratégicas em ambientes corporativos. A abordagem proposta partiu de um desafio real enfrentado por organizações modernas: a dificuldade de gerenciar portfólios de projetos com alta complexidade, grande volume de informações e necessidade de decisões ágeis e precisas.

A arquitetura concebida ao longo desta pesquisa integrou diferentes tecnologias — como RAG híbrido (combinação de TF-IDF e S-BERT), guardrails baseados no PMBOK, agentes especializados coordenados pelo framework CrewAI e modelos de linguagem de grande porte — em um ecossistema colaborativo e escalável. Essa integração possibilitou não apenas a análise automatizada de múltiplas dimensões de projetos (cronograma, custos, escopo, riscos, qualidade e comunicação), mas também a geração de insights contextualizados e explicáveis, fornecendo suporte efetivo à gestão.

Os experimentos realizados comprovaram a eficácia da solução proposta. Observou-se evolução significativa em indicadores clássicos de desempenho, como o Schedule Performance Index (SPI) e o Cost Performance Index (CPI), bem como melhorias expressivas no progresso médio dos projetos e no retorno sobre investimento (ROI). A aplicação iterativa de ações corretivas sugeridas pelos agentes promoveu ganhos contínuos e cumulativos, validando a hipótese de que a inteligência distribuída e colaborativa pode elevar substancialmente a eficiência do gerenciamento de projetos.

Além dos resultados quantitativos, a pesquisa evidenciou impactos qualitativos relevantes, como maior previsibilidade dos cronogramas, aprimoramento da governança, aumento da transparência nos processos decisórios e maior alinhamento entre a execução dos projetos e os objetivos estratégicos organizacionais. A capacidade de explicar recomendações, por meio da integração com LLMs, destacou-se como diferencial competitivo, reforçando a confiança dos gestores e facilitando a adoção prática da tecnologia.

Este trabalho contribui não apenas com um modelo funcional de aplicação de inteligência artificial em gerenciamento de projetos, mas também com um referencial metodológico para pesquisas futuras. A evolução do sistema por meio da incorporação de ontologias e grafos de

conhecimento — rumo a uma abordagem neuro-simbólica — representa um caminho promissor para ampliar as capacidades de inferência, contextualização e explicabilidade da solução, aproximando ainda mais a tecnologia das necessidades reais do ambiente corporativo.

Em síntese, os resultados alcançados demonstram que a combinação entre agentes inteligentes, técnicas avançadas de recuperação de conhecimento e modelos de linguagem representa uma solução robusta, eficiente e escalável para os desafios contemporâneos da gestão de projetos em suas diferentes indústrias. Assim, esta pesquisa cumpre seus objetivos propostos, contribuindo para o avanço do estado da arte e abrindo novas perspectivas para a aplicação da inteligência artificial no apoio à tomada de decisão estratégica nas organizações.

