Em Análise:

Inteligência Artificial Explicável no Apoio à Análise e Avaliação de Políticas Públicas[1]

Nuno Xavier[2]

ABSTRACT

A utilização de modelos de linguagem de grande escala (LLM) na análise e avaliação de políticas públicas abre novas possibilidades de pesquisa, síntese e organização da informação. No entanto, também levanta desafios de fiabilidade, rastreabilidade e verificação das respostas produzidas. Este Em Análise apresenta resultados preliminares de uma revisão focada da literatura em curso sobre a combinação de LLM, geração apoiada por recuperação documental (RAG), grafos de conhecimento e ontologias. A análise assenta, nesta fase, em 33 artigos que se encontram atualmente em fase de análise do texto integral (*full-text screening*). A literatura analisada sugere que o recurso a fontes controladas e a conhecimento estruturado pode melhorar a verificabilidade das respostas e apoiar tarefas que exigem relacionar informação dispersa entre diferentes fontes. Em simultâneo, evidencia novos requisitos de qualidade, atualização, governação do conhecimento e supervisão humana. A avaliação destas soluções em contextos profissionais reais permanece limitada. O E-POLARIS procura contribuir para esta área comparando LLM sem recuperação externa, RAG documental e uma arquitetura que combina recuperação documental com conhecimento estruturado.

KEY WORDS

Inteligência Artificial Explicável; Modelos de Linguagem de Grande Escala (LLM); Geração Apoiada por Recuperação Documental (RAG); Grafos de Conhecimento; Ontologias; Rastreabilidade; Análise e Avaliação de Políticas Públicas; E-POLARIS.

[1] Artigo publicado no dia 19 de novembro de 2026. As opiniões expressas no documento são da responsabilidade do autor e não refletem, necessariamente, a perspetiva da Direção-Geral da Economia ou do Ministério da Economia e da Coesão Territorial.

[2] Direção-Geral da Economia, nuno.xavier@dgeconomia.pt

Introdução

A utilização de inteligência artificial generativa tem vindo a expandir as possibilidades de pesquisa, organização e síntese da informação, o que pode ser especialmente relevante para os organismos públicos que trabalham com grandes volumes de informação, relatórios, estudos, indicadores e documentação técnica. Ferramentas baseadas em inteligência artificial generativa podem reduzir o esforço necessário para localizar informação e elaborar primeiras sínteses sobre matérias complexas.

Esta capacidade é particularmente relevante para a análise e avaliação de políticas públicas, em que uma mesma questão pode obrigar a relacionar documentos produzidos em momentos diferentes, identificar medidas e objetivos, acompanhar indicadores, comparar fontes ou reconstruir os fundamentos de determinada conclusão. O problema deixa, por isso, de ser apenas encontrar informação: é necessário compreender como os diferentes elementos se relacionam e em que evidência assenta determinada afirmação.

Os modelos de linguagem de grande escala, habitualmente designados por LLM (*Large Language Models*), apresentam vantagens na interação com informação textual, pois permitem formular perguntas em linguagem natural, sintetizar documentos e identificar rapidamente conteúdos potencialmente relevantes para as análises. No entanto, uma resposta convincente do ponto de vista linguístico não é necessariamente uma resposta correta ou adequadamente fundamentada em termos de análise de políticas públicas. Os LLM não garantem, por si só, que cada afirmação possa ser relacionada com uma fonte verificável, nem que os conceitos utilizados sejam consistentes entre documentos.

Uma linha de investigação recente procura responder a estas limitações, ao combinar LLM com geração apoiada por recuperação documental (RAG), grafos de conhecimento e ontologias. Em vez de depender apenas do conhecimento incorporado no modelo de linguagem, estas arquiteturas procuram fundamentar a resposta em documentação externa e, em alguns casos, representar explicitamente as entidades, os conceitos e as relações relevantes.

No contexto deste trabalho, a expressão «Inteligência Artificial Explicável» é utilizada sobretudo numa aceção operacional, centrada na capacidade de tornar verificáveis a evidência, a proveniência e as relações utilizadas pelo sistema. Esta perspetiva não exclui outras abordagens de *Explainable* AI (XAI) orientadas para explicar componentes do funcionamento ou do raciocínio do sistema, que poderão ser consideradas no desenvolvimento do E-POLARIS quando adequadas. O foco deste Em Análise incide, contudo, nas formas de explicabilidade mais diretamente relevantes para o trabalho do analista: rastreabilidade, ligação às fontes, percursos no grafo e possibilidade de auditoria. Não se pretende, assim, abranger toda a literatura de XAI.

