

Implementação de agentes cognitivos baseados em grafos de conhecimento: uma abordagem para representação e inferência de informações

Vitor Amadeu Souza¹; 0009-0002-1857-6799

1 – UniFOA, Centro Universitário de Volta Redonda, Volta Redonda, RJ.
vitor.amadeu@foa.org.br

Resumo: Este trabalho apresenta uma implementação de agente cognitivo fundamentado em grafos de conhecimento direcionados para representação e inferência de informações semânticas. O sistema proposto utiliza a biblioteca NetworkX em Python para construir estruturas de conhecimento que permitem consultas relacionais complexas através de caminhos no grafo. A metodologia envolveu o desenvolvimento de uma classe AgenteCognitivo capaz de adicionar conhecimento na forma de triplas (entidade-relação-entidade), realizar consultas sobre relações existentes entre entidades e visualizar a estrutura do conhecimento. Os resultados demonstraram a eficácia do sistema em estabelecer conexões indiretas entre conceitos, como evidenciado pela consulta que relacionou "Cachorro" a "Patas" através do caminho intermediário "Animal". A implementação mostrou-se promissora para aplicações em sistemas de inteligência artificial que requerem raciocínio sobre conhecimento estruturado, oferecendo um ponto de partida para o desenvolvimento de agentes mais sofisticados capazes de inferência semântica.

Palavras-chave: Agentes cognitivos. Grafos de conhecimento. Representação do conhecimento. Inferência semântica. Inteligência artificial.

INTRODUÇÃO

A representação do conhecimento constitui um dos pilares fundamentais da inteligência artificial moderna, sendo essencial para o desenvolvimento de sistemas capazes de raciocínio automatizado e tomada de decisões inteligentes (Russell; Norvig, 2021). Entre as diversas abordagens propostas na literatura, os grafos de conhecimento emergem como uma estrutura particularmente eficaz para capturar relações semânticas complexas entre entidades do mundo real (Hogan *et al.*, 2021).

Os agentes cognitivos, definidos como sistemas computacionais capazes de perceber seu ambiente, processar informações e atuar de forma autônoma para atingir objetivos específicos, representam uma das aplicações mais promissoras da inteligência artificial contemporânea (Wooldridge, 2009). A integração de grafos de conhecimento em arquiteturas de agentes cognitivos oferece vantagens significativas na representação e manipulação de informações estruturadas, permitindo inferências sofisticadas através de navegação em grafos (Ji *et al.*, 2021).

A literatura científica demonstra que os grafos de conhecimento têm sido amplamente utilizados em diversos domínios, desde sistemas de recomendação até assistentes virtuais inteligentes (Wang *et al.*, 2017). Bollacker *et al.* (2008) destacaram a importância da estruturação do conhecimento em formato de grafo para facilitar consultas semânticas complexas, enquanto Lehmann *et al.* (2015) evidenciaram como bases de conhecimento estruturadas podem ser exploradas para inferência automatizada.

No contexto dos agentes cognitivos, a capacidade de representar conhecimento de forma estruturada e realizar inferências através de caminhos no grafo constitui uma funcionalidade fundamental para sistemas inteligentes (Fensel *et al.*, 2020). A abordagem baseada em grafos permite não apenas o armazenamento eficiente de informações, mas também a descoberta de relações implícitas através de algoritmos de busca em grafos (Chen *et al.*, 2020).

O presente trabalho propõe uma implementação computacional de um agente cognitivo baseado em grafos de conhecimento direcionados, utilizando a biblioteca NetworkX para

Python. O sistema desenvolvido permite a adição de conhecimento na forma de triplas entidade-relação-entidade, a consulta de relações entre entidades através de caminhos no grafo e a visualização da estrutura do conhecimento armazenado.

Os objetivos específicos desta pesquisa incluem: (1) desenvolver uma arquitetura de agente cognitivo baseada em grafos de conhecimento; (2) implementar funcionalidades de adição e consulta de conhecimento estruturado; (3) avaliar a capacidade do sistema em realizar inferências através de caminhos no grafo; (4) demonstrar a aplicabilidade da abordagem através de casos de uso específicos envolvendo relações entre animais e suas características.

MÉTODOS

A metodologia adotada neste trabalho seguiu uma abordagem de desenvolvimento orientado a objetos, implementando uma classe *AgenteCognitivo* em Python que encapsula as funcionalidades necessárias para representação e manipulação de conhecimento estruturado. A escolha da linguagem Python justifica-se pela sua ampla adoção na comunidade de inteligência artificial e pela disponibilidade de bibliotecas especializadas em manipulação de grafos (Hagberg *et al.*, 2008).