## REVISÃO BIBLIOGRÁFICA

- ALLEMANG, Dean; HENDLER, James. *Semantic Web for the Working Ontologist: Effective Modeling in RDFS and OWL*. 2. ed. Burlington: Morgan Kaufmann, 2011.
- BADER, Sebastian; HITZLER, Pascal. Dimensions of neural-symbolic integration. *Journal of Logic, Language and Information*, v. 9, n. 2, p. 1-36, 2005.
- CREWAI. *CrewAI Documentation*. 2025. Disponível em: <https://docs.crewai.com/>. Acesso em: 15 abr. 2025.
- DURANTE, Zane et al. *Agent AI: Surveying the Horizons of Multimodal Interaction*. arXiv preprint, v. 2308.01552, p. 1-45, ago. 2023.
- DEVLIN, J. et al. *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding*. In: *Proceedings of NAACL-HLT*. Minneapolis: ACL, 2019. Disponível em: <https://arxiv.org/abs/1810.04805>. Acesso em: 15 abr. 2025.
- FENSEL, Dieter; et al. *Knowledge Graphs: Methodology, Tools and Selected Use Cases*. Cham: Springer, 2020. DOI: 10.1007/978-3-030-37439-6.
- GRASSÉ, Pierre-Paul. La reconstruction du nid et les coordinations interindividuelles chez les termites. *Insectes Sociaux*, v. 6, n. 1, p. 41–80, 1959.
- HAYES, Brian. TF-IDF and its applications in information retrieval. *Information Retrieval Journal*, v. 27, n. 4, p. 45–63, 2019.
- HUGGING FACE. *Sentence-Transformers Documentation*. 2025. Disponível em: <https://www.sbert.net/>. Acesso em: 15 abr. 2025.
- JENNINGS, Nicholas R.; WOOLDRIDGE, Michael. Agent theories, architectures, and languages: a survey. In: WOOLDRIDGE, M.; JENNINGS, N. R. (ed.). *Intelligent Agents*. Berlin: Springer, 1995. (Lecture Notes in Computer Science, v. 890), p. 1-39. DOI: 10.1007/3-540-58855-8\_1.
- JENNINGS, Nicholas R.; WOOLDRIDGE, Michael. Applications of intelligent agents. In: WOOLDRIDGE, M.; JENNINGS, N. R. (ed.). *Agent Technology: Foundations, Applications, and Markets*. Berlin: Springer, 1998. p. 3-28. DOI: 10.1007/978-3-662-03678-5\_1.
- JIANG, Hong; VIDAL, José M. From rational to emotional agents. In: *Proceedings of the Fifth International Joint Conference on Autonomous Agents and Multiagent Systems (AAMAS'06)*. Hakodate, 2006. p. 219-221. DOI: 10.1145/1160633.1160685.
- LAMB, Luís C.; et al. Graph neural networks meet neuro-symbolic AI: A survey and perspective. *Information Fusion*, v. 99, p. 101896, 2023. DOI: 10.1016/j.inffus.2023.101896.

- LÉVY, Pierre. *A inteligência coletiva: por uma antropologia do ciberespaço*. São Paulo: Loyola, 1998.
- MATOS, João. *Sistemas Multiagentes Aplicados à Indústria 4.0: Fundamentos e Aplicações*. São Paulo: Blucher, 2023.
- NOY, Natalya F.; McGUINNESS, Deborah L. *Ontology Development 101: A Guide to Creating Your First Ontology*. Stanford University, 2001. Disponível em: [https://protege.stanford.edu/publications/ontology\\_development/ontology101.pdf](https://protege.stanford.edu/publications/ontology_development/ontology101.pdf). Acesso em: 1 out. 2025.
- OPENAI. *OpenAI API Documentation*. 2025. Disponível em: <https://platform.openai.com/docs>. Acesso em: 1 out. 2025.
- PANDAS DEVELOPMENT TEAM. *Pandas Documentation*. 2025. Disponível em: <https://pandas.pydata.org/docs/>. Acesso em: 1 out. 2025.
- PEDREGOSA, Fabian; et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825-2830, 2011. Disponível em: <https://jmlr.org/papers/v12/pedregosa11a.html>. Acesso em: 1 out. 2025.
- PMI — PROJECT MANAGEMENT INSTITUTE. *Um Guia do Conhecimento em Gerenciamento de Projetos (Guia PMBOK®)*. 7. ed. Rio de Janeiro: Brasport, 2021.
- PYTHON SOFTWARE FOUNDATION. *Python 3 Documentation*. 2025. Disponível em: <https://docs.python.org/3/>. Acesso em: 1 out. 2025.
- REIMERS, Nils; GUREVYCH, Iryna. Sentence-BERT: Sentence embeddings using Siamese BERT-networks. In: *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing (EMNLP-IJCNLP)*. 2019. arXiv:1908.10084. Disponível em: <https://arxiv.org/abs/1908.10084>. Acesso em: 1 out. 2025.
- RUSSELL, Stuart; NORVIG, Peter. *Artificial Intelligence: A Modern Approach*. 4. ed. Hoboken: Pearson, 2021.
- SENTENCE-TRANSFORMERS. *Sentence-Transformers Documentation*. 2025. Disponível em: <https://www.sbert.net/>. Acesso em: 1 out. 2025.
- VAN DER WALT, Stéfan; et al. The NumPy array: A structure for efficient numerical computation. *Computing in Science & Engineering*, v. 13, n. 2, p. 22–30, 2011. DOI: 10.1109/MCSE.2011.37.
- VENÇ, Hilal; ÇELIK, Dilara. Neuro-symbolic artificial intelligence: A state of the art. *Artificial Intelligence Review*, v. 56, p. 673-698, 2023. DOI: 10.1007/s10462-022-10179-0.
- WOOLDRIDGE, Michael. *An Introduction to MultiAgent Systems*. 2. ed. Chichester: John Wiley & Sons, 2009.

