



IA GENERATIVA NO DESENVOLVIMENTO DE SISTEMAS BASEADOS EM CONHECIMENTO

Ranieri Alves dos Santos¹;
Fernando Alvaro Ostuni Gauthier²;
Marcelo Macedo³;
Vanessa Roberg⁴

***Abstract:** The paper explores the impact of generative AI on the development of Knowledge-Based Systems. The article is based on a qualitative mapping of recent contributions of generative AI to Knowledge-Based Systems, with a narrative review of works published since 2022, including theses, articles, and conference publications. The results reveal 15 approaches demonstrating how generative AI can enhance processes of searching, constructing, classifying, retrieving, and communicating knowledge in Knowledge-Based Systems. The integration of generative AI with Knowledge-Based Systems can lead to more creative and relevant solutions, as well as point out future directions for this intersection.*

Keywords: Generative AI; KBS; LLM; Qualitative Mapping.

***Resumen:** Este trabajo explora el impacto de la IA generativa en el desarrollo de Sistemas Basados en Conocimiento (SBC). El artículo se basa en un mapeo cualitativo de las contribuciones recientes de la IA generativa para los Sistemas Basados en Conocimiento, con una revisión narrativa de trabajos publicados desde 2022, abarcando tesis, artículos y publicaciones en eventos. Los resultados revelan 15 enfoques que demuestran cómo la IA generativa puede mejorar los procesos de búsqueda, construcción, clasificación, recuperación y comunicación del conocimiento en Sistemas Basados en Conocimiento. La integración de la IA generativa con SBC puede conducir a soluciones más creativas y relevantes, además de señalar direcciones futuras para esta intersección.*

Palabras clave: IA generativa; SBC; LLM; Mapeo Cualitativo;

Resumo: O trabalho explora o impacto da IA generativa no desenvolvimento de Sistemas Baseados em Conhecimento. O artigo se baseou em um mapeamento qualitativo de contribuições recentes da IA generativa para os Sistemas Baseados em Conhecimento, com uma revisão narrativa de

¹ Programa de Pós-graduação em Engenharia, Mídia e Gestão do Conhecimento – Universidade Federal de Santa Catarina (UFSC) Florianópolis – Brasil. ORCID: <https://orcid.org/0000-0002-7071-8291>. E-mail: ranierisantos@gmail.com

² Programa de Pós-graduação em Engenharia, Mídia e Gestão do Conhecimento – Universidade Federal de Santa Catarina (UFSC) Florianópolis – Brasil. ORCID: <https://orcid.org/0000-0002-1648-7613>. E-mail: gauthier@egc.ufsc.br

³ Programa de Pós-graduação em Engenharia, Mídia e Gestão do Conhecimento – Universidade Federal de Santa Catarina (UFSC) Florianópolis – Brasil. ORCID: <https://orcid.org/0000-0003-4154-9318>. E-mail: marcelo5360@gmail.com

⁴ Programa de Pós-graduação em Engenharia, Mídia e Gestão do Conhecimento – Universidade Federal de Santa Catarina (UFSC) Florianópolis – Brasil. ORCID: <https://orcid.org/0000-0002-1648-7613>. E-mail: vanessaroberg@gmail.com



trabalhos publicados a partir de 2022, abrangendo teses, artigos e publicações em eventos. Os resultados revelam 15 abordagens que demonstram como a IA generativa pode aprimorar processos de busca, construção, classificação, recuperação e comunicação do conhecimento em Sistemas Baseados em Conhecimento. A integração da GenAI com SBCs pode levar a soluções mais criativas e relevantes, além de apontar direções futuras para essa intersecção.

Palavras-chave: IA generativa; SBC; LLM; Mapeamento Qualitativo;

1. INTRODUÇÃO

A Inteligência Artificial Generativa tem emergido como uma área de grande interesse e potencial na ciência da computação, destacando-se pela sua capacidade de gerar novos conteúdos como textos, imagens e áudios a partir de dados existentes. Este avanço tecnológico tem aberto novas possibilidades em diversos campos, incluindo os Sistemas Baseados em Conhecimento (SBCs), que há muito tempo desempenham um papel crucial na representação e utilização do conhecimento humano em sistemas computacionais.