O presente Em Análise sintetiza os resultados preliminares de uma revisão focada da literatura em curso, realizada no âmbito do projeto E-POLARIS. A presente versão baseia-se nos 33 artigos que se encontram atualmente em fase de análise do texto integral (*full-text screening*),

sendo que a seleção final da revisão ainda não está concluída à data desta publicação. O objetivo deste documento não é, por isso, apresentar um recenseamento exaustivo da literatura científica disponível, mas retirar deste conjunto de estudos algumas conclusões úteis para compreender em que condições estas tecnologias podem acrescentar valor à análise e avaliação de políticas públicas.

A leitura transversal deste *corpus* permite destacar cinco mensagens principais: a ligação a fontes externas pode tornar as respostas mais verificáveis; os grafos podem ser úteis quando é necessário relacionar informação dispersa; a rastreabilidade da evidência é uma dimensão prática da explicabilidade; o conhecimento estruturado introduz novos requisitos de governação e manutenção deste tipo de soluções; e finalmente, continua a existir pouca evidência sobre o impacto destas soluções no trabalho quotidiano dos analistas de políticas públicas.

Tabela 1 - Da documentação à resposta verificável

Fontes documentais	Recuperação de informação	Ontologia e grafo de conhecimento	LLM / RAG	Resposta verificável
Validação humana ao longo do processo Proveniência e rastreabilidade: fonte → passagem → relação → resposta				

Fonte: elaboração própria.

1. Ligar os modelos de linguagem a fontes externas pode tornar as respostas mais verificáveis

Uma primeira tendência identificada na literatura consiste em reduzir a dependência do conhecimento incorporado no próprio modelo de linguagem, ligando-o a fontes documentais externas. Numa solução RAG, o sistema começa por procurar informação relevante num conjunto de documentos e disponibiliza ao modelo as passagens recuperadas para apoiar a geração da resposta. Deste modo, em vez de responder apenas com base nos padrões aprendidos durante o treino, o modelo passa a trabalhar sobre documentação selecionada para a tarefa.

A evolução deste princípio tem conduzido à combinação do RAG com grafos de conhecimento e ontologias. Nestes casos, o sistema pode recuperar não apenas fragmentos de texto semelhantes à pergunta, mas também entidades e relações previamente representadas. Uma política pública em análise pode, por exemplo, ser relacionada com os respetivos objetivos, medidas, indicadores, entidades responsáveis ou fontes documentais.

Os estudos analisados apresentam indícios de que este tipo de estruturação pode melhorar a sustentação factual das respostas em determinados contextos. Os resultados quantitativos, porém, variam consoante o domínio e a arquitetura utilizada e não devem ser interpretados como indicadores gerais de desempenho.

Num estudo aplicado à documentação sobre políticas do setor da energia elétrica, Wang et al. (2025) reportam uma exatidão factual de 90,01% para a arquitetura SPR-RAG, superior à das

abordagens de referência testadas no mesmo trabalho. Noutro domínio, Xu et al. (2025) observaram, numa aplicação de saúde pública, uma redução superior a 40% das alucinações relativamente aos modelos de referência avaliados. Lee et al. (2026), num sistema de resposta a perguntas geográficas baseado em dados públicos, registam uma taxa de alucinação de 60,0% com LLM sem recuperação, 25,7% com RAG denso, 17,1% com GraphRAG e 5,7% com uma arquitetura em que o raciocínio é realizado no próprio grafo. Estes números ilustram resultados obtidos em experiências específicas e não constituem uma medida universal da eficácia do RAG ou dos grafos de conhecimento.

A principal conclusão é, portanto, mais prudente: a utilização de fontes controladas e de conhecimento estruturado cria condições para reduzir alguns riscos associados à geração exclusivamente probabilística e, sobretudo, facilita a verificação da informação apresentada. Para a Administração Pública, uma ferramenta que indique claramente a documentação utilizada e permita ao analista identificar e consultar rapidamente as fontes tem um valor diferente do de uma ferramenta que apenas apresente uma resposta final, mesmo quando ambas produzem textos semelhantes.

