

AUTOMAÇÃO DA INTELIGÊNCIA COMPETITIVA: UMA ABORDAGEM BASEADA EM GRAFOS DE CONHECIMENTO E INTELIGÊNCIA ARTIFICIAL GENERATIVA

Fábio Cossenzo

Doutorando em Gestão e Organização do Conhecimento pela
Universidade Federal de Minas Gerais, Brasil.

E-mail: cossenzo@ufmg.br

Frederico Cesar Mafra Pereira

Doutor em Ciência da Informação pela Universidade Federal de Minas
Gerais, Brasil. Professor da Universidade Federal de Minas Gerais, Brasil.

E-mail: professorfredericomafra@gmail.com

Marcello Peixoto Bax

Doutor em Informática, Análise de Sistemas e Tratamento de Sinal pela
Université Montpellier 2, França. Professor da Universidade Federal de
Minas Gerais, Brasil.

E-mail: bax@ufmg.br

Resumo

O objetivo deste artigo é propor uma abordagem de automação do processo de inteligência competitiva baseada em grafos de conhecimento e inteligência artificial generativa, integrando a inteligência competitiva e a gestão do conhecimento. Este trabalho fornece um modelo, uma ontologia e um método de inteligência competitiva denominado GenCI, que é escalável, extensível, customizável e que pode ser completamente automatizado para assegurar maior tempestividade e menor tempo na coleta, integração e análise das informações de inteligência. A metodologia da pesquisa é definida pela proposição do modelo e do método GenCI, a construção de uma ontologia genérica do domínio da inteligência competitiva de forma integrada à gestão do conhecimento, e a criação e a consulta de um grafo de conhecimento. Realiza um experimento objetivo e reproduzível para testar a validade do GenCI a partir do uso do Google Gemini e da busca de artigos científicos pelo Google Acadêmico. Verifica tanto a validade do GenCI para responder às questões-chave de inteligência como a sua capacidade de identificar oportunidades de vantagens competitivas no ambiente de negócios. Conclui que a adoção do modelo e do método GenCI é um caminho possível e válido para a sobrevivência e a competitividade das organizações no contexto da Indústria 4.0 e da transformação digital.

Palavras-chave: inteligência competitiva; gestão do conhecimento; grafos de conhecimento; inteligência artificial generativa; transformação digital.

COMPETITIVE INTELLIGENCE AUTOMATION: AN APPROACH BASED ON KNOWLEDGE GRAPHS AND GENERATIVE ARTIFICIAL INTELLIGENCE

Abstract

This paper proposes an approach to automating the competitive intelligence process based on knowledge graphs and generative artificial intelligence, integrating competitive intelligence and knowledge management. This work provides a model, an ontology, and a competitive intelligence process called GenCI, which is scalable, extensible, customizable, and can be completely automated to ensure greater timeliness and shorter time in the collection, integration, and analysis of intelligence

information. The research methodology was defined by the proposition of the GenCI model and method, the construction of a generic ontology for the domain of competitive intelligence in an integrated way with knowledge management, and the creation and query of a knowledge graph. An objective and reproducible experiment was conducted to test the validity of GenCI using Google Gemini and the collection of scientific articles searched in Google Scholar. Both the validity of GenCI to answer key intelligence questions and its ability to identify opportunities for competitive advantages in the business environment were verified. It is concluded that adopting the GenCI model and method is a possible and valid path for the survival and competitiveness of organizations in the context of Industry 4.0 and digital transformation.

Keywords: competitive intelligence; knowledge management; knowledge graphs; generative artificial intelligence; digital transformation.

1 INTRODUÇÃO

No contexto da Indústria 4.0 e da transformação digital, as atividades digitais geram dados na ordem de bilhões de *terabytes* (Duan; Xu, 2021). Nas organizações, gerentes e colaboradores necessitam buscar e usar informações para a construção de significado, a aquisição de conhecimento e a devida tomada de decisão (Ottonicar; Valentim; Mosconi, 2018).

A inteligência competitiva é o processo de monitoramento ambiental do mercado e a transformação de informações distribuídas e desordenadas em conhecimento apropriado para a tomada de decisões estratégicas (Miller, 2000; Yap; Rashid, 2011). Nesse processo, o conhecimento precisa ser gerenciado para suportar a criação de significado, a inovação e comportamentos racionais orientados para os objetivos organizacionais (Choo, 2011).

No cerne da gestão do conhecimento está a adoção de processos e ferramentas gerenciais e tecnológicas para aprimorar a geração, a identificação, a validação, a disseminação, o compartilhamento e o uso dos conhecimentos estratégicos (Terra, 2005).

Contudo, há uma lacuna de abordagens de inteligência competitiva que estejam integradas à gestão do conhecimento e que sejam guiadas por processos de inteligência artificial, visando atender à demanda por maior tempestividade e menor tempo na análise das informações (Madureira; Popović; Castelli, 2023; Cekuls, 2023).

Portanto, o objetivo deste artigo é propor uma abordagem de automação do processo de inteligência competitiva baseada em grafos de conhecimento e inteligência artificial generativa, integrando a inteligência competitiva e a gestão do conhecimento. Nessa automação, as etapas do ciclo de inteligência competitiva são suportadas por processos de inteligência artificial generativa, ao passo que extraem informações relevantes, povoam grafos de conhecimento, possibilitam a inferência lógica e probabilística de novos relacionamentos entre os conceitos e criam novas formas de consulta e acesso a informações estratégicas para a tomada de decisão.

Inteligência artificial (IA) generativa se refere a um ramo da IA dedicado a modelos e algoritmos capazes de gerar conteúdo novo e original, tais como texto, imagens, músicas e vídeos. Nesse ramo, os grandes modelos de linguagem (*large language models* – LLM) fornecem a base de conhecimento e a capacidade de processamento de linguagem de uma aplicação de IA generativa (Kulkarni *et al.*, 2023; Feuerriegel *et al.*, 2024).

Por sua vez, os grafos de conhecimento são estruturas de dados que acumulam e comunicam conhecimento do mundo real (Peng *et al.*, 2023). Um grafo de conhecimento descreve os conceitos do mundo e seus relacionamentos sob a forma de um grafo, composto por nós e arestas (Tian *et al.*, 2022).

A abordagem proposta nesta pesquisa se justifica pelas vantagens de se unir grafos de conhecimento e LLM, haja vista que suas vantagens e desvantagens são complementares. Por

exemplo, os grafos de conhecimento possuem as vantagens de manipular o conhecimento estruturado simbolicamente, com precisão e assertividade, enquanto nesses aspectos os LLM possuem as desvantagens de manipular o conhecimento de forma implícita e sujeita a alucinação e indecisão. Por outro lado, os LLM possuem as vantagens de processar volumes informações compatíveis com a Indústria 4.0 (Duan; Xu, 2021), abrangendo um vasto conhecimento e com poder de generalização, mas os grafos de conhecimento lidam com conhecimento de domínio, possuem lacunas de interpretação da linguagem e assumem que fatos que fogem à sua representação são fatos desconhecidos (Pan *et al.*, 2024).

Este artigo está organizado nas seguintes seções: no referencial teórico, são apresentados conceitos e abordagens identificados na literatura em inteligência competitiva, gestão do conhecimento, grafos de conhecimento e inteligência artificial generativa. Em seguida, a metodologia da pesquisa é delineada, incluindo o modelo, o método e a ontologia propostos, bem como os procedimentos do experimento realizado. Em seguida, os resultados do experimento são apresentados e discutidos. Nas considerações finais, são destacados o atendimento ao objetivo deste artigo e as contribuições desta pesquisa, suas implicações teóricas e práticas, suas limitações, e as sugestões de pesquisas futuras.

2 REFERENCIAL TEÓRICO

2.1 Inteligência competitiva

A inteligência competitiva é o processo organizacional de busca por informações distribuídas e desordenadas, monitoramento ambiental do mercado e gestão dessas informações que visa criar e disseminar conhecimento estratégico acionável para a tomada de decisão, colocando a organização em vantagem em relação aos seus concorrentes (Prescott, 1999; Miller, 2000; Fernandez; Lana, 2008; Zangouinezhad; Moshabaki, 2009; Yap; Rashid, 2011).