Para tal, este artigo busca explorar e analisar as contribuições que a Inteligência Artificial Generativa pode oferecer aos Sistemas Baseados em Conhecimento. Busca-se compreender como as técnicas e modelos da IA Generativa podem aprimorar processos fundamentais dos SBCs, tais como a busca, construção, classificação, recuperação e comunicação do conhecimento.

O artigo está estruturado da seguinte forma: inicialmente, são apresentados os fundamentos da IA Generativa, incluindo sua estrutura, mecanismos de geração e modelos generativos. Em seguida, é realizada uma exposição sobre Sistemas Baseados em Conhecimento. Na parte central do artigo, é realizado um mapeamento qualitativo das contribuições recentes da IA Generativa para os Sistemas Baseados em Conhecimento, seguido por uma análise detalhada dessas contribuições. Por fim, são discutidas as implicações e potenciais direções futuras para a integração entre ambas as áreas.

2. FUNDAMENTOS DA IA GENERATIVA

A expressão "IA Generativa" é uma tradução do termo em inglês "*Generative AI*", ou da sua abreviação comum *GenAI*. Ela se refere a uma das áreas da inteligência artificial que se concentra no desenvolvimento de algoritmos capazes de gerar novos conteúdos, como textos, imagens, músicas ou códigos, a partir de dados existentes. Essa capacidade de criação é o que



distingue a IA generativa de outras formas de IA, que normalmente se concentram especialmente em tarefas de classificação, predição e reconhecimento de padrões (Kanbach et al, 2024; Chiu, 2023).

O trabalho de Goodfellow et al. (2014), apresentou a possibilidade do uso de uma nova estrutura de redes neurais, possibilitando a partir do aprendizado de máquina, a geração de alta qualidade de amostras de novos dados. Este trabalho, publicado na conferência *XXVII Advances in Neural Information Processing Systems* (NIPS'2014) abriu novas possibilidades para aplicações do que hoje denominamos como *GenAI*, como a geração de imagens, vídeos, dados e tarefas avançadas como a simulação e modelagem de dados complexos.

A partir destas premissas, foi possível o desenvolvimento de diferentes arquiteturas de modelos que foram desenvolvidas ao longo dos anos. Por exemplo, os modelos de difusão generativa têm ganhado destaque por sua capacidade de gerar imagens de alta qualidade a partir de amostras de ruídos aleatórios, permitindo uma abordagem inovadora para a síntese de imagens. Esses modelos funcionam através de um processo executado de forma sequencial, onde uma imagem é refinada passo a passo, removendo o ruído e adicionando detalhes até que a imagem final seja alcançada (Ho et al., 2020).

Assim, a *GenAI* não apenas replica padrões existentes, mas também permite a criação de novos padrões e a construção de soluções específicas e personalizadas. Além disso, a *GenAI* também vem sendo empregada na automação de processos criativos. Em setores como design gráfico e produção musical, os modelos generativos têm sido utilizados para auxiliar profissionais na geração de ideias, permitindo que eles se concentrem em aspectos mais estratégicos e criativos de seu trabalho. Por exemplo, *softwares* que utilizam *GenAI* podem sugerir sequências de paletas de cores, composições musicais ou até mesmo roteiros, otimizando o fluxo de trabalho e reduzindo o tempo necessário para a produção (Brown et al., 2020).

2.1. ESTRUTURA DA IA GENERATIVA

Uma das bases da estrutura da *GenAI* é o aprendizado de máquina (*machine learning*), um conjunto de técnicas da inteligência artificial conexionista que se concentra no desenvolvimento de algoritmos e modelos que permitem que sistemas computacionais aprendam a partir de dados, identificando padrões e fazendo previsões sem a necessidade de programação explícita para cada



tarefa. No aprendizado de máquina, os modelos não seguem instruções rígidas, eles utilizam técnicas estatísticas para analisar grandes conjuntos de dados e extrair informações. Esse processo é baseado na construção de modelos que podem generalizar a partir de exemplos, permitindo que eles realizem previsões e classificações baseadas em novos dados. O aprendizado de máquina é amplamente utilizado em diversas aplicações, como análise de imagens, reconhecimento de voz, recomendações de produtos e diagnósticos (Zhou, 2021).