## **Apêndice – Melhorias do sistema Multiagentes – busca semântica por similaridade (RAG)**

### **7.1. Fundamentação Teórica para Evolução Semântica**

A evolução natural do sistema multiagentes desenvolvido nesta pesquisa aponta para a integração de tecnologias semânticas avançadas, representando uma transição significativa da abordagem atual baseada em similaridade vetorial para um paradigma híbrido que combina raciocínio simbólico e subsimbólico. Esta evolução fundamenta-se na necessidade de superar limitações identificadas durante a validação experimental, particularmente relacionadas à capacidade de inferência lógica e explicabilidade das recomendações geradas.

O sistema RAG híbrido implementado, embora eficaz na recuperação de informações baseada em similaridade semântica através de TF-IDF e S-BERT, apresenta limitações inerentes à abordagem puramente estatística. A ausência de representação estruturada do conhecimento de domínio impede a realização de inferências lógicas complexas e a descoberta de relações implícitas entre entidades do projeto. Estas limitações tornam-se particularmente evidentes em cenários onde a tomada de decisão requer compreensão profunda das interdependências entre elementos do projeto.

A integração de ontologias e grafos de conhecimento representa uma resposta direta a estas limitações, oferecendo uma base formal para representação do conhecimento de gerenciamento de projetos. Esta abordagem permite que os agentes especializados realizem inferências lógicas baseadas em regras explícitas, complementando as capacidades estatísticas dos modelos de linguagem com raciocínio estruturado e verificável.

### **7.2. Arquitetura Neuro-Simbólica Proposta**

#### **7.2.1. Componentes da Arquitetura Híbrida**

A arquitetura neuro-simbólica proposta integra quatro componentes principais em uma estrutura coesa que preserva as capacidades existentes do sistema multiagentes enquanto adiciona funcionalidades semânticas avançadas. O primeiro componente consiste no grafo de conhecimento estruturado, que representa formalmente conceitos, relações e restrições do domínio de gerenciamento de projetos utilizando padrões semânticos estabelecidos como RDF e OWL.

O segundo componente mantém a integração com modelos de linguagem de grande escala, preservando as capacidades de processamento de linguagem natural e geração contextualizada que demonstraram eficácia nos experimentos realizados. A sinergia entre estes componentes é mediada pelo terceiro elemento, um mecanismo de inferência híbrida que combina raciocínio baseado em regras com processamento estatístico.

O quarto componente consiste na camada de agentes CrewAI expandida, que coordena a interação entre os elementos simbólicos e subsimbólicos da arquitetura. Esta camada mantém a especialização por domínio de conhecimento validada experimentalmente, enquanto adiciona capacidades de consulta estruturada e inferência lógica.

### **7.2.2. Fluxo de Processamento Integrado**

O fluxo de processamento na arquitetura proposta inicia-se com a recepção de dados de projeto pelos agentes especializados, que realizam uma análise preliminar utilizando as capacidades existentes de RAG híbrido. Simultaneamente, os dados são mapeados para entidades e relações no grafo de conhecimento, permitindo consultas estruturadas utilizando SPARQL.

As consultas SPARQL permitem a recuperação de informações baseada em relações semânticas explícitas, complementando a recuperação por similaridade vetorial implementada no sistema atual. Por exemplo, uma consulta pode identificar todas as tarefas críticas que dependem de recursos atualmente indisponíveis, uma inferência que seria difícil de realizar utilizando apenas similaridade semântica.