Segundo Porter (2004), o desenvolvimento de uma estratégia competitiva consiste no estabelecimento de como a empresa competirá, quais são as suas metas e por meio de quais políticas operacionais buscará atingir essas metas. As metas podem ser vistas como os fins da empresa, enquanto as políticas operacionais representam os meios para alcançar os fins. Na formulação da estratégia competitiva, devem ser levados em conta os limites internos, abrangendo os pontos fortes e fracos da empresa, bem como os limites externos, abrangendo as oportunidades e as ameaças da indústria e do seu ambiente.

O ciclo de inteligência competitiva pode ser descrito por quatro etapas. A primeira etapa é a identificação dos tomadores de decisão e de suas necessidades informacionais, as quais darão suporte às principais decisões estratégicas previstas, visando a vantagem competitiva no ambiente de negócios da organização (Miller, 2000).

Na etapa de identificação das necessidades, são especificados os tópicos-chave de inteligência (*key intelligence topics* – KIT) e as respectivas questões-chave de inteligência (*key intelligence questions* – KIQ). Os KIT e as KIQ contribuem para a sistematização, priorização e eficácia dos esforços da atividade de inteligência. Enquanto os KIT tratam dos temas ou objetivos centrais, as KIQ detalham quais são as perguntas que devem ser respondidas relativas a problemas em cada KIT, de modo a suprir a necessidade informacional dos decisores (Herring, 1999).

Os KIT podem ser categorizados em tópicos de inteligência para (i) suporte às ações e decisões estratégicas; (ii) identificação e descrição de atores-chave do ambiente de negócios; e (iii) monitoramento ambiental do mercado. A primeira categoria tem como propósito buscar, organizar e entregar informações relevantes ao processo decisório da organização. Por sua vez, a segunda categoria almeja mapear os perfis dos atores-chave, tais como concorrentes,

clientes e fornecedores. Finalmente, a terceira e última categoria é responsável por informar antecipadamente sobre os riscos, ou seja, a possibilidade de ocorrência de eventos que possam impactar positiva ou negativamente os negócios e as partes interessadas (Herring, 1999).

A segunda etapa do ciclo de inteligência competitiva é a de coleta das informações necessárias ao atendimento das necessidades informacionais (Miller, 2000), de acordo com os KIT e as KIQ especificadas (Herring, 1999).

Em seguida, a terceira etapa do ciclo de inteligência competitiva é a análise dos dados e das informações coletadas para transformá-las em inteligência. Finalmente, a última etapa é a disseminação dos produtos de inteligência ou produtos informacionais aos usuários ou tomadores de decisões (Miller, 2000).

A área de inteligência competitiva pode ser considerada multidisciplinar, abrangendo estudos dos campos da administração, ciência da computação e ciência da informação (Mafrá Pereira; Carvalho; Jordão, 2016).

Destaca-se a proximidade intrínseca entre as áreas de inteligência competitiva e gestão do conhecimento. A inteligência competitiva pode ser entendida como a capacidade das organizações para desenvolver processos de tratamento e uso de informação e conhecimento que facilite a efetiva tomada de decisões, gerando vantagens competitivas. Nesse sentido, a atividade de inteligência competitiva permite aumentar e transformar o conhecimento tácito e explícito na organização, para que esta esteja apta a agir de forma apropriada frente às mudanças internas e externas identificadas (Cruz; Domínguez, 2007).

2.2 Gestão do conhecimento

O conhecimento pode ser definido como um conjunto fluido de experiências, valores, informações contextualizadas e apoio especializado que fornece as condições para a avaliação e incorporação de novas informações. Enquanto o conhecimento se origina e é utilizado na mente das pessoas, no ambiente organizacional o conhecimento se apresenta também em documentos, rotinas, processos, práticas e normas (Davenport; Prusak, 1998).

Uma organização do conhecimento é aquela capaz de integrar eficientemente os processos de criação de significado, construção do conhecimento e tomada de decisões. Inicialmente, a informação sobre o ambiente é percebida e depois seu significado é construído socialmente. Essa etapa fornece as bases para a construção do conhecimento na mente dos indivíduos, que deve ser compartilhado e transformado em inovação. Quando é suficiente a socialização do conhecimento adquirido, a organização está apta a agir de forma racional e alinhada aos seus objetivos estratégicos (Choo, 2011).

A gestão do conhecimento é um sistema que organiza políticas, processos e ferramentas gerenciais e tecnológicas para facilitar a geração, a identificação, a validação, a disseminação, o compartilhamento, a proteção e o uso dos conhecimentos estratégicos, visando gerar resultados para o negócio e as partes interessadas (Terra, 2005).

O ciclo de conversão do conhecimento, ou espiral do conhecimento, é uma maneira de perceber o processo de gestão do conhecimento. O conhecimento pode ser convertido de tácito para explícito e vice-versa. Conhecimento tácito é aquele que uma pessoa adquire a partir de suas experiências e intuições e que se mostra subjetivo e de difícil formalização. Por sua vez, o conhecimento explícito é de mais fácil registro, documentação e transmissão. Esses dois tipos de conhecimento são complementares e necessários. Contudo, torna-se preponderante a explicitação do conhecimento para a inovação e o desenvolvimento de novos produtos e serviços dentro das organizações (Nonaka; Takeuchi, 1995).

De acordo com Nonaka e Takeuchi (1995), o ciclo de conversão do conhecimento começa no processo de socialização, no qual compartilha-se o conhecimento tácito entre

membros da organização. Na etapa seguinte, por meio do processo de exteriorização, o conhecimento tácito é convertido em conhecimento explícito. Em seguida, o conhecimento explícito é somado à base de conhecimento no processo de combinação do conhecimento explícito. Finalmente, o novo conhecimento explícito é assimilado pelas pessoas no processo de internalização.

2.3 Grafos de conhecimento

Um grafo de conhecimento descreve os conceitos do mundo e seus relacionamentos sob a forma de uma estrutura de dados composta por um conjunto de nós e um conjunto de ligações ou arestas (Tian *et al.*, 2022). Os grafos de conhecimento armazenam, acumulam e comunicam conhecimento do mundo real (Peng *et al.*, 2023). Pessoas e sistemas podem raciocinar a partir de grafos de conhecimento. Raciocínio é uma das formas primárias de pensamento simulado e um processo de deduzir novas conclusões a partir de premissas existentes (Chen *et al.*, 2020).

Grafos de conhecimento são estruturas criadas a partir de ontologias, que podem ser explorados por abordagens dedutivas e indutivas. A abordagem dedutiva permite a extração de conhecimento usando implicações e raciocínio por meio de axiomas e regras lógicas. No caso da abordagem indutiva, o conhecimento é derivado a partir da análise de padrões generalizados (Ryen *et al.*, 2022).

Uma ontologia é uma representação formal e explícita de conhecimento que especifica uma conceitualização compartilhada (Gruber, 1995; Studer; Benjamins; Fensel, 1998). As ontologias tiveram seu uso e sua aplicação crescentes desde a década de 1990, devido à necessidade de se criar representações de conhecimento de domínio que fossem formais e compreensíveis tanto por humanos quanto por máquinas, visando o compartilhamento e o reúso do conhecimento (Guizzardi, 2005).

A questão central do uso de ontologias reside na definição dos conceitos, dos dados que os representam e das suas restrições. Essas características superam a simples definição dos dados e fornecem independência de codificações e resoluções específicas (Gruber, 1995).

2.4 Inteligência artificial generativa

A inteligência artificial generativa é um ramo da IA dedicado a modelos e algoritmos capazes de gerar conteúdo novo e original, tais como texto, imagens, músicas e vídeos (Kulkarni *et al.*, 2023). A ampla difusão da IA generativa com GPT-4, Copilot e Dall-E 2, por exemplo, está revolucionando a forma com que as pessoas trabalham e se comunicam. As aplicações de IA generativa podem suportar ou substituir tarefas de trabalho humanas, com impactos para o produto interno bruto e o cenário de empregos em todo o mundo (Feuerriegel *et al.*, 2024).