A *GenAI* se baseia especialmente nos modelos de aprendizado profundo (*deep learning*), uma das técnicas de aprendizado de máquina que busca combinar diversas camadas de modelos de aprendizagem, em conjunto. No aprendizado profundo são utilizadas redes neurais artificiais com múltiplas camadas, conhecidas como redes neurais profundas. Essas redes são projetadas para imitar a forma como o cérebro humano processa informações, permitindo que o sistema aprenda representações hierárquicas e complexas dos dados. Com estas técnicas, o aprendizado profundo é especialmente capaz de desenvolver tarefas que envolvem grandes volumes de dados não estruturados, como imagens, áudio e texto, devido à sua capacidade de extrair características relevantes automaticamente.

2.1.1. Mecanismos de Geração

A partir das redes neurais de aprendizado profundo são concebidos os mecanismos de geração em *GenAI*, estruturas necessárias para o desenvolvimento dos modelos capazes de gerar novos dados a partir de treinamento. Um dos mecanismos de geração fundamentais é o de amostragem, uma técnica que permite a seleção de amostras a partir de uma distribuição de dados aprendida pelo modelo, sendo necessário para a criação de novas amostras dados que mantenham características semelhantes aos dados de treinamento (Coeurdoux et al, 2024).

Métodos como amostragem de Gibbs e amostragem de rejeição são comumente utilizados para garantir que as amostras geradas representem a distribuição, permitindo assim a criação de conteúdos variados e de alta qualidade (Carter & Kohn, 1994; Gelfand, 2000). O conceito de espaço latente é outro mecanismo de geração utilizado na *GenAI*, onde os dados são modelados de uma forma compacta e abstrata, facilitando a geração de novos conteúdos (Winterhalder & Bellagente, 2021; Vahdat, 2021).



2.1.2. Modelos Generativos

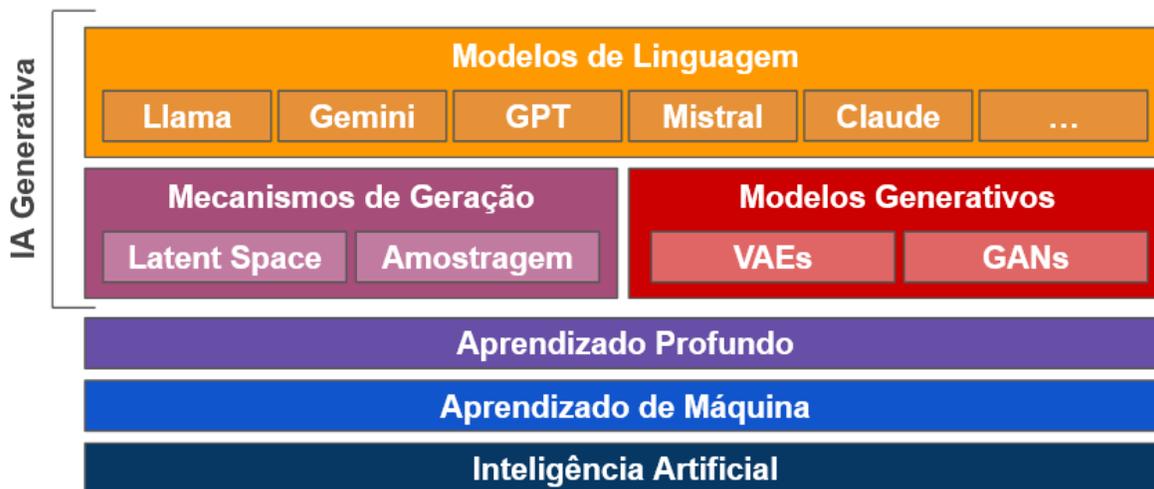
Em conjunto com os mecanismos de geração, a *GenAI* utiliza diferentes modelos generativos para a criação de novos dados a partir da entrada de dados (*prompt*), utilizando os modelos treinados, que trataremos aqui como modelos generativos. Um destes modelos é o de Redes Generativas Adversariais, “*Generative Adversarial Networks*” (GANs). As GANs consistem em duas redes neurais que operam com dois papéis, o gerador e o discriminador. O gerador é o elemento responsável por criar novos dados a partir de um vetor de ruído aleatório, enquanto o elemento discriminador avalia se os dados gerados são reais ou falsos, os comparando com um conjunto de dados reais (Yan et al, 2020). Durante o treinamento, essas duas redes competem entre si; a rede do gerador busca melhorar suas amostras para enganar a rede do discriminador, enquanto o discriminador se torna cada vez mais eficaz em identificar as amostras falsas (Creswell et al, 2018).