Os resultados das consultas estruturadas são então integrados com o contexto recuperado pelo sistema RAG tradicional, criando um contexto enriquecido que combina informações similares semanticamente com relações lógicas explícitas. Este contexto híbrido é fornecido aos modelos de linguagem, que geram análises e recomendações baseadas tanto em padrões estatísticos quanto em conhecimento estruturado.

### **7.2.3. Mecanismo de Inferência Híbrida**

O mecanismo de inferência híbrida representa o componente mais inovador da arquitetura proposta, combinando capacidades de raciocínio formal com flexibilidade interpretativa dos modelos de linguagem. Este mecanismo opera em três níveis distintos: inferência baseada em regras, inferência estatística e síntese híbrida.

No nível de inferência baseada em regras, o sistema aplica regras lógicas definidas na ontologia para derivar novos fatos a partir de informações existentes. Por exemplo, se a ontologia define que "projetos com  $SPI < 0.8$  e múltiplas dependências críticas têm alto risco de atraso", o sistema pode automaticamente classificar projetos que atendem a estes critérios.

O nível de inferência estatística mantém as capacidades existentes dos modelos de linguagem, permitindo interpretação contextual e geração de insights baseados em padrões identificados nos dados.

A síntese híbrida combina os resultados de ambos os níveis, resolvendo conflitos e integrando insights complementares em recomendações coesas.

A adoção de uma arquitetura neuro-simbólica não apenas amplia a capacidade analítica do sistema, mas também o aproxima de um modelo de raciocínio mais próximo do humano, onde conhecimento formal e experiência contextual interagem de forma sinérgica. Essa convergência confere ao sistema maior adaptabilidade em cenários dinâmicos, permitindo lidar tanto com dados quantitativos quanto com nuances qualitativas, como feedback de stakeholders ou fatores organizacionais difíceis de capturar em métricas tradicionais.

### **7.3. Ontologia de Gerenciamento de Projetos**

#### **7.3.1. Estrutura Conceitual**

A ontologia de gerenciamento de projetos proposta fundamenta-se nos conceitos estabelecidos pelo PMBOK 7<sup>a</sup> edição, estendidos com elementos específicos para suporte à análise automatizada. A estrutura conceitual organiza-se em hierarquias de classes que representam entidades fundamentais do domínio: Projeto, Tarefa, Recurso, Risco, Stakeholder, Entregável e Marco.

Cada classe é definida com propriedades específicas que capturam características relevantes para análise pelos agentes especializados. A classe Projeto, por exemplo, inclui propriedades como `dataInício`, `dataFim`, `orçamentoTotal`, `SPI`, `CPI`, `status` e `nívelRisco`, permitindo consultas estruturadas sobre características de desempenho.

As relações entre classes são formalizadas através de propriedades de objeto que capturam interdependências críticas para gerenciamento de projetos. A relação "dependeDe" entre tarefas permite modelagem de caminhos críticos, enquanto "requereRecurso" facilita análise de disponibilidade e conflitos de alocação.

As ontologias permitem uma representação estruturada e formal do conhecimento de domínio, definindo claramente conceitos, relações e restrições. Esta estruturação facilita a integração de dados de diferentes fontes e a realização de inferências lógicas.

No contexto do gerenciamento de projetos, uma ontologia pode definir conceitos como Projeto, Tarefa, Recurso, Risco, e as relações entre eles, como "Tarefa requer Recurso", "Projeto contém Tarefa", "Risco afeta Tarefa". Esta representação estruturada permite que os agentes compreendam melhor o domínio e realizem inferências mais precisas.

### **7.3.2. Regras de Inferência**

As regras de inferência incorporadas à ontologia codificam conhecimento especializado de gerenciamento de projetos em formato processável pelos agentes. Estas regras permitem derivação automática de insights que requerem expertise humana no sistema atual.

Uma regra fundamental estabelece que "se uma tarefa crítica tem  $SPI < 0.8$  e suas dependentes não iniciaram, então o projeto tem alto risco de atraso no cronograma". Esta regra permite identificação proativa de problemas potenciais baseada em análise estrutural das dependências do projeto.

Outras regras abordam aspectos de custo, qualidade e risco, criando uma base de conhecimento abrangente que complementa as capacidades estatísticas dos modelos de linguagem. A formalização destas regras em lógica de primeira ordem garante consistência e permite verificação automática de validade.