Na raiz do funcionamento das aplicações de IA generativa estão os grandes modelos de linguagem, que fornecem a base de conhecimento e a capacidade de processamento da linguagem. Geralmente os LLM são treinados por meio de enormes quantidades de dados textuais disponíveis na Internet. A característica principal desses modelos é sua capacidade de aprender padrões complexos, representações semânticas e relacionamentos contextuais em linguagem natural (Kulkarni *et al.*, 2023; Feuerriegel *et al.*, 2024).

No uso dos grandes modelos de linguagem, quando a tarefa envolve um raciocínio complexo, pode-se adotar uma investigação passo-a-passo, em uma série de etapas de raciocínio intermediários, denominada de cadeia-de-pensamento (*chain-of-thought*). Essa técnica é parte da área denominada de *prompt engineering* (Wei *et al.*, 2022; Ling *et al.*, 2024).

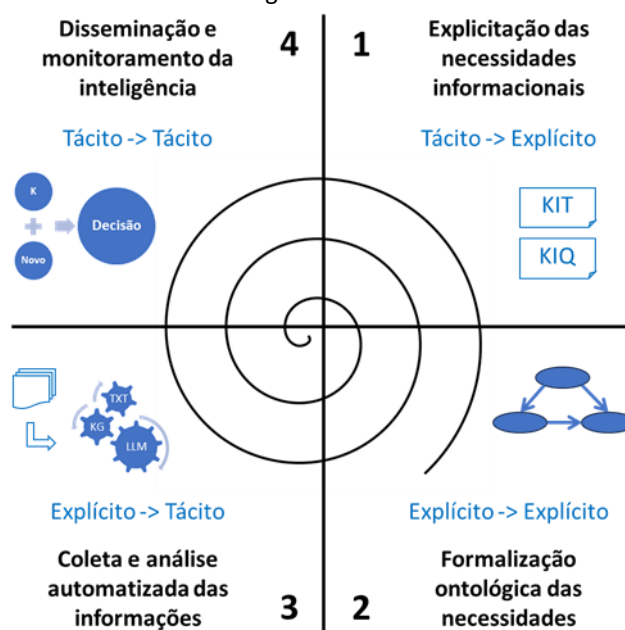
O uso combinado de inteligência artificial generativa e grafos de conhecimento é uma estratégia eficiente para o monitoramento ambiental e a descoberta de avanços científicos (Pan *et al.*, 2024; Buehler, 2024).

3 METODOLOGIA

Esta é uma pesquisa aplicada, exploratória e de abordagem qualitativa.

Inicialmente foi desenvolvido um modelo e um método integrado de inteligência competitiva e gestão do conhecimento suportado por processos de inteligência artificial generativa e grafos de conhecimento, conforme demonstrado na Figura 1, haja vista as lacunas identificadas na literatura (Madureira; Popovič; Castelli, 2023; Cekuls, 2023) e as vantagens de se combinar grafos de conhecimento e LLM (Pan *et al.*, 2024; Buehler, 2024). O modelo (e o método) foi denominado GenCI¹, que significa inteligência competitiva (*competitive intelligence* – CI) suportada por IA generativa (*generative AI*). O GenCI foi baseado nos processos de conversão do conhecimento organizacional de Nonaka e Takeuchi (1995), no ciclo de inteligência competitiva de Miller (2000) e no processo para identificar e definir as necessidades de inteligência de Herring (1999), conforme descritos no referencial teórico.

Figura 1 – GenCI – Modelo e método de inteligência competitiva suportado por inteligência artificial generativa



Fonte: Elaborado pelos autores (2024) e adaptado de Nonaka e Takeuchi (1995), Herring (1999) e Miller (2000)

Na primeira etapa do ciclo do GenCI, os tomadores de decisão da organização explicitam e especificam suas necessidades de informações de inteligência por meio da definição de KIT e KIQ. Os KIT são compostos por um objetivo e uma descrição do que se pretende alcançar. Cada KIQ é vinculado a um KIT específico. Uma KIQ é definida por um problema ou pergunta que precisa de resposta. Essa especificação é suficiente para explicitar as necessidades informacionais.

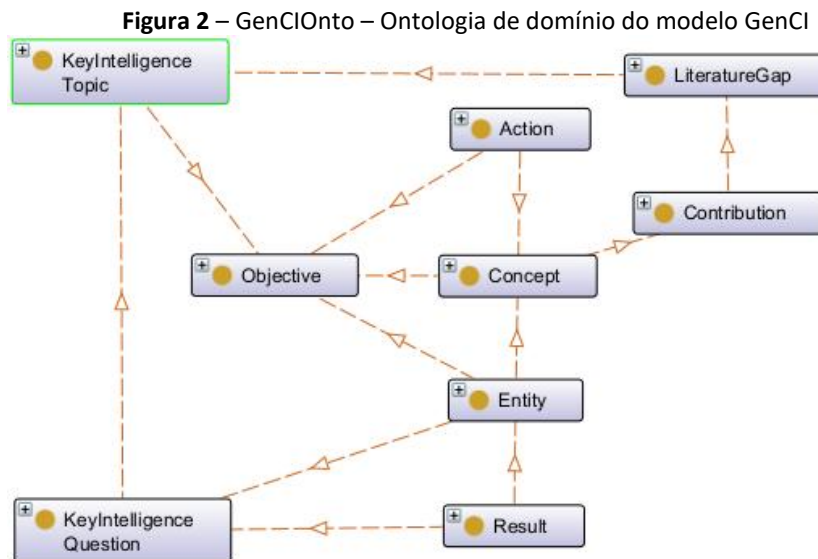
¹ Link para artefatos, conjunto de dados e documentação é omitido para avaliação anônima.

A segunda etapa do GenCI é composta por uma ontologia genérica, denominada GenCIOnto, cujo escopo é a modelagem do domínio de inteligência competitiva de forma integrada à gestão do conhecimento. A ontologia foi desenvolvida com base no Método 101 (Noy; McGuinness, 2001), por ser de simples aplicação e frequentemente adotado em outras pesquisas. O método de Noy e McGuinness (2001) consiste nos passos: (1) definir o domínio e o escopo, (2) definir as classes e a hierarquia de classes, (3) definir as propriedades das classes, (4) definir os atributos das propriedades e (5) criar instâncias.

Na construção de uma ontologia, um passo útil para delinear ou especificar o escopo é a definição de questões de competência, que exemplificam o potencial informacional da ontologia. Nesta pesquisa, foram estabelecidas as seguintes questões de competência:

- **QC1:** Quais foram as informações de monitoramento do ambiente coletadas para cada KIT?
- **QC2:** Quais respostas foram obtidas para responder às KIQs?
- **QC3:** Quais conceitos foram identificados para cada um dos objetivos dos KIT?

A ontologia GenCIOnto foi desenvolvida no software Protégé 5.6.1 (Musen, 2015) e pode ser visualizada na Figura 2, exportada por meio da aba OntoGraf do Protégé.