Os modelos de linguagem, como o GPT e suas variantes, representam uma classe de modelos generativos que se especializam na produção de texto coerente e contextualizado. Esses modelos são treinados em grandes quantidades de texto, onde aprendem a prever a próxima palavra em uma sequência com base nas palavras anteriores. Essa abordagem permite que os modelos de linguagem capturem nuances semânticas e sintáticas, resultando em saídas que não apenas são gramaticalmente corretas, mas também contextualmente relevantes (Eloundou et al, 2023; Yan et al, 2020).

Estes modelos de linguagem são baseados nos mecanismos de geração e modelos generativos que utilizam as técnicas de aprendizado profundo, oriundos dos modelos de aprendizagem de máquina, que são todas, abordagens de inteligência artificial. A Figura 1 apresenta a sumarização desta estrutura de mecanismos e modelos envolvidos na *GenAI*.



Figura 1 – Estrutura da GenAI



Fonte: Dos Autores (2024)

2.1.3. Grandes Modelos de Linguagem

Quando os modelos de linguagem são expostos a uma grande quantidade de dados eles comumente passam a ser classificados como Grandes Modelos de Linguagem (*Large Language Models*), ou LLM's. Eles são uma classe avançada de modelos geracionais que se destacam por sua capacidade de entender e gerar linguagem natural em diferentes contextos. Esses modelos são treinados em vastas quantidades de dados, permitindo que aprendam padrões complexos e relações entre palavras e frases, bem como entre outros dados como áudio e imagens (Platt & Platt, 2023). Essa habilidade de modelar a linguagem de forma contextualizada os torna extremamente eficazes em uma ampla gama de aplicações, incluindo tradução de idiomas, geração de texto, chatbots e assistentes virtuais, onde a interação natural com os usuários é essencial (Kaswan et al, 2023).

Os modelos de linguagem tradicionais são projetados para tarefas específicas, como prever a próxima palavra em uma sequência ou classificar textos, e geralmente possuem um número limitado de parâmetros e um escopo de treinamento mais restrito. Já os LLMs são modelos mais avançados, são modelos de linguagem de larga escala, que utilizam arquiteturas mais complexas como os transformadores, que são treinados em quantidades massivas de dados textuais (Eloundou et al, 2023). Essa escala de treinamento permite que os LLMs capturem relações de alta complexidade entre palavras e aprendam representações semânticas avançadas, permitindo que



seja realizada uma ampla variedade de tarefas relacionadas à linguagem, desde geração de texto até a compreensão de linguagem natural. Além disso, os LLMs geralmente possuem a capacidade de se adaptar a diferentes contextos e estilos de escrita por meio de técnicas de ajuste fino, os tornando mais flexíveis e versáteis do que os modelos de linguagem tradicionais (Kaswan et al, 2023; Chiu, 2023).

3. SISTEMAS BASEADOS EM CONHECIMENTO

Os sistemas baseados em conhecimento (SBCs) são uma classe de sistemas de inteligência artificial que utilizam conhecimento para resolver problemas complexos e tomar decisões informadas. Esses sistemas são projetados para simular a capacidade humana de raciocínio e inferência, utilizando uma base de conhecimento que contém informações, regras e relações sobre um domínio específico (Owens & Levary, 2006). Para este trabalho, serão tratadas como um SBC, todas as abordagens que envolvam o armazenamento do conhecimento, bem como a representação, a busca, a comunicação e a recuperação do conhecimento. Um dos principais tipos de sistemas baseados em conhecimento são os sistemas especialistas (*expert systems*), aplicações de propósito específico, desenvolvidas a partir do conhecimento de um determinado domínio, que visa automatizar o processo de raciocínio e diagnóstico a partir do conhecimento especializado já armazenado (Giarratano & Riley, 1998).

Uma das características distintivas dos SBCs é a sua capacidade de aprender e adaptar-se a partir de novas informações. Isso é frequentemente realizado por meio de técnicas de engenharia do conhecimento, onde especialistas humanos contribuem para a construção e atualização da base de conhecimento. Além disso, os SBCs podem incorporar mecanismos de aprendizado de máquina para melhorar sua eficácia ao longo do tempo, ajustando-se a mudanças nas condições ou na natureza dos dados. Essa combinação de conhecimento explícito e aprendizado adaptativo torna os SBCs particularmente valiosos em domínios dinâmicos, como saúde, finanças e engenharia, onde a capacidade de precisão é essencial (Owens & Levary, 2006).