2. Os grafos de conhecimento podem acrescentar valor quando é necessário relacionar informação dispersa

Nem todas as perguntas colocadas durante uma análise de políticas públicas exigem uma arquitetura tecnológica complexa. Quando o objetivo do analista é apenas localizar uma definição, identificar uma disposição concreta ou resumir um único documento, uma solução simples de recuperação documental pode ser suficiente. O problema torna-se mais exigente quando a resposta depende de informação distribuída por documentos de fontes diversas ou da compreensão das relações entre vários conceitos.

É neste segundo tipo de situações que os grafos de conhecimento podem apresentar maior interesse. Um grafo representa entidades e as relações entre elas. Em vez de tratar cada fragmento documental como uma unidade independente, permite, por exemplo, associar uma medida a um objetivo, um objetivo a um indicador ou uma entidade a uma determinada competência. Esta representação permite percorrer relações em vários passos e recuperar informação que não depende apenas da semelhança textual entre a pergunta e uma passagem do documento.

Alguns estudos do *corpus* analisado identificam vantagens das abordagens baseadas em grafos em tarefas que exigem relacionar informação distribuída por várias fontes ou responder a perguntas que dependem de relações entre entidades. Sun e Luo (2025) integram um grafo de conhecimento num processo de RAG aplicado a políticas florestais. Han et al. (2025) constroem um grafo de políticas de promoção do investimento e integram GraphRAG para responder a perguntas, enquanto Ghizzota et al. (2025) aplicam GraphRAG ao Código dos Contratos Públicos italiano. Estes exemplos sugerem que a utilidade do grafo tende a aumentar

quando a pergunta exige preservar relações que, de outro modo, se podem perder numa recuperação baseada apenas em fragmentos de texto.

No entanto, a evidência disponível não permite concluir que estas arquiteturas sejam superiores ao RAG documental em qualquer circunstância. A conclusão mais útil para a Administração Pública é que a complexidade da solução deve acompanhar a complexidade do problema. Um sistema baseado em ontologias e grafos implica custos adicionais de desenvolvimento, modelação, validação e manutenção; se uma questão puder ser resolvida adequadamente através de uma pesquisa documental mais simples, essa solução poderá ser preferível.

A introdução de uma camada semântica torna-se mais justificável quando as relações entre diferentes elementos constituem uma parte essencial do problema analítico. Esta abordagem evita que a adoção de uma solução tecnológica em concreto seja determinada apenas pela sofisticação da ferramenta disponível e permite focar a atenção na questão fundamental: que ganho concreto resulta da representação explícita das relações existentes na informação?

3. Explicabilidade inclui conseguir reconstruir a ligação à evidência

No debate sobre inteligência artificial, a explicabilidade é frequentemente associada à compreensão do funcionamento interno dos modelos. Porém, nas aplicações de apoio à análise de políticas públicas, a literatura analisada aponta para uma dimensão mais operacional: a capacidade de perceber a origem de determinada afirmação e a evidência que a sustenta. Esta forma de explicabilidade depende da proveniência e da rastreabilidade.

Uma resposta é mais verificável quando o utilizador consegue identificar o documento de origem, a passagem utilizada e, sempre que aplicável, as relações que contribuíram para a sua construção. No *corpus* analisado, esta preocupação está presente em arquiteturas que procuram ligar respostas a conhecimento estruturado e em abordagens neuro-simbólicas que explicitam as regras e relações utilizadas no raciocínio, incluindo aplicações dirigidas à Administração Pública e à deteção de conflitos entre políticas (Ghizzota, 2026; Hmimou et al., 2026).

Importa, contudo, distinguir rastreabilidade de validade substantiva da evidência. A possibilidade de relacionar uma afirmação com a respetiva fonte permite verificar a sua proveniência, mas não garante que essa afirmação seja metodologicamente robusta, que resulte de uma relação causal adequadamente identificada ou que represente um consenso na literatura. Na análise e avaliação de políticas públicas, a rastreabilidade deve, por isso, ser complementada pela apreciação da qualidade, relevância e natureza da evidência, mantendo-se essa avaliação sob responsabilidade do analista.