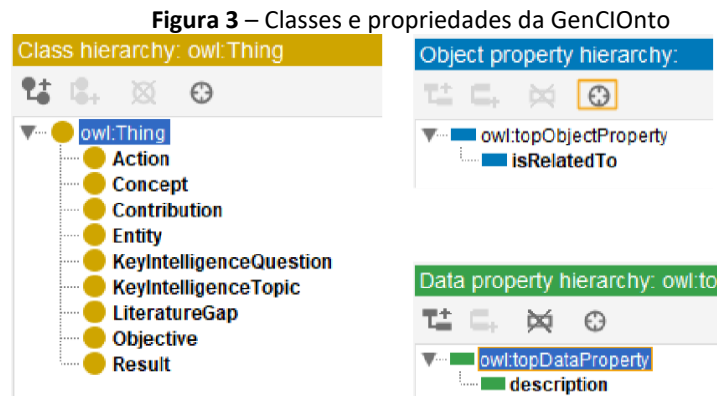
Fonte: Elaborado pelos autores (2024)

As seguintes classes disjuntas foram definidas, sem hierarquia entre elas: **KeyIntelligenceTopic:** representa um KIT. **Objective:** representa o objetivo do KIT. **KeyIntelligenceQuestion:** representa uma KIQ, que deve ser vinculada a um KIT. **Concept:** conceitos reconhecidos e extraídos do KIT. **Action:** ações (verbos) ou relacionamentos reconhecidos e extraídos do KIT. **Entity:** entidades nomeadas reconhecidas e extraídas da descrição da KIQ. **Contribution:** contribuições de um documento ou artigo científico relativas ao objetivo do KIT. **LiteratureGap:** informações de monitoramento do ambiente obtidas a partir das lacunas da literatura identificadas em um documento ou artigo científico relativas ao objetivo do KIT. **Result:** resultado identificado em um documento ou artigo científico que foi considerado capaz de responder ao problema ou pergunta especificada na KIQ.

Embora a natureza de **Concept** e **Entity** seja fortemente interligada, um relacionamento pode conectar uma entidade nomeada a um conceito. Neste caso, o relacionamento poderia ser representado potencialmente pela **Action**. Por exemplo, a entidade nomeada “Pedro” poderia estar conectada ao conceito “xadrez” pelo relacionamento

“joga”, enquanto a entidade nomeada “ChatGPT” poderia estar conectada ao conceito “chatbot” pelo relacionamento “é um” (Martinelli *et al.*, 2024).

A única *object property*² definida foi **isRelatedTo** e está indicada na Figura 2 pelas setas que ligam as classes. Trata-se de uma propriedade simétrica, ou seja, sempre que um relacionamento “**A isRelatedTo B**” for definido, o raciocinador (*reasoner*) automaticamente inferirá que o relacionamento “**B isRelatedTo A**” também é verdadeiro. A única *data property* definida foi **description**, cujo contradomínio ou *range* é **xsd:string**³. A Figura 3 demonstra as classes, as *object properties* e as *data properties* da ontologia.



Fonte: Elaborado pelos autores (2024)

Um grafo de conhecimento criado a partir da GenCIOnto é povoado com as informações obtidas na primeira etapa do GenCI. Dessa forma, são criadas instâncias das classes **KeyIntelligenceTopic**, **Objective**, **KeyIntelligenceQuestion**, **Concept**, **Action** e **Entity**.

Na terceira etapa do GenCI, são buscados documentos e artigos científicos da literatura mais atual para suprir a necessidade informacional especificada, abrangendo informações de monitoramento do ambiente (**LiteratureGap**) e respostas às perguntas ou problemas definidos nas KIQ (**Result**). Essa etapa representa um processamento cognitivo das informações coletadas, que estavam distribuídas e desconectadas dos KIT. Por isso, representa a conversão entre conhecimento explícito para tácito. Esta versão do GenCI não se propõe a atender a categoria de KIT que se refere à identificação e descrição de atores-chave do ambiente de negócios da organização.

Finalmente, na quarta e última etapa do ciclo do GenCI, realiza-se a socialização de um conhecimento novo, relevante e direcionado para a tomada de decisão por meio da visualização do grafo de conhecimento gerado e das possíveis inferências lógicas e probabilísticas realizadas, respectivamente, por raciocinadores e algoritmos de aprendizado de máquina. Os tomadores de decisão também podem consultar as informações do grafo de conhecimento por meio de consultas SPARQL⁴. O *feedback* dos decisores é importante e poderá ser refletido por meio de mudanças nas definições dos KIT e das KIQ no novo ciclo.

Com o propósito de testar empiricamente o GenCI, foi realizado um experimento baseado na GenCIOnto e nas questões de competência elaboradas. O experimento foi

² Em ontologias, uma *object property* implementa atributos extrínsecos que relacionam os objetos (instâncias das classes). Uma *data property* implementa os atributos intrínsecos aos objetos.

³ Dessa maneira é possível associar uma descrição em linguagem natural a cada um dos objetos, facilitando a compreensão do usuário.

⁴ <https://www.w3.org/TR/sparql11-query/>.

realizado no dia 25/6/2024 com o suporte da IA generativa Gemini⁵, pois considera as informações recentes disponíveis na Web.

Como técnica de *prompt engineering* foi utilizada a cadeia de pensamento (*chain-of-thought*), que é apropriada quando o caso de uso envolve um raciocínio complexo (Wei *et al.*, 2022; Ling *et al.*, 2024). Destaca-se que todos os *prompts* são padronizados e devem apenas substituir os termos relativos às informações específicas em cada caso concreto. Adicionalmente, os *prompts* foram elaborados na língua inglesa, mas as respostas podem ser solicitadas no idioma desejado pelo usuário e que seja compatível com a ferramenta Google Gemini. Portanto, o experimento realizado é generalizável.

O experimento não foi realizado sobre necessidades de informação reais de alguma empresa. Contudo, a proposta é que o experimento possa ser reproduzido e testado em diferentes contextos, locais e aplicações de forma objetiva, ou seja, independentemente do pesquisador. Essas características reforçam a validade científica do estudo empírico, bem como do próprio GenCI. Nesse sentido, os KIT e as KIQ foram elaborados a partir de Wang *et al.* (2024), um artigo científico recente que é um *survey* sobre agentes autônomos baseados em LLM. Os resultados reivindicados no artigo foram cotejados com a capacidade do método proposto em identificar lacunas na literatura (monitoramento do ambiente) e em identificar resultados relevantes e inovadores (responder às KIQ).

Em relação à construção do agente autônomo, que é objeto do artigo de Wang *et al.* (2024), os autores focam em duas questões, que passam a ser considerados os objetivos dos KIT do experimento:

- **KIT1**: “*how to design the agent architecture to better leverage LLMs*”;
- **KIT2**: “*how to inspire and enhance the agent capability to complete different tasks*”.

Esses KIT são desdobrados em KIQ segundo os detalhes de Wang *et al.* (2024):

- **KIQ1A** (vinculado⁶ ao KIT1): “*agent framework*”;
- **KIQ2A** (vinculado ao KIT2): “*commonly-used strategies for agents’ capability acquisition*”;
- **KIQ2B** (vinculado ao KIT2): “*applications of LLM-based autonomous agents in social science, natural science, and in engineering*”;
- **KIQ2C** (vinculado ao KIT2): “*strategies for evaluating LLM-based autonomous agents*”.

Neste momento de implementação do GenCI, as definições dos KIT e das KIQ foram feitas manualmente, o que poderá ser automatizado em implementações futuras.

As KIQ foram definidas a partir de um texto livre escrito pelos autores do artigo tomado como referência (Wang *et al.*, 2024). Assim como em situações organizacionais reais, a especificação das necessidades pode não ser expressa de forma estruturada e completa por seus tomadores de decisão. Por exemplo, a **KIQ1A** estabelece como pergunta apenas “*agent framework*”. Embora não seja de fato uma pergunta, a **KIQ1A** estabelece que a necessidade informacional de inteligência específica se refere à obtenção de um arcabouço de agente, que daria suporte ao projeto de uma arquitetura de agente para fins de aprimoramento do uso de LLM (**KIT1**). Essa definição incompleta das KIQ se justifica pela natureza automatizada do método proposto, que não supõe ou exige a intervenção humana para o seu funcionamento. Dessa forma, o método pode seguir o seu curso de ação mesmo com entradas incompletas fornecidas pelos usuários, o que evidentemente pode afetar os resultados. Contudo, na fase de monitoramento do GenCI, os usuários poderão avaliar os resultados e formular melhores KIT e KIQ no próximo ciclo, na etapa de identificação das necessidades.

⁵ <https://gemini.google.com>.

⁶ Vinculado pela *object property isRelatedTo*.