Enquanto os SBCs são projetados para resolver problemas específicos utilizando conhecimento explícito e regras lógicas, a *GenAI* é capaz de produzir novos dados, como textos, imagens e áudios, a partir de padrões aprendidos em grandes conjuntos de dados. Essa junção permite que os SBCs se beneficiem da criação de novos dados e soluções criativas, enquanto a IA



generativa pode ser aprimorada por meio de conhecimento especializado que orienta a produção de conteúdo mais relevante e contextualizado. A próxima seção tratará desta intersecção, analisando as contribuições mapeadas que a *GenAI* pode prover para sistemas baseados em conhecimento.

4. PROCEDIMENTOS METODOLÓGICOS

Visando analisar o escopo do que se tem produzido nas áreas de abrangência deste trabalho, foi realizada uma pesquisa de mapeamento qualitativo de abordagens recentes que utilizam a GenAI em sistemas baseados em conhecimento. Esta pesquisa procurou buscar trabalhos que apresentavam, propunham, ou que revisavam contribuições que a GenAI poderia oferecer para os sistemas baseados em conhecimento nas suas mais variadas instâncias, seja na criação do conhecimento, no armazenamento do conhecimento, na integração entre conhecimentos e na classificação de conhecimentos.

A pesquisa se baseou em uma revisão narrativa, buscando trabalhos publicados a partir de 2022. Para a tarefa foram inseridos os mais variados tipos de estudos. Visto que a pesquisa não foi excludente, por se tratar de temas emergentes, foram aceitos no estudo trabalhos oriundos de teses de doutorado, artigos preprints e artigos publicados em anais de eventos e em revistas.

A pesquisa retornou 15 trabalhos que trazem contribuição da GenAI para sistemas que utilizem os processos de aquisição, armazenamento e compartilhamento do conhecimento. Após a análise, foi feita uma classificação dos trabalhos quanto à natureza da sua contribuição para SBCs, em cinco grupos:

- Trabalhos que contribuem para a Busca de conhecimento;
- Trabalhos que contribuem para a Construção de conhecimento;
- Trabalhos que contribuem para a Classificação de conhecimento;
- Trabalhos que contribuem para a Recuperação de conhecimento;
- Trabalhos que contribuem para a Comunicação de conhecimento.



O Quadro 01 apresenta a distribuição dos 15 trabalhos de acordo com esta classificação em cinco grupos, apresentando cada contribuição da GenAI aos SBC, ordenada por ano e referência.

Quadro 1 – Mapeamento de Contribuições da *GenAI* para os SBCs

Ano	Referência	Classificação	Contribuições
2024	Deng et al	Busca	Reduzir a demanda de comunidades de conhecimento online
2024	Robertson et al	Construção	Incentivar a co-construção do conhecimento entre humanos e IA
2024	Roy et al	Recuperação	Recuperar conhecimento em revisões sistemáticas da literatura
2024	Shahabikargar et al	Classificação	Enriquecer a classificação de dados a partir de bases de conhecimento de clientes
2023	Beheshti	Recuperação	Conectar o conhecimento com a experiência, permitindo a geração de novos conteúdos e processos
2023	Bulfamante	Busca	Permitir buscas generativas em bases de conhecimento
2023	Chern et al	Classificação	Analisar a veracidade de fatos baseados em conhecimento, geração de código, raciocínio e revisão de literatura
2023	Mukherjee e Kamath	Comunicação	Construir agentes virtuais a partir de bases de conhecimento organizacionais
2023	Platt e Platt	Classificação	Analisar conteúdo para classificação em determinados domínios para tarefas de compreensão do conhecimento
2023	Ren et al	Construção	Desenvolver bases de conhecimento semânticas para potencializar a comunicação
2023	Selker	Construção	Impulsionar a geração de novas ideias a partir do conhecimento humano, sem a colaboração de especialista humano
2023	Su et al	Construção	Incentivar a contribuição conhecimento de especialistas humanos alinhando as respostas geradas
2023	Wölfel et al	Comunicação	Construir chatbots educativos utilizando bases de conhecimento
2023	Zou et al	Comunicação	Permitir a comunicação entre dispositivos interoperando conhecimento
2022	Kather et al	Classificação	Contribuir com o diagnóstico baseado em conhecimento utilizando imagens