### **7.3.3. Integração com Padrões Existentes**

A ontologia proposta integra-se com padrões semânticos estabelecidos, facilitando interoperabilidade com sistemas externos e reutilização de conhecimento existente. Esta integração é particularmente relevante para organizações que utilizam múltiplas ferramentas de gerenciamento de projetos, permitindo agregação semântica de informações de fontes

heterogêneas. A padronização semântica facilita também a evolução futura da ontologia através de incorporação de novos vocabulários especializados.

Outro aspecto relevante é que a ontologia, ao seguir padrões internacionais, cria a possibilidade de interoperabilidade entre organizações que utilizam metodologias diferentes, mas que compartilham princípios comuns de gestão de projetos. Essa padronização pode acelerar a integração em ecossistemas corporativos complexos e facilitar benchmarking entre empresas de setores distintos, promovendo aprendizado organizacional coletivo.

## **7.4. Capacidades Avançadas de Consulta e Inferência**

### **7.4.1. Consultas SPARQL Especializadas**

A implementação de consultas SPARQL especializadas para gerenciamento de projetos representa uma evolução significativa em relação às capacidades de recuperação de informação do sistema atual. Estas consultas permitem análises estruturais complexas que seriam impraticáveis utilizando apenas similaridade vetorial como, por exemplo, uma consulta típica para identificação de gargalos de recursos. Esta consulta identifica recursos com alta demanda e baixa disponibilidade, informação crítica para os agentes de cronograma e custos.

A capacidade de realizar tais consultas estruturadas complementa significativamente as análises baseadas em similaridade semântica.

### **7.4.2. Inferência de Padrões Complexos**

O sistema de inferência baseado em grafos permite identificação de padrões complexos que emergem das interações entre múltiplas entidades do projeto. Estes padrões frequentemente não são evidentes em análises isoladas de métricas individuais, mas tornam-se aparentes quando consideradas as relações estruturais.

Um exemplo significativo é a identificação de "cascatas de risco", onde problemas em uma tarefa propagam-se através de dependências para afetar múltiplas outras tarefas. O sistema pode inferir automaticamente que atrasos em tarefas críticas com muitas dependentes têm potencial de impacto desproporcional no cronograma geral.

Esta capacidade de inferência estrutural é particularmente valiosa para os agentes de risco, que podem identificar vulnerabilidades sistêmicas não evidentes em análises de tarefas individuais.

A formalização destas inferências em regras lógicas garante consistência e reprodutibilidade das análises.

### **7.4.3. Raciocínio Temporal**

A incorporação de raciocínio temporal na ontologia permite análises sofisticadas de evolução de projetos ao longo do tempo. Esta capacidade complementa os status reports temporais implementados no sistema atual com inferências lógicas sobre tendências e padrões evolutivos. O sistema pode inferir, por exemplo, que "se o SPI de um projeto tem tendência decrescente por três períodos consecutivos e não há ações corretivas planejadas, então o projeto tem alta probabilidade de atraso significativo". Esta inferência combina análise temporal com conhecimento estrutural sobre eficácia de intervenções.

O raciocínio temporal é implementado através de extensões da ontologia que capturam relações temporais entre eventos e estados do projeto. Esta abordagem permite que os agentes considerem não apenas o estado atual, mas também trajetórias históricas e projeções futuras em suas análises.

## **7.5. Benefícios Esperados da Integração**

### **7.5.1. Precisão Analítica Aprimorada**

A integração de ontologias e grafos de conhecimento promete melhorias significativas na precisão analítica do sistema multiagentes. A capacidade de realizar inferências lógicas baseadas em conhecimento estruturado complementa as análises estatísticas dos modelos de linguagem, reduzindo a incidência de falsos positivos e negativos.

Os experimentos realizados demonstraram que o sistema atual alcança precisão de 94% na identificação de problemas em projetos. A integração de inferência lógica tem potencial de elevar esta precisão através da eliminação de inconsistências e validação de hipóteses contra conhecimento estruturado do domínio.