4 RESULTADOS E DISCUSSÃO

Nesta seção, serão apresentados os resultados do experimento, bem como as discussões em comparação com a literatura. Na exibição das respostas da ferramenta Gemini, serão omitidos detalhamentos do texto desnecessários para o propósito deste artigo, sem prejuízo para a compreensão ou validade das explicações aqui presentes. Os textos utilizados como *prompts* serão integralmente reproduzidos.

Os *prompts* utilizados foram inseridos manualmente no Gemini com o propósito de validar o GenCI. Porém, são textos padronizados preenchidos com informações que podem ser obtidas automaticamente, desde as necessidades de informação até as informações produzidas pelo próprio LLM (Gemini) em suas respostas. Pesquisas futuras poderão automatizar por completo o modelo GenCI, cuja implementação, neste momento, ainda exige a execução das etapas de forma manual.

Na primeira interação com o Gemini, é realizada preliminarmente uma contextualização sobre grafos de conhecimento segundo Tian *et al.* (2022), visando estabelecer que as extrações de informações que serão solicitadas possuem relação com a construção de grafos de conhecimento. Em seguida, solicita-se a extração de conceitos do **KIT1** (Quadro 1), objetivos do **KIT1** (Quadro 2), ações do **KIT1** (Quadro 3) e entidades nomeadas da **KIQ1A** (Quadro 4).

Quadro 1 – Primeira interação com Gemini

Prompt:
The knowledge graph (KG) describes the objective world's concepts, entities, and their relationships in the form of graphs. It can organize, manage, and understand massive information in a way close to human cognitive thinking. In that case, KG plays an important role in a variety of downstream applications, such as semantic search, intelligent recommendation, and question answering. Please extract the concepts from the following phrase: "how to design the agent architecture to better leverage LLMs".
Resposta:
Here are the concepts extracted from the phrase "how to design the agent architecture to better leverage LLMs": <ul style="list-style-type: none"> ● Agent architecture: [...] ● Large Language Models (LLMs): [...] ● Leverage: [...] Additional concepts (implicit): <ul style="list-style-type: none"> ● Design: [...] ● Better: [...] [...]

Fonte: Elaborado pelos autores (2024)

Quadro 2 – Segunda interação com Gemini

Prompt:
Please extract the objectives from the following phrase: "how to design the agent architecture to better leverage LLMs".
Resposta:
The phrase "how to design the agent architecture to better leverage LLMs" implies two possible objectives, though it doesn't explicitly state them: <ol style="list-style-type: none"> 1. Improved Agent Capabilities: [...] 2. Effective LLM Integration: [...] [...]

Quadro 3 – Terceira interação com Gemini

Prompt:
Please extract the actions from the following phrase: "how to design the agent architecture to better leverage LLMs".
Resposta:
The phrase "how to design the agent architecture to better leverage LLMs" focuses on a concept and doesn't explicitly mention any actions. However, we can infer some implied actions involved in achieving the objective:

Quadro 4 – Quarta interação com Gemini

Prompt:
Please extract the entities from the following phrase: "agent framework".
Resposta:
In the phrase "agent framework", there are two entities: <ul style="list-style-type: none"> ● Agent: [...] ● Framework: [...] [...]

Fonte: Elaborado pelos autores (2024)

- Design: [...]
- Leveraging LLMs: [...]

Fonte: Elaborado pelos autores (2024)

Fonte: Elaborado pelos autores (2024)

A partir da obtenção dessas informações, passa-se a buscar os artigos científicos de interesse, que visem atender às necessidades de informação de inteligência. Para fins de demonstração, a identificação de necessidades foi restrita ao **KIT1** e à respectiva **KIQ1A**. No Quadro 5 é mostrada a solicitação de formulação de uma consulta no Google Acadêmico, enquanto na Figura 4 é apresentado o resultado da busca. Outras fontes de informação relevantes poderiam ser também consultadas em versões expandidas do experimento.

Quadro 5 – Quinta interação com Gemini

Prompt:
Formulate a Google Scholar search string to look for peer-reviewed research papers on the concepts “Agent architecture”, “Large Language Models (LLMs)”, and “Leverage”. Additional concepts may be of interest, such as “Design” and “Better”. The research papers should be related to some of the objectives “Improved Agent Capabilities” or “Effective LLM Integration”. The text of the paper should mention actions such as “Design” and “Leveraging LLMs”.
Resposta:
Here's a Google Scholar search string designed to meet your criteria: ("agent architecture" OR "agent framework") AND "Large Language Models" (leverage OR integration) AND (design OR improve*) AND (task* OR capability OR performance) [...]

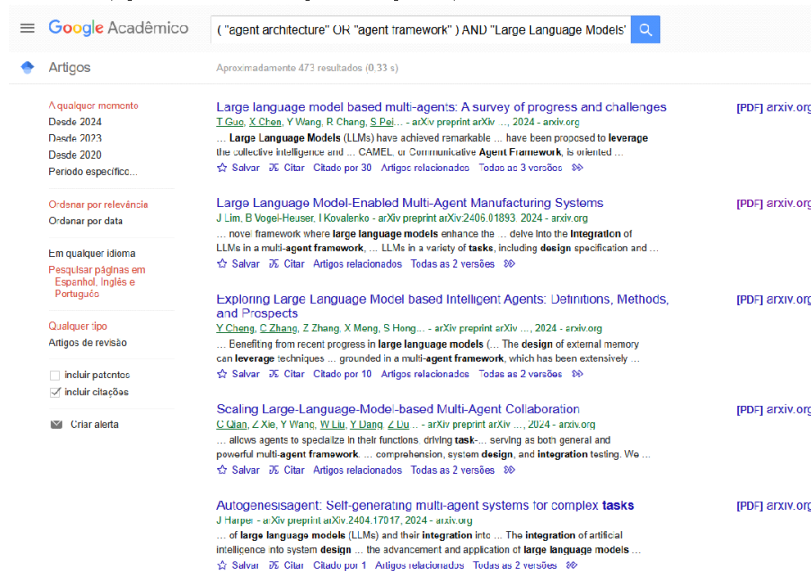
Fonte: Elaborado pelos autores (2024)

Figura 4 – Resultado da busca por artigos científicos

Google Scholar search string:

("agent architecture" OR "agent framework") AND "Large Language Models" (leverage OR integration) AND (design OR improve*) AND (task* OR capability OR performance)

Resultados (5 primeiros resultados para exemplificar):



Fonte: Elaborado pelos autores (2024)

A partir dos resultados da busca, pode-se selecionar somente os artigos científicos mais recentes, haja vista que o GenCI é um método de aquisição de

conhecimento incremental. Ou seja, a cada execução, se mantidas as necessidades informacionais de inteligência, somente os artigos publicados posteriormente à última execução precisam ser considerados.

Para cada artigo selecionado, passa-se à extração dos seus resultados, das suas contribuições e das lacunas de literatura identificadas (Quadro 6). Em seguida, solicita-se conclusividade na resposta à **KIQ1A** (Quadro 7). Neste caso, a resposta conclusiva indica que não houve resultado específico relevante.

Quadro 6 – Sexta interação com Gemini

Prompt:
Regarding the paper "Large language model based multi-agents: A survey of progress and challenges", by T Guo, X Chen, Y Wang, R Chang, S Pei, 2024, please look for contributions from the paper related to "Agent" and "Framework" that fill some gap found in the literature according to the authors. Finally, specify what were the concrete results related to "Agent" and "Framework" that represent contributions. The response must be in the following format: (i) Results; (ii) Contributions; (iii) Literature gaps.
Resposta:
<p>Extracted Information from "Large Language Model based Multi-Agents: A Survey of Progress and Challenges"</p> <p>(i) Results The paper by Guo et al. (2024) doesn't explicitly state specific results related to "Agent" and "Framework" as standalone contributions. However, it focuses on the overall progress and challenges in LLM-based multi-agent systems (LLM-MA). These systems involve designing frameworks for multiple agents powered by LLMs.</p> <p>(ii) Contributions The paper's contribution regarding "Agent" and "Framework" lies in its comprehensive survey of the LLM-MA field. [...]</p> <p>(iii) Literature Gaps The paper highlights several gaps in the literature related to "Agent" and "Framework" in LLM-MA systems:</p> <ul style="list-style-type: none"> ● Limited Standardization: [...] ● Scalability and Efficiency: [...] ● Limited Evaluation Techniques: [...]