Fonte: Dos autores (2024)

5. RESULTADOS E DISCUSSÕES

Dos trabalhos analisados, os que estabelecem contribuições da *GenAI* para os processos de busca de conhecimento em bases de dados de SBCs, tanto o trabalho de Deng et al. (2024) quanto o de Bulfamante (2023) oferecem vislumbres acerca de como a *GenAI* pode ser capaz de prover mecanismos de consultas em grandes volumes de dados. O estudo de Deng et al. (2024) aborda a diminuição da demanda por comunidades online de compartilhamento de conhecimento,



especialmente em bases de conhecimento como o *StackOverflow*, o que implica uma maior eficiência na forma como os SBCs podem acessar e processar informações. Por outro lado, a pesquisa de Bulfamante (2023) foca na implementação de buscas generativas em bases de conhecimento, esta abordagem permite que os SBCs não apenas localizem dados específicos, mas também criem respostas contextualmente relevantes com base nas informações disponíveis.

Acerca dos trabalhos voltados para a construção do conhecimento a partir de *GenAI*, estudo de Robertson et al. (2024) destacam a importância da co-construção do conhecimento, onde humanos e IA trabalham juntos para enriquecer as bases de conhecimento, promovendo um ciclo de melhora na qualidade e na quantidade do conhecimento armazenado. Complementando essa abordagem, Ren et al. (2023) focam no desenvolvimento de bases de conhecimento semânticas, que potencializam a comunicação e a interoperabilidade entre diferentes sistemas a partir do enriquecimento contextual, permitindo uma representação mais rica e contextualizada do conhecimento. Além disso, Selker (2023) explora a capacidade da *GenAI* de impulsionar a geração de novas ideias a partir do conhecimento humano, mesmo na ausência de especialistas, ampliando as possibilidades criativas e inovadoras. Por fim, Su et al. (2023) explana sobre a importância de alinhar as respostas geradas com as contribuições de especialistas, profissionais humanos, garantindo que o conhecimento produzido seja relevante e coeso.

No âmbito da classificação do conhecimento, os trabalhos voltados para esta área apresentaram as contribuições da *GenAI* como mecanismo para a categorização de conhecimentos a partir dos modelos de linguagem. O trabalho de Shahabikargar et al. (2024), por exemplo, busca enriquecer a classificação de dados utilizando bases de conhecimento de clientes, permitindo uma personalização e relevância maiores nas informações geradas, buscando identificar o perfil do cliente que costuma cancelar serviços empresariais. Complementando essa abordagem, Chern et al. (2023) analisam a veracidade de fatos baseados em conhecimento, integrando a geração de código e raciocínio lógico, o que não apenas aprimora a qualidade da informação classificada, mas também assegura que os dados utilizados para a classificação sejam confiáveis e reais. Além disso, Platt e Platt (2023) contribuem para a análise de conteúdo em domínios específicos, facilitando a compreensão do conhecimento e sua aplicação em tarefas práticas, enquanto Kather et al. (2022) utilizam imagens para diagnósticos baseados em conhecimento, demonstrando como a classificação pode ser aplicada em contextos visuais e médicos.



Sobre o uso da GenAI em SBCs para a recuperação do conhecimento, Roy et al. (2024) apresentam um trabalho sobre como recuperar conhecimento de maneira eficiente em revisões sistemáticas utilizando *GenAI*, um processo importante para a síntese de evidências em diversas áreas do conhecimento. Ao utilizar técnicas de processamento de linguagem natural e aprendizado de máquina, a *GenAI* é capaz de analisar grandes volumes de textos acadêmicos, identificando padrões, conceitos-chave e insights relevantes para a revisão em questão. Já Beheshti (2023) explora como a *GenAI* pode conectar o conhecimento com a experiência, permitindo a geração de novos conteúdos e processos.