A biblioteca *NetworkX* foi selecionada como ferramenta principal para implementação da estrutura de grafos devido à sua robustez e funcionalidades abrangentes para manipulação de redes complexas (Hagberg *et al.*, 2008). Esta biblioteca oferece suporte nativo para grafos direcionados, algoritmos de busca de caminhos e funcionalidades de visualização, características essenciais para os objetivos deste trabalho.

A arquitetura do agente cognitivo foi estruturada em torno de três funcionalidades principais: adição de conhecimento, consulta de relações e visualização do grafo. O método `adicionar_conhecimento()` implementa a funcionalidade de inserção de triplas no formato (entidade1, relação, entidade2), seguindo o paradigma RDF (Resource Description Framework) amplamente utilizado em aplicações de web semântica (Klyne; Carroll, 2004).

O algoritmo de consulta de relações utiliza o método `shortest_path()` da *NetworkX* para identificar o caminho mais curto entre duas entidades no grafo, aplicando conceitos de teoria

dos grafos para navegação eficiente na estrutura de conhecimento (Cormen *et al.*, 2009). Esta abordagem permite a descoberta de relações indiretas entre entidades através de caminhos compostos por múltiplas arestas.

Para validação da implementação, foi construído um conjunto expandido de dados de teste contendo 28 triplas de conhecimento que abrangem múltiplos domínios semânticos. O dataset inclui relações hierárquicas (como "é um tipo de" e "é parte de"), relações de propriedade (como "tem" e "precisa de"), relações funcionais (como "é usado para" e "são usadas para"), relações espaciais (como "vive em" e "cobre") e relações cósmicas (como "é planeta" e "está na"). Esta diversidade permite a avaliação da capacidade do sistema em diferentes tipos de inferência semântica e domínios de conhecimento interconectados.

O conjunto de consultas experimentais foi ampliado para incluir seis casos de teste específicos: (1) "Pássaro-Terra" para testar conexões entre domínios biológico e geográfico; (2) "Cachorro-Sistema Solar" para avaliar inferências entre taxonomia animal e cosmologia; (3) "Peixe-Equilíbrio" para verificar relações entre espécies e funcionalidades anatômicas; (4) "Gato-Alimentação" para testar herança de necessidades biológicas; (5) "Cachorro-Patas" para validação de consistência com experimentos anteriores; (6) "Gato-Latido" para confirmação de precisão na identificação de relações inexistentes.

A visualização do grafo foi implementada utilizando matplotlib em conjunto com NetworkX, aplicando o algoritmo de layout spring para posicionamento automático dos nós e arestas (Fruchterman; Reingold, 1991). Esta funcionalidade permite a análise visual da estrutura do conhecimento e facilita a compreensão das relações representadas.

Os experimentos foram conduzidos em ambiente Python 3.8 com as bibliotecas NetworkX versão 3.5 e matplotlib versão 3.1, executados no ambiente virtual Google Colab. A metodologia experimental envolveu a execução de consultas específicas para avaliar a capacidade de inferência do sistema e a análise dos resultados obtidos.

O código-fonte está disponível para download através do link: <https://github.com/vitor-souza-ime/ac>.