Fonte: Elaborado pelos autores (2024)

Quadro 7 – Sétima interação com Gemini

Prompt:
Now be conclusive. Are there any specific results related to "Agent" and "Framework" (Yes/No)? What are the most important gaps left in this regard?
Resposta:
<p>Conclusive Answer</p> <p>(i) Specific Results:</p> <p>No</p> <p>[...]</p>

Fonte: Elaborado pelos autores (2024)

O processo iniciado na extração dos resultados (Quadro 6) continua para cada um dos artigos recuperados, conforme se segue. O Quadro 8 mostra o exemplo para o segundo artigo recuperado na busca efetuada no Google Acadêmico. Em seguida, solicita-se conclusividade na resposta à **KIQ1A** (Quadro 9). Neste caso a resposta é positiva, portanto considera-se que o resultado específico obtido é uma resposta relevante para a **KIQ1A**.

Observa-se, pelo experimento, a capacidade do GenCI de processamento da linguagem natural: na identificação de conceitos, ações e entidades nomeadas; na extração de informações contextualizadas; na identificação de contribuições, lacunas e resultados; e na identificação de conteúdo novo e relevante, como demonstrado nos exemplos dos artigos de *Guo et al.* (2024) (Quadro 7) e *Lim et al.* (2024) (Quadro 8).

A partir das respostas obtidas pelas interações com o Gemini, foram criadas manualmente instâncias (Figura 5) das classes da ontologia para testar a capacidade do grafo de conhecimento em responder às questões de competência. Por exemplo, a partir das respostas contidas no Quadro 4, foram criadas as instâncias de **Entity** denominadas **entityAgent** e **entityFramework**, com atributo **description** preenchido com "agent" e "framework", respectivamente. Neste artigo, para fins de

demonstração, no experimento somente o **KIT1** e a **KIQ1A** foram completamente detalhados.

Quadro 8 – Oitava interação com Gemini

Prompt:
Regarding the paper "Large Language Model-Enabled Multi-Agent Manufacturing Systems", by J Lim, B Vogel-Heuser, I Kovalenko, 2024, please look for contributions from the paper related to "Agent" and "Framework" that fill some gap found in the literature according to the authors. Finally, specify what were the concrete results related to "Agent" and "Framework" that represent contributions. The response must be in the following format: (i) Results; (ii) Contributions; (iii) Literature gaps.
Resposta:
<p>Extracted Information from "Large Language Model-Enabled Multi-Agent Manufacturing Systems"</p> <p>(i) Results The paper by Lim et al. (2024) presents concrete results related to their proposed framework for multi-agent manufacturing systems that leverage Large Language Models (LLMs). [...]</p> <p>(ii) Contributions The paper's key contributions regarding "Agent" and "Framework" lie in proposing a novel framework that addresses limitations in traditional multi-agent manufacturing systems. [...]</p> <p>(iii) Literature Gaps (Implicit) While the paper doesn't explicitly mention literature gaps, the proposed framework addresses limitations present in traditional multi-agent manufacturing systems:</p> <ul style="list-style-type: none"> ● Limited Flexibility: [...] ● Reliance on Pre-Programmed Knowledge: [...]

Fonte: Elaborado pelos autores (2024)

Quadro 9 – Nona interação com Gemini

Prompt:
Now be conclusive. Are there any specific results related to "Agent" and "Framework" (Yes/No)? What are the most important gaps left in this regard?
Resposta:
<p>Conclusive Answer</p> <p>(i) Specific Results: Yes The paper by Lim et al. (2024) presents specific results demonstrating the effectiveness of their proposed framework for "Agent" and "Framework" in multi-agent manufacturing systems. These results showcase improvements in task allocation, operational adaptability, and agent communication. [...]</p>

Fonte: Elaborado pelos autores (2024)

A classificação das informações extraídas, tais como o conceito "*agent architecture*" e a entidade "*agent*", pode parecer arbitrária e gerar discussões a respeito de sua precisão ou de sua natureza de serem entidades ou conceitos. O refinamento desse processo, contudo, poderá ser realizado mediante o fornecimento de exemplos ao LLM em experimentos de pesquisas futuras.

Com as instâncias criadas para cada classe da GenCLOnto (Figura 5), tendo em vista que a *object property isRelatedTo* é simétrica, o raciocinador Pellet (*plugin*) do Protégé foi capaz de inferir relacionamentos adicionais entre as instâncias, explicitando algo implícito, assim gerando conhecimento novo. Na Figura 6, as inferências estão destacadas com o fundo sombreado em amarelo. Por exemplo, inferiu-se que o conceito "*agent architecture*" está relacionado à ação "*design*" e que o objetivo do **KIT1** está relacionado ao conceito "LLM".

Figura 5 – Instâncias das classes da ontologia criadas manualmente

Class	Members
owl:Thing	KIT1Contribution1Gap3, KIT1Contribution2Gap1, KIT1Contribution2Gap2, KIT1Contribution1Gap1, KIT1Contribution2Gap3, KIT1Contribution1Gap2
LiteratureGap	resultKIQ1A
Result	conceptLLM, additionalConceptBetter, conceptLeverage, additionalConceptDesign, conceptAgentArchitecture
Concept	entityAgent, entityFramework
Entity	objectiveKIT1, objectiveKIT2
Objective	KIT1Contribution1, KIT1Contribution2
Contribution	actionLeveragingLLM, actionDesign
Action	KIQ1A, KIQ2B, KIQ2C, KIQ2A
KeyIntelligenceQuestion	KIT1, KIT2
KeyIntelligenceTopic	

Fonte: Elaborado pelos autores (2024)

Figura 6 – Exemplos de inferências realizadas pelo raciocinador do Protégé (fundo sombreado de amarelo)



Fonte: Elaborado pelos autores (2024)

Em seguida foram respondidas as questões de competência QC1 (Figura 7), QC2 (Figura 8) e QC3 (Figura 9), por meio de consultas ao grafo de conhecimento povoado com as instâncias e com as inferências realizadas pelo raciocinador do Protégé. As consultas foram realizadas por intermédio do Snap SPARQL Query, disponível no Protégé.

Figura 7 – QC1: Quais foram as informações de monitoramento do ambiente coletadas para cada KIT?

```
select ?kit ?descricaoLacuna where {
  ?kit a :KeyIntelligenceTopic .
  optional { ?lacuna a :LiteratureGap ;
    :isRelatedTo ?kit ;
    :description ?descricaoLacuna . }
}
order by ?kit
```

?kit	?descricaoLacuna
:KIT1	Evaluation Techniques: There's a need for better methods to evaluate the effectiveness of LLM-MA systems.^xsd:string
:KIT1	Scalability: How well does the framework scale to larger and more complex manufacturing environments?^xsd:string
:KIT1	Security and Reliability: The paper doesn't explicitly discuss security considerations or potential vulnerabilities in the LLM integration.^xsd:string
:KIT1	Standardization: A lack of standardized frameworks makes it difficult to compare and combine different approaches.^xsd:string
:KIT1	Real-world Implementation: While the results are promising, further research might be needed to evaluate the framework's effectiveness in real-world manufacturing settings.^xsd:string
:KIT1	Scalability and Efficiency: Current frameworks might not handle large numbers of agents or complex environments efficiently.^xsd:string
:KIT2	

Fonte: Elaborado pelos autores (2024)

Cotejando as informações obtidas no experimento referentes à **QC1** (Figura 7) com o artigo de Wang *et al.* (2024), verifica-se que todos os tipos de lacunas são abordados no *survey*, portanto validando os resultados obtidos.