A rastreabilidade torna-se especialmente importante quando um sistema é utilizado para apoiar trabalho técnico sujeito a revisão por terceiros. O utilizador não deve ter de confiar na resposta apenas porque esta parece convincente e bem escrita: deve poder consultar a fonte,

confirmar a interpretação e ter a capacidade de intervir, corrigindo o sistema quando necessário.

A literatura sugere, assim, uma distinção útil entre duas dimensões complementares da explicabilidade: a primeira procura explicar como o modelo produziu internamente determinado resultado, e a segunda procura explicar com base em que evidência documental esse resultado pode ser sustentado. Para muitas aplicações na Administração Pública, esta segunda dimensão poderá ser a mais diretamente útil.

O objetivo não é necessariamente tornar transparente toda a complexidade matemática de um modelo de linguagem, mas sim permitir que um analista consiga reconstruir uma cadeia simples entre pergunta, informação recuperada, fonte, relações identificadas e resposta produzida. Esta lógica pode aumentar a capacidade de escrutínio e facilitar a revisão do trabalho realizado com apoio de IA.

4. O conhecimento estruturado não elimina os riscos: cria novos requisitos de qualidade, atualização e supervisão

Uma das conclusões mais importantes da literatura analisada é a de que a utilização de grafos e ontologias não resolve automaticamente o problema da fiabilidade das respostas do texto gerado. Quando um sistema depende de um grafo de conhecimento, a qualidade das respostas passa também a depender da qualidade desse grafo.

Se determinada fonte estiver ausente, se uma relação for incorretamente extraída ou se uma alteração posterior não tiver sido incorporada, o sistema poderá produzir uma resposta incompleta ou inadequada, mesmo que o modelo de linguagem funcione corretamente. A qualidade, a correção e a atualização do grafo passam, portanto, a fazer parte do próprio problema analítico.

Este risco é particularmente relevante quando o próprio LLM é utilizado para extrair automaticamente entidades e relações dos documentos, pois a automatização pode reduzir o esforço necessário para construir o grafo, mas pode também introduzir erros na fase anterior à geração da resposta. Os trabalhos de Sun e Luo (2025) e Han et al. (2025), aplicados a documentação de políticas públicas, ilustram tanto o potencial da extração assistida por modelos como a necessidade de mecanismos de validação, correção e controlo da qualidade.

A validação humana aparece, por isso, de forma recorrente neste *corpus* de artigos. Em diferentes arquiteturas, os utilizadores ou especialistas de domínio intervêm para rever relações, confirmar regras ou rejeitar informação que não deve ser integrada na base de conhecimento. Contudo, a literatura não oferece uma solução única para determinar quanto trabalho de validação humana é necessário. Se, por um lado, uma revisão humana integral de tudo o que o sistema produz pode eliminar parte das vantagens da automatização, por outro, uma supervisão humana demasiado limitada pode permitir que os erros passem a integrar o próprio conhecimento utilizado pelo sistema e, dessa forma, sejam perpetuados.

Além do tema da qualidade inicial da informação gerada, existe um segundo problema: a evolução temporal do conhecimento. As políticas, a legislação, os programas, os indicadores e as estruturas institucionais mudam ao longo do tempo, e um sistema concebido para apoiar a análise de políticas públicas não pode pressupor que o conhecimento permanece estático. Liu et al. (2025), por exemplo, incorporam versionamento e relações espaçotemporais num grafo de políticas de renovação urbana, mostrando que a evolução do conhecimento tem de ser tratada explicitamente na própria arquitetura.

No *corpus* analisado, a representação de versões, alterações ou relações temporais está presente em algumas soluções, mas a atualização dinâmica das bases de conhecimento continua largamente dependente de processos semi-automatizados e de validação humana. Assim, a adoção de grafos de conhecimento não deve ser vista apenas como um projeto tecnológico inicial: implica também um processo continuado de governação, atualização e controlo da qualidade do conhecimento.