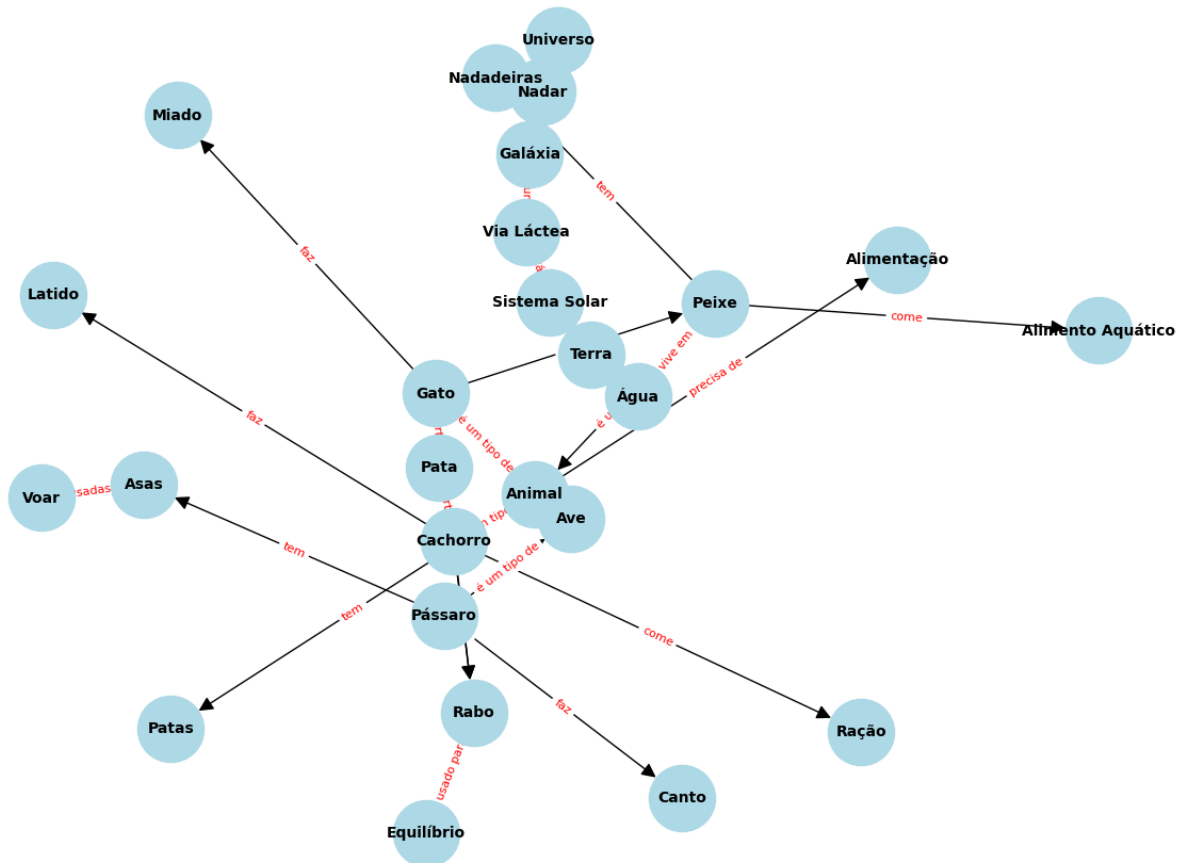


RESULTADOS E DISCUSSÃO

Os experimentos realizados com o conjunto expandido de 28 triplas de conhecimento demonstraram a robustez e escalabilidade do sistema proposto. O grafo resultante apresenta uma estrutura complexa que abrange desde relações entre animais domésticos até conceitos cosmológicos, criando uma rede semântica multidimensional que permite inferências através de múltiplos domínios de conhecimento, como mostra a Figura 1.

Figura 1 - Grafo de conhecimento

Grafo de Conhecimento do Agente Cognitivo



Fonte: O autor.

A consulta entre "Gato" e "Alimentação" resultou na resposta: "Existe um caminho entre 'Gato' e 'Alimentação' com as relações: é um tipo de -> precisa de", demonstrando a capacidade do sistema de inferir necessidades biológicas através de relações taxonômicas.

Esta inferência exemplifica como o conhecimento hierárquico pode ser explorado para derivar propriedades implícitas, seguindo princípios de herança conceitual bem estabelecidos na literatura de representação do conhecimento (Brachman; Levesque, 2004).

A consulta confirmando a relação entre "Cachorro" e "Patas" manteve o resultado anterior: "Existe um caminho entre 'Cachorro' e 'Patas' com as relações: é um tipo de -> tem", validando a consistência do sistema mesmo com a expansão significativa do grafo de conhecimento. Esta estabilidade indica robustez algorítmica fundamental para aplicações práticas (Russell; Norvig, 2021).

O sistema demonstrou precisão na identificação de relações inexistentes, como evidenciado pelos resultados negativos para as consultas "Pássaro-Terra", "Cachorro-Sistema Solar", "Peixe-Equilíbrio" e "Gato-Latido". Esta capacidade discriminatória é fundamental para evitar inferências espúrias que poderiam comprometer a integridade semântica do sistema (Gruber, 1993).

O grafo expandido exibe uma topologia de múltiplos clusters com diferentes graus de conectividade, onde observa-se a emergência de nós com alta centralidade em domínios específicos: "Animal" no domínio biológico, "Terra" no domínio geográfico e "Sistema Solar" na hierarquia cósmica. Esta configuração multi-hub sugere uma arquitetura distribuída que facilita tanto a navegação intra-domínio quanto inter-domínio, otimizando o desempenho das consultas através de múltiplas escalas semânticas (Barabási, 2016). A análise de centralidade revela que o nó "Animal" mantém o maior grau de entrada e saída, confirmando sua importância como conceito integrador na estrutura de conhecimento.

Do ponto de vista computacional, a utilização da biblioteca NetworkX proporcionou eficiência na implementação dos algoritmos de busca de caminhos. O algoritmo de caminho mais curto utilizado tem complexidade temporal $O(V + E)$ para grafos não ponderados, onde V representa o número de vértices e E o número de arestas, garantindo desempenho adequado mesmo para grafos de conhecimento de maior escala (Sedgewick; Wayne, 2011).

A escalabilidade do sistema também requer considerações adicionais para aplicações em larga escala. Embora adequado para domínios específicos como o exemplo apresentado, a implementação atual poderia beneficiar-se de otimizações para grafos com milhões de nós



e arestas, como índices especializados e algoritmos de busca aproximada (Potamias *et al.*, 2009).