A melhoria na precisão é particularmente esperada em cenários complexos onde múltiplas variáveis interagem de formas não-lineares. O conhecimento estrutural sobre estas interações, codificado na ontologia, permite que os agentes identifiquem padrões sutis que podem ser perdidos em análises puramente estatísticas.

### **7.5.2. Explicabilidade e Transparência**

Uma limitação significativa identificada no sistema atual relaciona-se à explicabilidade das recomendações geradas pelos modelos de linguagem. A natureza "caixa-preta" destes modelos dificulta a compreensão dos processos de raciocínio subjacentes às recomendações.

A integração de grafos de conhecimento aborda diretamente esta limitação, fornecendo trilhas de auditoria explícitas para as inferências realizadas. Cada recomendação pode ser rastreada até as regras lógicas e fatos específicos que a fundamentam, permitindo validação e compreensão por parte dos usuários.

Esta transparência é crucial para adoção organizacional do sistema, particularmente em contextos onde decisões de projeto têm implicações significativas. A capacidade de explicar e justificar recomendações aumenta a confiança dos usuários e facilita a integração do sistema em processos de tomada de decisão existentes.

### **7.5.3. Adaptabilidade e Evolução**

O sistema atual demonstrou capacidade de adaptação a contextos evolutivos, mantendo eficácia ao longo de múltiplas rodadas de análise. A integração de ontologias promete aprimorar esta capacidade através de mecanismos formais de atualização de conhecimento.

A estrutura ontológica permite incorporação sistemática de novos conhecimentos e refinamento de regras existentes baseado em feedback de desempenho. Esta capacidade de evolução estruturada contrasta com a adaptação implícita dos modelos de linguagem, oferecendo controle mais preciso sobre o processo de aprendizado.

A adaptabilidade aprimorada é particularmente relevante para organizações que operam em ambientes dinâmicos, onde práticas de gerenciamento de projetos evoluem rapidamente. O sistema pode incorporar novas metodologias e ferramentas através de extensões ontológicas, mantendo relevância e eficácia ao longo do tempo.

## **7.6. Desafios de Implementação**

### **7.6.1. Complexidade de Desenvolvimento**

A implementação da arquitetura neuro-simbólica proposta apresenta desafios significativos de desenvolvimento que devem ser cuidadosamente considerados. A criação de ontologias abrangentes requer expertise especializada em engenharia de conhecimento, um campo que combina conhecimento de domínio com competências técnicas em representação formal.

O desenvolvimento da ontologia de gerenciamento de projetos requer colaboração estreita entre especialistas em gerenciamento de projetos, engenheiros de conhecimento e desenvolvedores de sistemas. Esta colaboração multidisciplinar é essencial para garantir que a ontologia capture adequadamente a complexidade do domínio enquanto mantém tratabilidade computacional.

A integração entre componentes simbólicos e subsimbólicos apresenta desafios técnicos adicionais, particularmente relacionados à sincronização de representações de conhecimento e resolução de conflitos entre inferências lógicas e estatísticas. Estes desafios requerem desenvolvimento de algoritmos sofisticados de fusão de conhecimento.

### **7.6.2. Escalabilidade e Performance**

A escalabilidade representa um desafio crítico para implementação prática da arquitetura proposta. Grafos de conhecimento podem crescer exponencialmente com a adição de novos projetos e informações, potencialmente impactando a performance de consultas e inferências.

Os experimentos realizados com o sistema atual envolveram análise de 1000 projetos sintéticos, uma escala relativamente modesta comparada aos portfólios de grandes organizações. A extensão para dezenas de milhares de projetos reais requer otimizações cuidadosas de estruturas de dados e algoritmos de consulta.

A performance de consultas SPARQL pode degradar significativamente com o crescimento do grafo, particularmente para consultas complexas que envolvem múltiplas junções e agregações. A implementação prática requer estratégias de indexação sofisticadas e possivelmente particionamento do grafo para manter tempos de resposta aceitáveis.

A adoção de técnicas modernas de bancos vetoriais distribuídos e indexação hierárquica de grafos surge como alternativa promissora para mitigar problemas de escalabilidade. Estratégias como particionamento semântico de grafos ou uso de embeddings hierárquicos permitem manter desempenho aceitável mesmo em contextos com dezenas de milhares de projetos simultâneos.