5. A avaliação técnica é necessária, mas ainda sabemos relativamente pouco sobre o impacto no trabalho efetivo dos analistas

A maioria dos estudos identificados avalia os sistemas através de métricas de precisão, correção factual, recuperação de informação ou qualidade das respostas. Estas medidas são importantes, mas não respondem, por si só, a uma questão fundamental para a Administração Pública: a ferramenta melhora efetivamente o trabalho dos profissionais que a utilizam?

A análise do *corpus* de literatura indica que são ainda relativamente escassos os trabalhos que avaliam estas soluções durante períodos prolongados, integradas em processos reais de trabalho e com utilizadores profissionais. Um dos exemplos mais próximos neste contexto é o estudo de Ghizzota et al. (2025), que testou uma aplicação de GraphRAG sobre o Código dos Contratos Públicos italiano com especialistas do domínio. O sistema obteve 82,19 pontos na Escala de Usabilidade do Sistema (SUS) e um *Net Promoter Score* (NPS) de 25. Os resultados sugerem boa facilidade de utilização, mas mostram também que a aceitação de uma ferramenta para uso profissional depende de requisitos mais exigentes do que apenas a usabilidade, nomeadamente a qualidade e a precisão da informação apresentada.

Uma avaliação adequada deverá, por isso, considerar simultaneamente várias dimensões: correção factual, qualidade e precisão das referências, possibilidade de verificar a informação, tempo necessário para realizar uma tarefa, facilidade de utilização, confiança do utilizador, adequação ao processo de trabalho e valor acrescentado face ao método anteriormente utilizado pelo profissional.

Esta dimensão constitui uma das principais oportunidades de investigação futura: mais do que desenvolver sistemas cada vez mais complexos, importa testar se essa complexidade gera ganhos observáveis para os profissionais que deles necessitam.

Tabela 2 - Síntese das principais mensagens da literatura

O que a literatura sugere	Potencial benefício	Principal cautela
RAG sobre fontes controladas	Maior sustentação documental e possibilidade de regressar às fontes	O resultado depende da qualidade da recuperação e do corpus documental
Grafos de conhecimento e ontologias	Relacionar informação dispersa e tornar explícitas entidades e relações	Custos de construção, erros de extração e necessidade de manutenção
Proveniência e rastreabilidade	Maior capacidade de verificação, revisão e auditoria	A rastreabilidade não garante, por si só, a validade substantiva da evidência
Validação humana	Detetar e corrigir relações ou interpretações incorretas	O esforço de revisão pode reduzir os ganhos de automatização
Avaliação com utilizadores	Medir utilidade efetiva e adequação ao processo de trabalho	A evidência operacional em contextos públicos continua limitada

Fonte: elaboração própria com base na revisão focada da literatura em curso.

6. Implicações para a análise e avaliação de políticas públicas

Os resultados da literatura permitem retirar algumas ilações para os organismos públicos que pretendam experimentar soluções deste tipo.

A primeira ilação é a de que se deve começar pelo problema analítico, e não pela tecnologia, ou seja, a questão inicial não deverá ser «como utilizar um grafo de conhecimento?», mas antes «que tarefa não está a ser adequadamente resolvida pelos instrumentos atuais?». Em alguns casos, a resposta poderá ser uma melhoria da pesquisa documental, noutros, poderá justificar-se uma estrutura capaz de relacionar diferentes fontes e conceitos.

A segunda ilação é a da adoção de uma lógica incremental: uma sequência possível passa por começar com um conjunto controlado de documentos e uma solução de RAG documental, avaliar os resultados e só depois acrescentar estrutura semântica, caso sejam identificadas limitações que o justifiquem.

A terceira ilação é a de considerar a rastreabilidade como um requisito de conceção: sempre que o sistema produza uma afirmação relevante, o utilizador deverá poder identificar a informação utilizada para a sustentar e distinguir o conteúdo documental das sínteses ou inferências produzidas pelo sistema. A adoção destas soluções deve ainda considerar, desde a conceção, os requisitos de governação, proteção de dados e enquadramento regulamentar aplicáveis ao caso de uso e ao tipo de informação tratado, nomeadamente no quadro das obrigações e princípios estabelecidos pelo Regulamento Europeu da Inteligência Artificial (Osório de Barros, 2024).