Como último item mapeado nestas pesquisas, o de comunicação a partir do conhecimento, Mukherjee e Kamath (2023) destacam como a *GenAI* pode ser utilizada para criar agentes virtuais que interagem com humanos de maneira natural e contextualizada, utilizando informações extraídas de bases de conhecimento corporativas. Essa abordagem melhora a eficiência da comunicação interna e externa das organizações, além de personalizar a experiência do usuário. Da mesma forma, Wölfel et al. (2023) demonstram como a *GenAI* pode ser aplicada na construção de chatbots educativos, que fornecem suporte e informações aos alunos com base em conhecimento pedagógico. Esses chatbots não apenas facilitam o acesso ao conhecimento, mas também proporcionam um aprendizado mais interativo e adaptado às necessidades individuais. Complementando essas contribuições, Zou et al. (2023) exploram como a *GenAI* pode permitir a comunicação entre diferentes dispositivos, interoperando conhecimento entre sistemas e garantindo a consistência e a integridade das informações compartilhadas.

A partir destas pesquisas, foi possível observar que diversas aplicações baseadas no uso do conhecimento podem se beneficiar de processos que utilizem modelos de GenAI, especialmente nas áreas de busca, comunicação, recuperação, classificação e construção do conhecimento.

6. CONSIDERAÇÕES FINAIS

A análise desenvolvida neste trabalho buscou demonstrar que a integração entre a *GenAI* com os SBCs pode impulsionar as abordagens relacionadas com a forma com que o conhecimento pode ser buscado, construído, classificado, recuperado e comunicado. Sendo assim, esta pesquisa oferece uma visão abrangente e atualizada sobre o estado da arte da *GenAI* e sua aplicação em



SBCs. Além disso, o mapeamento qualitativo realizado fornece uma categorização útil das contribuições recentes, facilitando a compreensão das diferentes áreas de impacto.

Com base no mapeamento deste estudo, várias direções para pesquisas futuras se apresentam. Uma área promissora é o desenvolvimento de frameworks integrados que combinem de forma mais eficaz as capacidades da GenAI com as estruturas tradicionais dos SBCs, bem como estudos empíricos sobre a eficácia dessas integrações em domínios específicos, como saúde, educação ou finanças. E o desenvolvimento de métricas específicas para avaliar o desempenho e a qualidade dos SBCs aprimorados por *GenAI* representaria uma contribuição significativa para o campo.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

REFERÊNCIAS

- Abraham, T. H. (2002). (Physio) logical circuits: The intellectual origins of the McCulloch–Pitts neural networks. *Journal of the History of the Behavioral Sciences*, 38(1).
- Asperti, A., & Tonelli, V. (2023). Comparing the latent space of generative models. *Neural Computing and Applications*, 35(4), 3155-3172.
- Barlow, H. B. (1989). Unsupervised learning. *Neural Computation*, 1(3), 295-311.
- Beheshti, A. (2023). Empowering generative AI with knowledge base 4.0: Towards linking analytical, cognitive, and generative intelligence. In *2023 IEEE International Conference on Web Services (ICWS)* (pp. 763-771). IEEE.
- Brown, T., et al. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877-1901.
- Brynjolfsson, E., Li, D., & Raymond, L. R. (2023). Generative AI at work. National Bureau of Economic Research.
- Bulfamante, D. (2023). Generative enterprise search with extensible knowledge base using AI (Doctoral Dissertation). Politecnico di Torino.