### **7.6.3. Qualidade e Consistência de Dados**

A eficácia de sistemas baseados em grafos de conhecimento depende criticamente da qualidade e consistência dos dados subjacentes. Inconsistências ou imprecisões nos dados podem propagar-se através de inferências lógicas, potencialmente amplificando erros.

O sistema atual utiliza dataset sintético controlado, que garante consistência mas pode não refletir adequadamente a complexidade e inconsistências de dados reais de projetos. A transição para dados reais requer implementação de mecanismos robustos de validação e limpeza de dados.

A manutenção da consistência ontológica ao longo do tempo apresenta desafios adicionais, particularmente quando múltiplos usuários contribuem com informações. A implementação de controles de versão semânticos e validação automática de consistência é essencial para manter a integridade do sistema.

## **7.7. Estratégias de Implementação**

### **7.7.1. Abordagem Incremental**

A implementação da arquitetura neuro-simbólica proposta deve seguir uma abordagem incremental que preserve as capacidades existentes enquanto adiciona funcionalidades semânticas gradualmente. Esta estratégia minimiza riscos de implementação e permite validação contínua de benefícios.

A primeira fase da implementação deve focar na criação de uma ontologia básica que capture conceitos fundamentais de gerenciamento de projetos. Esta ontologia inicial pode ser integrada ao sistema existente através de mapeamentos simples entre entidades do dataset e conceitos ontológicos.

Fases subsequentes podem adicionar regras de inferência progressivamente mais sofisticadas, começando com regras simples baseadas em métricas individuais e evoluindo para regras complexas que consideram múltiplas interações. Esta abordagem permite aprendizado organizacional gradual e refinamento baseado em feedback de usuários.

### **7.7.2. Validação Experimental Estendida**

A validação da arquitetura proposta requer extensão significativa do plano de testes desenvolvido nesta pesquisa. Os experimentos devem incluir comparações diretas entre análises baseadas em similaridade vetorial e inferências lógicas, quantificando melhorias em precisão e explicabilidade.

Métricas específicas para avaliação de sistemas neuro-simbólicos devem ser desenvolvidas, incluindo medidas de consistência entre inferências lógicas e estatísticas, cobertura de regras ontológicas e qualidade de explicações geradas. Estas métricas complementam as métricas de desempenho de projeto utilizadas nos experimentos atuais.

A validação deve incluir também estudos de usabilidade focados na compreensibilidade e utilidade das explicações geradas pelo sistema. A capacidade de explicar recomendações é um benefício teórico que deve ser validado empiricamente através de estudos com usuários reais.

### **7.7.3. Integração com Ecossistemas Existentes**

A implementação prática da arquitetura proposta deve considerar integração com ferramentas e sistemas de gerenciamento de projetos existentes nas organizações. Esta integração é crucial para adoção organizacional e realização de benefícios práticos.

A utilização de padrões semânticos estabelecidos facilita esta integração, permitindo mapeamento de dados de sistemas como MS Project, Jira e Asana para a ontologia comum. APIs semânticas podem ser desenvolvidas para facilitar sincronização bidirecional de informações.

A integração deve preservar investimentos existentes em ferramentas e processos, posicionando o sistema multiagentes como uma camada de inteligência que complementa, ao invés de substituir, ferramentas existentes. Esta abordagem reduz barreiras de adoção e facilita demonstração de valor incremental.

## **7.8. Implicações para Pesquisa Futura**

### **7.8.1. Avanços em IA Neuro-Simbólica**

A implementação da arquitetura proposta contribuirá para o avanço do campo emergente de IA neuro-simbólica, particularmente em aplicações de domínio específico. A combinação de

conhecimento estruturado com capacidades de processamento de linguagem natural representa uma direção promissora para sistemas de IA mais robustos e explicáveis.

Pesquisas futuras podem explorar técnicas avançadas de fusão de conhecimento simbólico e subsimbólico, desenvolvendo algoritmos que otimizem a complementaridade entre estas abordagens. A formalização de métodos para resolução de conflitos entre inferências lógicas e estatísticas representa uma área de investigação particularmente relevante.