Cotejando as informações obtidas no experimento referentes à **QC2** (Figura 8) com o artigo de Wang *et al.* (2024), verifica-se que o resultado obtido para a **KIQ1A** foi abordado por Wang *et al.* (2024) no que se refere a *task allocation* e *agent communication*, portanto similares nesse aspecto. Contudo, aparentemente o artigo recuperado traz resultados inovadores não cobertos pelo *survey* no que se refere a *multi-agent manufacturing systems* e *operational adaptability*. Nesse sentido, o método proposto parece ser capaz de identificar oportunidades de vantagens competitivas no ambiente de negócios.

Figura 8 – QC2: Quais respostas foram obtidas para responder às KIQs?

```
select ?kit ?kiq ?descricaoKiq ?descricaoResultado where {
  ?kit a :KeyIntelligenceTopic .
  ?kiq a :KeyIntelligenceQuestion ;
        :isRelatedTo ?kit ;
        :description ?descricaoKiq .
  optional { ?resultado a :Result ;
              :isRelatedTo ?kiq ;
              :description ?descricaoResultado .
            }
}
order by ?kit
```

?kit	?kiq	?descricaoKiq	?descricaoResultado
:KIT1	:KIQ1A	Agent framework^^xsd:string	The paper by Lim et al. (2024) presents specific results demonstrating the effectiveness of their proposed framework for "Agent" and "Framework" in multi-agent manufacturing systems. These results showcase improvements in task allocation, operational adaptability, and agent communication.^^xsd:string
:KIT2	:KIQ2B	Applications of LLM-based autonomous agents in social science, natural science, and in engineering^^xsd:string	
:KIT2	:KIQ2C	Strategies for evaluating LLM-based autonomous agents^^xsd:string	
:KIT2	:KIQ2A	Commonly-used strategies for agents' capability acquisition^^xsd:string	

Fonte: Elaborado pelos autores (2024)

Cotejando as informações obtidas no experimento referentes à **QC3** (Figura 9) com o artigo de Wang *et al.* (2024), verifica-se os conceitos obtidos estão presentes no *survey* nas seguintes frequências: *agent architecture*, 6 ocorrências; *better*, 9 ocorrências; *design*, 65 ocorrências; *Large Language Model*, 90 ocorrências; *LLM*, 282 ocorrências; *leverage*, 28 ocorrências. Logo, observa-se a consistência dos conceitos identificados automaticamente com os termos frequentes presentes no *survey* de Wang *et al.* (2024).

Figura 9 – QC3: Quais conceitos foram identificados para cada um dos objetivos dos KIT?

```
select ?kit ?descricaoObjetivo ?descricaoConceito where {
  ?kit a :KeyIntelligenceTopic ;
        :isRelatedTo ?objetivo .
  ?objetivo a :Objective ;
            :description ?descricaoObjetivo .
  ?conceito a :Concept ;
            :isRelatedTo ?objetivo ;
            :description ?descricaoConceito .
}
order by ?kit ?descricaoConceito
```

?kit	?descricaoObjetivo	?descricaoConceito
:KIT1	How to design the agent architecture to better leverage LLMs^^xsd:string	Agent architecture^^xsd:string
:KIT1	How to design the agent architecture to better leverage LLMs^^xsd:string	Better^^xsd:string
:KIT1	How to design the agent architecture to better leverage LLMs^^xsd:string	Design^^xsd:string
:KIT1	How to design the agent architecture to better leverage LLMs^^xsd:string	Large Language Model (LLM)^^xsd:string
:KIT1	How to design the agent architecture to better leverage LLMs^^xsd:string	Leverage^^xsd:string

Fonte: Elaborado pelos autores (2024)

5 CONSIDERAÇÕES FINAIS

O objetivo deste artigo foi propor uma abordagem de automação do processo de inteligência competitiva baseada em grafos de conhecimento e inteligência artificial generativa, integrando a inteligência competitiva e a gestão do conhecimento. O objetivo foi alcançado por meio da proposição do modelo GenCI, da ontologia GenCIONto e da experimentação do método GenCI. Por meio do experimento, constatou-se a validade tanto do

modelo quanto da ontologia e do método proposto para responder às questões-chave de inteligência, bem como sua capacidade de identificar oportunidades de vantagens competitivas no ambiente de negócios.

Este trabalho fornece uma série de contribuições teóricas e aplicadas para as áreas de inteligência competitiva e gestão do conhecimento. Primeiramente, a proposta de um modelo de automação do ciclo de inteligência competitiva de forma integrada ao ciclo da gestão do conhecimento (Cruz; Domínguez, 2007), aplicável a instituições públicas e privadas de todos os portes. Em segundo lugar, o uso combinado de grafos de conhecimento e LLM podem resultar na extração automatizada e organização de informações mais completas (Pan *et al.*, 2024; Buehler, 2024). Finalmente, supre-se parcialmente uma lacuna identificada na literatura de modelos de inteligência competitiva que sejam suportados por processos de IA generativa (Madureira; Popovič; Castelli, 2023; Cekuls, 2023).

O método proposto é escalável, extensível e customizável, e pode ser completamente automatizado para maior tempestividade e menor tempo na coleta, integração e análise das informações de inteligência (Madureira; Popovič; Castelli, 2023; Cekuls, 2023).

A pesquisa realizada possui caráter multidisciplinar, reunindo conhecimentos de administração, ciência da computação e ciência da informação. Os resultados alcançados ainda ampliam a influência da ciência da informação na área de inteligência competitiva (Mafra Pereira; Carvalho; Jordão, 2016), abrindo novas perspectivas de atuação socialmente relevante e atualizada para os profissionais deste campo. Com efeito, vislumbra-se por esta pesquisa a abertura de todo um campo de atuação para o profissional da informação, pela aplicação de teorias e técnicas de representação, organização e monitoramento do conhecimento, próprias à ciência da informação. O profissional da informação encontrará ao explorar e aprofundar esta pesquisa uma forma relevante de colaborar decisivamente para a sobrevivência e a competitividade das organizações no contexto da Indústria 4.0 e da transformação digital.

Em termos de implicações teóricas, pode-se destacar a proposição e o detalhamento de um novo modelo de inteligência competitiva, que se destaca de outros modelos da literatura na medida em que é integrado à gestão do conhecimento e que também pode ser automatizado por meio de processo de IA generativa e pelo uso de grafos de conhecimento. Nesse sentido, o GenCI representa um avanço do conhecimento científico no que se refere aos processos tradicionais de inteligência competitiva e gestão do conhecimento (Nonaka; Takeuchi, 1995; Miller, 2000; Terra, 2005; Yap; Rashid, 2011; Ottonicar; Valentim; Mosconi, 2018).

As aplicações práticas desta pesquisa abrangem desde a descoberta científica (Buehler, 2024), a representação do conhecimento para a tomada de decisão estratégica (Gruber, 1995; Studer; Benjamins; Fensel, 1998; Tian *et al.*, 2022; Ryen *et al.*, 2022; Peng *et al.*, 2023), até a implementação efetiva e automática da metodologia de identificação de necessidades de informações de inteligência – incluindo KIT e KIQ (Herring, 1999; Miller, 2000).

As implicações gerenciais desta pesquisa abrangem tanto a maior eficiência e sustentabilidade do processo de inteligência competitiva para empresas de micro e pequeno portes, como também um maior nível de eficácia e integração deste processo em organizações de médio e grande portes.

Nas empresas com menor disponibilidade de recursos para investimento em pesquisa e desenvolvimento, o GenCI viabiliza a implementação da inteligência competitiva e da gestão do conhecimento de forma automatizada e com baixo custo, haja vista a disponibilidade de ferramentas tecnológicas e bases científicas de acesso gratuito.

No caso das grandes organizações, o modelo GenCI apresenta uma visão integrada dos processos de inteligência competitiva e gestão do conhecimento que reduz a complexidade e a heterogeneidade das informações e do processo decisório, sem prejuízos para uma análise ampla e fundamentada das informações disponíveis.