A quarta ilação é a de preservar uma distinção clara entre apoio à análise, inferência causal e decisão. Estas ferramentas podem apoiar a localização de informação, a organização de documentos, a identificação de relações, a comparação de fontes e a preparação de sínteses, mas não substituem os métodos necessários para estabelecer relações causais, avaliar impactos, ponderar opções ou assumir a responsabilidade pelas conclusões e decisões finais. Um exemplo interessante desta complementaridade é apresentado por Xie et al. (2026), que combina a síntese de evidência textual através de RAG e de um grafo de conhecimento com o

posterior teste quantitativo de hipóteses em modelos de simulação aplicados à política de qualidade do ar.

Finalmente, a avaliação deve incluir profissionais reais e tarefas próximas das que estes realizam habitualmente. Medir apenas a qualidade técnica de uma resposta é insuficiente se não for possível demonstrar que a ferramenta reduz o esforço, melhora a qualidade do trabalho ou facilita a verificação dos resultados.

7. O E-POLARIS como aplicação desta oportunidade de investigação

É neste contexto que se insere o E-POLARIS - *Explainable, Ontology-Driven Expert System for Public Policy Analysis*. Trata-se de um projeto em desenvolvimento que procura investigar em que condições a combinação de ontologias, grafos de conhecimento, recuperação documental e modelos de linguagem pode acrescentar valor à análise e avaliação de políticas públicas. Assenta num princípio simples: a utilização de IA neste contexto deve facilitar não apenas a obtenção de respostas, mas também a possibilidade de verificar como essas respostas se relacionam com a evidência disponível.

O desenvolvimento do projeto está a aprofundar três dimensões relacionadas com as lacunas identificadas na literatura: a primeira diz respeito à estruturação e à governação do conhecimento, incluindo a evolução das fontes e das relações representadas; a segunda centra-se na explicabilidade e rastreabilidade, procurando aproximar cada afirmação produzida da documentação que a sustenta e explorar, quando adequado, a exposição das relações e percursos no grafo ou outros mecanismos de explicação compatíveis com a arquitetura; e a terceira incide na avaliação comparativa da solução.

O objetivo não é demonstrar que uma arquitetura baseada em grafos é, por definição, superior a soluções mais simples. Pretende-se, antes, comparar diferentes abordagens perante as mesmas tarefas: utilização de um LLM sem recuperação externa, utilização de um RAG documental e, finalmente, o E-POLARIS, combinando recuperação documental com conhecimento estruturado.

A avaliação deverá considerar não apenas a correção factual e a qualidade das fontes apresentadas, mas também a sustentação nas fontes, a rastreabilidade, o tempo necessário e a utilidade percebida pelos utilizadores. A pergunta central passa, assim, a ser: em que situações a introdução de ontologias e grafos de conhecimento produz ganhos suficientes para justificar a sua maior complexidade?

Responder empiricamente a esta questão poderá ser mais útil para a adoção destas tecnologias na Administração Pública do que assumir antecipadamente que soluções tecnologicamente mais sofisticadas serão necessariamente melhores.

8. Conclusão

A inteligência artificial generativa cria oportunidades relevantes para atividades intensivas em informação, mas a sua utilização na análise e avaliação de políticas públicas coloca exigências adicionais no que toca ao rigor e verificabilidade dos resultados apresentados.

A literatura analisada indica que a combinação de modelos de linguagem com recuperação documental, ontologias e grafos de conhecimento pode melhorar a sustentação das respostas e facilitar tarefas que dependem da relação entre informação distribuída por várias fontes. Ao mesmo tempo, mostra que a estruturação do conhecimento não elimina os riscos por si só, pois a qualidade das fontes, a extração correta das relações, a atualização das bases de conhecimento e a validação humana continuam a ser determinantes.

Também permanece limitada a evidência sobre o impacto destas soluções no trabalho efetivo dos profissionais. Saber se uma arquitetura produz uma resposta tecnicamente melhor não é suficiente: importa determinar se reduz o tempo de análise, melhora a qualidade da informação utilizada e facilita a verificação das conclusões.