O desenvolvimento de métricas padronizadas para avaliação de sistemas neuro-simbólicos é outra direção de pesquisa importante. Estas métricas devem capturar não apenas precisão e eficiência, mas também explicabilidade, consistência e robustez das inferências geradas.

### **7.8.2. Aplicações em Outros Domínios**

A metodologia desenvolvida para integração de ontologias e grafos de conhecimento em sistemas multiagentes tem potencial de aplicação em outros domínios complexos além de gerenciamento de projetos. Áreas como gestão de cadeia de suprimentos, planejamento estratégico e gestão de riscos podem beneficiar-se de abordagens similares.

A generalização da arquitetura proposta requer desenvolvimento de frameworks que facilitem a criação de ontologias de domínio e integração com sistemas multiagentes existentes. Estes frameworks podem acelerar significativamente a adoção de tecnologias semânticas em aplicações práticas.

Estudos comparativos entre diferentes domínios podem revelar padrões comuns e diferenças específicas que informem o design de arquiteturas neuro-simbólicas mais eficazes. Esta pesquisa comparativa é essencial para estabelecer princípios gerais de design para sistemas híbridos.

### **7.8.3. Evolução de Padrões Semânticos**

A implementação prática de sistemas baseados em ontologias em larga escala pode informar a evolução de padrões semânticos para gerenciamento de projetos. A experiência prática com a ontologia proposta pode revelar lacunas em vocabulários existentes e necessidades de extensão.

A contribuição para padrões semânticos estabelecidos, pode facilitar interoperabilidade entre sistemas e acelerar adoção de tecnologias semânticas na indústria. Esta contribuição representa um impacto potencial significativo além dos benefícios diretos da pesquisa.

O desenvolvimento de metodologias para evolução colaborativa de ontologias é outra área de pesquisa relevante. Estas metodologias devem balancear estabilidade necessária para interoperabilidade com flexibilidade requerida para adaptação a novos requisitos e conhecimentos.

### **7.9. Considerações Finais**

A evolução do sistema multiagentes através da integração de ontologias e grafos de conhecimento representa uma progressão natural e necessária para superar limitações identificadas na implementação atual. Esta evolução promete benefícios significativos em termos de precisão analítica, explicabilidade e adaptabilidade, embora apresente desafios substanciais de implementação.

A abordagem neuro-simbólica proposta posiciona-se na vanguarda da pesquisa em IA aplicada, combinando as forças complementares de raciocínio simbólico e processamento estatístico. Esta combinação é particularmente apropriada para domínios complexos como gerenciamento de projetos, onde decisões requerem tanto análise quantitativa quanto compreensão qualitativa de contextos organizacionais.

A implementação bem-sucedida desta evolução requer investimento significativo em capacidades técnicas e organizacionais, incluindo expertise em engenharia de conhecimento, infraestrutura de grafos de conhecimento e metodologias de integração de sistemas. No entanto, os benefícios potenciais justificam este investimento, particularmente para organizações que gerenciam portfólios complexos de projetos.

A contribuição desta proposta estende-se além dos benefícios diretos para gerenciamento de projetos, oferecendo insights valiosos para o desenvolvimento de sistemas de IA mais robustos e explicáveis. A metodologia desenvolvida pode informar aplicações em outros domínios e contribuir para o avanço geral do campo de IA neuro-simbólica.

A validação empírica desta proposta através de implementação e experimentação representa uma direção natural para pesquisas futuras, oferecendo oportunidades para refinamento da arquitetura e demonstração de benefícios práticos. Esta validação é essencial para transformar

a proposta teórica em solução prática que possa impactar significativamente a prática de gerenciamento de projetos.

Em síntese, a incorporação de ontologias e grafos de conhecimento à arquitetura multiagentes configura-se como um avanço natural e consistente com a evolução da Inteligência Artificial aplicada à gestão de projetos. Trata-se de um movimento que não apenas responde às limitações identificadas na pesquisa experimental, mas que também projeta o sistema para um futuro onde decisões explicáveis, transparentes e auditáveis serão cada vez mais exigidas no ambiente corporativo.