- Carter, C. K., & Kohn, R. (1994). On Gibbs sampling for state space models. *Biometrika*, 81(3), 541-553.
- Chern, I., et al. (2023). FacTool: Factuality detection in generative AI--A tool augmented framework for multi-task and multi-domain scenarios. *arXiv preprint arXiv:2307.13528*.
- Chiu, T. K. F. (2023). The impact of generative AI (GenAI) on practices, policies and research direction in education: A case of ChatGPT and Midjourney. *Interactive Learning Environments*.
- Coeurdoux, F., Dobigeon, N., & Chainais, P. (2024). Plug-and-play split Gibbs sampler: Embedding deep generative priors in Bayesian inference. *IEEE Transactions on Image Processing*.
- Creswell, A., White, T., Dumoulin, V., Arulkumaran, K., Sengupta, B., & Bharath, A. (2018). Generative adversarial networks: An overview. *IEEE Signal Processing Magazine*, 35(1), 53-65.
- Deng, S., et al. (2024). Recognizing AI responses from generative AI in knowledge-based online Q&A communities. In *Knowledge Organization for Resilience in Times of Crisis: Challenges and Opportunities* (pp. 355-362). Ergon-Verlag.
- Eloundou, T., Manning, S., Mishkin, P., & Rock, D. (2023). GPTs are GPTs: An early look at the labor market impact potential of large language models. *arXiv preprint arXiv:2303.10130*.
- Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2024). Generative AI. *Business & Information Systems Engineering*, 66(1), 111-126.
- Gelfand, A. E. (2000). Gibbs sampling. *Journal of the American Statistical Association*, 95(452), 1300-1304.
- Giarratano, J. C., & Riley, G. (1998). *Expert systems*. PWS Publishing Co.
- Kanbach, D. K., et al. (2024). The GenAI is out of the bottle: Generative artificial intelligence from a business model innovation perspective. *Review of Managerial Science*, 18(4), 1189-1220.
- Kaswan, K. S., et al. (2023). Generative AI: A review on models and applications. In *2023 International Conference on Communication, Security and Artificial Intelligence (ICCSAI)* (pp. 699-704). IEEE.
- Mukherjee, A., & Kamath, N. P. (2023). Intelligent auto-learning generative knowledge finder for proactively aiding a virtual agent. *Defensive Publications Series - Technical Disclosure Commons*.



- Kather, J. N., et al. (2022). Medical domain knowledge in domain-agnostic generative AI. *NPJ Digital Medicine*, 5(1), 90.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems*, 27.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5.
- Michel-Villarreal, R., Vilalta-Perdomo, E., Salinas-Navarro, D. E., & Thierry-Aguilera, R. (2023). Challenges and opportunities of generative AI for higher education as explained by ChatGPT. *Education Sciences*, 13(9), 856.
- Mukherjee, S., et al. (2019). Clustergan: Latent space clustering in generative adversarial networks. In *Proceedings of the AAAI Conference on Artificial Intelligence*.
- Owens, S. F., & Levary, R. R. (2006). An adaptive expert system approach for intrusion detection. *International Journal of Security and Networks*, 1(3-4), 206-217.
- Platt, M., & Platt, D. (2023). Effectiveness of generative artificial intelligence for scientific content analysis. In *2023 IEEE 17th International Conference on Application of Information and Communication Technologies (AICT)* (pp. 1-4). IEEE.
- Ren, J., et al. (2023). Knowledge base enabled semantic communication: A generative perspective. *arXiv preprint arXiv:2311.12443*.
- Robertson, J., et al. (2024). Game changers: A generative AI prompt protocol to enhance human-AI knowledge co-construction. *Business Horizons*.
- Roy, K., et al. (2024). GEAR-Up: Generative AI and external knowledge-based retrieval: Upgrading scholarly article searches for systematic reviews. In *Proceedings of the AAAI Conference on Artificial Intelligence* (pp. 23823-23825).
- Selker, T. (2023). AI for the generation and testing of ideas towards an AI supported knowledge development environment. *arXiv preprint arXiv:2307.08876*.
- Shahabikargar, M., et al. (2024). Generative AI-enabled knowledge base fine-tuning: Enhancing feature engineering for customer churn. *Preprint available at Research Square*, 1.
- Su, Y., Zhang, K., Wang, Q., & Qiu, L. (2023). Generative AI and human knowledge sharing: Evidence from a natural experiment. *SSRN Electronic Journal*.



- Vahdat, A., Kreis, K., & Kautz, J. (2021). Score-based generative modeling in latent space. *Advances in Neural Information Processing Systems*, 34, 11287-11302.
- Yan, K., et al. (2020). Chiller fault diagnosis based on VAE-enabled generative adversarial networks. *IEEE Transactions on Automation Science and Engineering*, 19(1), 387-395.
- Winterhalder, R., Bellagente, M., & Nachman, B. (2021). Latent space refinement for deep generative models. *arXiv preprint arXiv:2106.00792*.
- Wölfel, M., et al. (2023). Knowledge-based and generative-AI-driven pedagogical conversational agents: A comparative study of Grice's cooperative principles and trust. *Big Data and Cognitive Computing*, 8(1), 2.
- Zhou, Z.-H. (2021). *Machine learning*. Springer Nature.
- Zou, H., et al. (2023). Wireless multi-agent generative AI: From connected intelligence to collective intelligence. *arXiv preprint arXiv:2307.02757*.