Essas implicações facilitam a adaptação das organizações ao contexto da Indústria 4.0 e da transformação digital, de modo que permaneçam competitivas (Ottonicar; Valentim; Mosconi, 2018; Madureira; Popovič; Castelli, 2023; Cekuls, 2023).

As principais limitações desta pesquisa foram a ausência de casos de levantamento de necessidades de informações de inteligência de empresas reais, o uso de apenas um serviço de IA generativa e o conjunto reduzido de dados de teste para o experimento. Assim como o modelo, o método ainda pode se beneficiar de detalhamento e formalização mais explícitos.

Sugere-se que estudos futuros considerem necessidades reais de empresas, extensões e modelagens mais sofisticadas da ontologia GenCIOnto que suporta o GenCI, o uso de conjuntos de dados mais amplos e de diferentes fontes, o fornecimento de exemplos ao LLM para melhorar a precisão de sua classificação de informações e a automação completa do processo de uso de IA generativa. Nesse sentido, poderá ser realizado um processamento cognitivo mais amplo e aprofundado, próprio a uma interpretação mais completa da inteligência competitiva no contexto da gestão do conhecimento.

REFERÊNCIAS

BUEHLER, Markus J. Accelerating Scientific Discovery with Generative Knowledge Extraction, Graph-Based Representation, and Multimodal Intelligent Graph Reasoning. **arXiv preprint arXiv:2403.11996**, 2024.

CEKULS, Andrejs. The Evolution of Competitive Intelligence: A Systemic Approach to Organizational Management. **Journal of Intelligence Studies in Business**, v. 13, n. 2, p. 4-5, 2023.

CHEN, Xiaojun; JIA, Shengbin; XIANG, Yang. A review: Knowledge reasoning over knowledge graph. **Expert systems with applications**, v. 141, p. 112948, 2020.

CHOO, Chun Wei. **A organização do conhecimento: como as organizações usam a informação para criar significado, construir conhecimento e tomar decisões**. 3. ed. São Paulo: Ed. SENAC, 2011.

CRUZ, Yunier Rodriguez; DOMÍNGUEZ, Esther Galán. La inteligencia organizacional: necesario enfoque de gestión de información y del conocimiento. **Ciência da informação**, v. 36, p. 51-58, 2007.

DAVENPORT, Thomas H.; PRUSAK, Laurence. **Working knowledge: How organizations manage what they know**. Harvard Business Press, 1998.

DUAN, Lian; DA XU, Li. Data analytics in industry 4.0: A survey. **Information Systems Frontiers**, p. 1-17, 2021.

FERNANDEZ, Marcelo Jorge; LANA, Rogério Adilson. Inteligência Competitiva: uma nova ferramenta para o empreendedorismo. **RACE-Revista de Administração, Contabilidade e Economia**, v. 7, n. 2, p. 149-166, 2008.

FEUERRIEGEL, Stefan et al. Generative AI. **Business & Information Systems Engineering**, v. 66, n. 1, p. 111-126, 2024.

GRUBER, Thomas R. Toward principles for the design of ontologies used for knowledge sharing? **International journal of human-computer studies**, v. 43, n. 5-6, p. 907-928, 1995.

GUIZZARDI, G. Ontological foundations for structural conceptual models. 2005. Tese de Doutorado. Enschede, The Netherlands: Centre for Telematics and Information Technology, University of Twente.

HERRING, Jan P. Key intelligence topics: a process to identify and define intelligence needs. **Competitive Intelligence Review**: Published in Cooperation with the Society of Competitive Intelligence Professionals, v. 10, n. 2, p. 4-14, 1999.

KULKARNI, Akshay et al. Applied Generative AI for Beginners. **Apress, Berkeley, CA**, 2023.

LING, Zhan et al. Deductive verification of chain-of-thought reasoning. **Advances in Neural Information Processing Systems**, v. 36, 2024.

MADUREIRA, Luis; POPOVIČ, Aleš; CASTELLI, Mauro. Competitive Intelligence Maturity Models: Systematic Review, Unified Model and Implementation Frameworks. **Journal of Intelligence Studies in Business**, v. 13, n. 1, p. 6-29, 2023.

MAFRA PEREIRA, Frederico Cesar; CARVALHO, Rodrigo Baroni; JORDÃO, Ricardo Vinícius Dias. Análise do ciclo da inteligência competitiva em arranjos produtivos locais: estruturação e implantação do bureau de inteligência do apl de software de Belo Horizonte. **Revista Inteligência Competitiva**, v. 6, n. 1, p. 139-164, 2016.

MARTINELLI, Giuliano et al. CNER: Concept and Named Entity Recognition. In: **Proceedings of the 2024 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (Volume 1: Long Papers)**. 2024. p. 8329-8344.

MILLER, Jerry. **Millennium intelligence**: understanding and conducting competitive intelligence in the digital age. Information Today, Inc., 2000.

MUSEN, Mark A. The protégé project: a look back and a look forward. **AI matters**, v. 1, n. 4, p. 4-12, 2015.

NONAKA, Ikuji; TAKEUCHI, Hirotaka. **The knowledge-creating company**: how japanese companies create the dynamics of innovation. Oxford University Press, 1995.

NOY, Natalya F.; MCGUINNESS, Deborah L. **Ontology Development 101: A Guide to Creating Your First Ontology**. 2001.

OTTONICAR, Selma Leticia Capinzaiki; VALENTIM, Marta Lígia Pomim; MOSCONI, Elaine. A competitive intelligence model based on information literacy: organizational competitiveness in the context of the 4th Industrial Revolution. **Journal of Intelligence Studies in Business**, v. 8, n. 3, 2018.

PAN, Shirui et al. Unifying large language models and knowledge graphs: A roadmap. **IEEE Transactions on Knowledge and Data Engineering**, 2024.

PENG, Ciyuan et al. Knowledge graphs: Opportunities and challenges. **Artificial Intelligence Review**, v. 56, n. 11, p. 13071-13102, 2023.

PORTER, Michael E. **Estratégia Competitiva-Técnicas para análise de indústrias e da concorrência**. Elsevier Brasil, 2004.

PRESCOTT, John E. The evolution of competitive intelligence. **Proposal Management**, Spring, p. 37-52, 1999.

RYEN, Vetle; SOYLU, Ahmet; ROMAN, Dumitru. Building semantic knowledge graphs from (semi-) structured data: a review. **Future Internet**, v. 14, n. 5, p. 129, 2022.

TERRA, J.C.C. **Gestão do conhecimento: o grande desafio empresarial**. 5. ed. rev. e atual. São Paulo: Negócio, 2005.

STUDER, Rudi; BENJAMINS, V. Richard; FENSEL, Dieter. Knowledge engineering: Principles and methods. **Data & knowledge engineering**, v. 25, n. 1-2, p. 161-197, 1998.

TIAN, Ling et al. Knowledge graph and knowledge reasoning: A systematic review. **Journal of Electronic Science and Technology**, v. 20, n. 2, p. 100159, 2022.

TOLEDO, Luciano Augusto; TOLEDO, Luiz Alberto. Sistema de Inteligência Competitiva: um Estudo de Caso no Setor de Telecomunicação. **Revista da FAE**, v. 10, n. 1, 2007.

WANG, Lei et al. A survey on large language model based autonomous agents. **Frontiers of Computer Science**, v. 18, n. 6, p. 186345, 2024.

WEI, Jason et al. Chain-of-thought prompting elicits reasoning in large language models. **Advances in neural information processing systems**, v. 35, p. 24824-24837, 2022.

YAP, Ching Seng; RASHID, Md Zabid Abdul. Acquisition and strategic use of competitive intelligence. **Malaysian Journal of Library and Information Science**, v. 16, n. 1, p. 125-136, 2011.

ZANGOUEINEZHAD, Abouzar; MOSHABAKI, Asghar. The role of structural capital on competitive intelligence. **Industrial Management & Data Systems**, v. 109, n. 2, p. 262-280, 2009.

Recebido em/Received: 01/02/2025 | Aprovado em/Approved: 10/04/2025