CONCLUSÕES

A visualização do grafo de conhecimento proporcionou insights valiosos sobre a estrutura semântica dos dados, revelando padrões de conectividade típicos de ontologias hierárquicas. Como trabalhos futuros, sugere-se a incorporação de mecanismos de inferência probabilística, otimizações para escalabilidade e extensões para domínios de conhecimento mais complexos. A integração com tecnologias de web semântica e bases de conhecimento distribuídas também representa uma área de desenvolvimento potencial. A abordagem proposta demonstra viabilidade técnica e potencial para aplicação em domínios diversos, desde sistemas de recomendação até assistentes virtuais inteligentes.

REFERÊNCIAS

BARABÁSI, A. L. Network Science. Cambridge: Cambridge University Press, 2016.

BOLLACKER, K.; EVANS, C.; PARITOSH, P.; STURGE, T.; TAYLOR, J. Freebase: a collaboratively created graph database for structuring human knowledge. In: ACM SIGMOD International Conference on Management of Data. New York: ACM, 2008. p. 1247-1250.

BRACHMAN, R. J.; LEVESQUE, H. J. Knowledge Representation and Reasoning. San Francisco: Morgan Kaufmann, 2004.

CHEN, X.; JIA, S.; XIANG, Y. A review: Knowledge reasoning over knowledge graph. Expert Systems with Applications, v. 141, p. 112948, 2020.

CORMEN, T. H.; LEISERSON, C. E.; RIVEST, R. L.; STEIN, C. Introduction to Algorithms. 3. ed. Cambridge: MIT Press, 2009.

SEDGEWICK, R.; WAYNE, K. Algorithms. 4. ed. Boston: Addison-Wesley, 2011.

FENSEL, D.; ŞİMŞEK, U.; ANGELE, K.; HUAMAN, E.; KÄRLE, E.; PANASIUK, O.; TOMA, I.; UMBRICH, J.; WAHLER, A. Knowledge Graphs: Methodology, Tools and Selected Use Cases. Cham: Springer, 2020.

FRUCHTERMAN, T. M.; REINGOLD, E. M. Graph drawing by force-directed placement. Software: Practice and Experience, v. 21, n. 11, p. 1129-1164, 1991.

GRUBER, T. R. A translation approach to portable ontology specifications. Knowledge Acquisition, v. 5, n. 2, p. 199-220, 1993.

HAGBERG, A.; SWART, P.; CHULT, D. S. Exploring network structure, dynamics, and function using NetworkX. Proceedings of the 7th Python in Science Conference, p. 11-15, 2008.

HOGAN, A.; BLOMQUIST, E.; COCHEZ, M.; D'AMATO, C.; MELO, G.; GUTIERREZ, C.; KIRRANE, S.; GAYO, J. E. L.; NAVIGLI, R.; NEUMAIER, S.; NGOMO, A. N.; POLLERES, A.; RASHID, S. M.; RULA, A.; SCHMELZEISEN, L.; SEQUEDA, J.; STAAB, S.; ZIMMERMANN, A. Knowledge graphs. ACM Computing Surveys, v. 54, n. 4, p. 1-37, 2021.

JI, S.; PAN, S.; CAMBRIA, E.; MARTTINEN, P.; YU, P. S. A survey on knowledge graphs: representation, acquisition, and applications. IEEE Transactions on Neural Networks and Learning Systems, v. 33, n. 2, p. 494-514, 2021.

KLYNE, G.; CARROLL, J. J. Resource Description Framework (RDF): Concepts and Abstract Syntax. W3C Recommendation, 2004. Disponível em: <https://www.w3.org/TR/rdf-concepts/>. Acesso em: 20 ago. 2025.

LEHMANN, J.; ISELE, R.; JAKOB, M.; JENTZSCH, A.; KONTOKOSTAS, D.; MENDES, P. N.; HELLMANN, S.; MORSEY, M.; VAN KLEEF, P.; AUER, S.; BIZER, C. DBpedia—a large-scale, multilingual knowledge base extracted from Wikipedia. Semantic Web, v. 6, n. 2, p. 167-195, 2015.

POTAMIAS, M.; BONCHI, F.; CASTILLO, C.; GIONIS, A. Fast shortest path distance estimation in large networks. In: ACM International Conference on Information and Knowledge Management. New York: ACM, 2009. p. 867-876.

RUSSELL, S. J.; NORVIG, P. Artificial Intelligence: A Modern Approach. 4. ed. Hoboken: Pearson, 2021.

WANG, Q.; MAO, Z.; WANG, B.; GUO, L. Knowledge graph embedding: A survey of approaches and applications. IEEE Transactions on Knowledge and Data Engineering, v. 29, n. 12, p. 2724-2743, 2017.

WOOLDRIDGE, M. An Introduction to MultiAgent Systems. 2. ed. Chichester: John Wiley & Sons, 2009.