Para a Administração Pública, a abordagem mais prudente parece ser a experimentação gradual, começando por tarefas e conjuntos documentais bem delimitados e comparando soluções de complexidade crescente. O projeto E-POLARIS pretende contribuir para esta linha de ação, testando uma arquitetura baseada em conhecimento estruturado em comparação com alternativas mais simples. O seu contributo dependerá, em última análise, de demonstrar que a complexidade adicional produz ganhos concretos de qualidade, rastreabilidade e utilidade para o trabalho analítico.

Em síntese

- Ligar LLM a fontes controladas pode melhorar a verificabilidade, mas os ganhos dependem do domínio e da arquitetura.
- Grafos e ontologias são mais justificáveis quando a tarefa exige relacionar informação distribuída por várias fontes.
- Rastreabilidade, atualização do conhecimento e validação humana devem ser tratadas como requisitos de conceção do sistema.
- A complexidade adicional só se justifica se produzir ganhos observáveis de qualidade, tempo e utilidade para os analistas.

9. Referências

Ghizzota, E. (2026). Large Language Models and Knowledge Graphs Synergy to Support the Public Administration. *Lecture Notes in Computer Science, 15832*, (pp. 225-234). Obtido de https://doi.org/10.1007/978-3-031-99554-5_37

Ghizzota, E., Siciliani, L., Basile, P., & Semeraro, G. (2025). Enhancing Public Contract Code analysis with Graph Retrieval-Augmented Generation. *CEUR Workshop Proceedings, 4020*, (pp. 27-35).

Han, C., Li, Y., & Tang, X. (2025). DocPolicyKG: A Lightweight LLM-Based Framework for Knowledge Graph Construction from Chinese Policy Documents. *Proceedings of the 34th ACM International Conference on Information and Knowledge Management*, (pp. 4753–4757). Obtido de https://doi.org/10.1145/3746252.3760904

Hmimou, A., Jovanovic, P., & Romero, O. (2026). Implicit to Explicit: A Pipeline for Inter-Policy Conflict Detection in Data Ecosystems Governance. *IEEE 42nd International Conference on Data Engineering Workshops (ICDEW), Montreal, QC, Canada*, (pp. 197-203). Obtido de https://doi.org/10.1109/ICDEW71238.2026.00025

Lee, C.-S., Park, D.-S., Choi, J.-M., & Chang, H.-J. (2026). GNLM: A Graph-Native Language Model With Road Name Address-Based Spatial Reasoning for Geographic Question Answering. *IEEE Access, vol. 14*, pp. 78339-78361. Obtido de https://doi.org/10.1109/ACCESS.2026.3695549

Liu, W., Gu, J., Li, M., Guo, W., Wang, Y., Wang, S., . . . Zhang, Y. (2025). Construction and Dynamic Evolution of an Urban Renewal Policy Knowledge Graph Integrating Multi-Source Data. *8th International Conference on Algorithms, Computing and Artificial Intelligence (ACAI)*, (pp. 1-8). Nanjing, China. Obtido de 10.1109/ACAI68217.2025.11406380

Osório de Barros, G. (2024). Regulamentação da Inteligência Artificial na União Europeia: Uma análise do AI Act. *Gabinete de Estratégia e Estudo: Em Análise*.

Sun, J., & Luo, Z. (2025). ForPKG: A Framework for Constructing Forestry Policy Knowledge Graph and Application Analysis. *International Joint Conference on Neural Networks (IJCNN), Rome, Italy*, (pp. 1-8). Obtido de https://doi.org/10.1109/IJCNN64981.2025.11228178

Wang, Y., Xu, T., & Zhu, Y. (2025). SPR-RAG: Semantic Parsing Retriever-Enhanced Question Answering for Power Policy. *Algorithms 18 no. 12*, p. 802. Obtido de https://doi.org/10.3390/a18120802

Xie, X., Kassem, M., Cabaneros, S. M., & Pan, H. (2026). Synthesising textual- and model-based evidence for proactive urban policymaking: A case in air quality management. *Journal of Environmental Management 404*, p. 129470. doi:https://doi.org/10.1016/j.jenvman.2026.129470

Xu, S., Yan, Z., Dai, C., & Wu, F. (2025). MEGA-RAG: a retrieval-augmented generation framework with multi-evidence guided answer refinement for mitigating hallucinations of LLMs in public health. *Frontiers in Public Health Volume 13*. Obtido de https://doi.org/10.3389/fpubh.2025.1635381