

De la web semántica a la web sintética: los grafos de conocimiento como infraestructura de la IA generativa

From the semantic web to the synthetic web: Knowledge graphs as infrastructure for generative AI

Juan-Antonio Pastor-Sánchez

Pastor-Sánchez, Juan-Antonio (2025). “De la web semántica a la web sintética: los grafos de conocimiento como infraestructura de la IA generativa”. *Anuario ThinkEPI*, v. 19, e19a30.

<https://doi.org/10.3145/thinkepi.2025.e19a30>

Publicado en *IweTel* el 28 de noviembre de 2025

Juan-Antonio Pastor-Sánchez

<https://www.directorioexit.info/ficha1964>

<https://orcid.org/0000-0002-1677-1059>

Universidad de Murcia

pastor@um.es



Resumen: La web semántica nació con la idea de publicar datos estructurados e interconectados. Su adopción fue limitada por barreras técnicas, falta de herramientas accesibles y escasa cultura de datos abiertos. Aun así, proyectos como *DBpedia* y, sobre todo, *Wikidata* demostraron que los grafos de conocimiento pueden sostener aplicaciones fiables y útiles en dominios específicos. La irrupción de la IA generativa basada en LLM ha cambiado el panorama. Estos sistemas generan respuestas fluidas, pero también alucinaciones y falta de trazabilidad. Además, su conocimiento es implícito y difícil de actualizar. Esto ha impulsado el interés por integrar IA generativa con grafos de conocimiento para aportar precisión, coherencia y verificación. Por este motivo surgen enfoques híbridos que combinan LLM con grafos de conocimiento: técnicas RAG que consultan grafos RDF, generación de tripletes, asistencia en ingeniería del conocimiento, razonamiento restringido por grafos y entrenamiento con datos estructurados. En este contexto, *Wikidata* se ha consolidado como infraestructura clave para una “web sintética” en la que a través de su capacidad de representación de datos estructurados y su potencial para la verificación factual permiten construir sistemas más fiables de IA generativa.

Palabras clave: Grafos de conocimiento; IA generativa; LLM; Web semántica; Web sintética; Wikidata.

Abstract: The semantic web was born with the idea of publishing structured and interconnected data. Its adoption was limited by technical barriers, a lack of accessible tools and a weak culture of open data. Even so, projects like *DBpedia* and, above all, *Wikidata* demonstrated that knowledge graphs can support reliable and useful applications in specific domains. The emergence of generative AI based on LLMs has changed the landscape. These systems produce fluent responses, but also hallucinations and a lack of traceability. In addition, their knowledge is implicit and difficult to update. This has increased interest in integrating generative AI with knowledge graphs to provide precision, coherence and verification. For this reason, hybrid approaches combining LLMs with knowledge graphs are emerging: RAG techniques that query RDF graphs, triple generation, assistance in knowledge engineering, graph-constrained reasoning and training

with structured data. In this context, *Wikidata* has become a key infrastructure for a “synthetic web”, where its capacity to represent structured data and its potential for factual verification make it possible to build more reliable generative AI systems.

Keywords: Knowledge graphs; Generative AI; LLMs; Semantic web; Synthetic web; *Wikidata*.

1. Introducción

Casi desde la aparición de la Web se desarrolló la propuesta de web semántica para crear una infraestructura que permitiese publicar datos estructurados e interconectados. La semántica de las propiedades utilizadas para definir relaciones entre recursos o asignar valores a atributos resulta esencial para la interoperabilidad de los datos. Metafóricamente hablando (o no tanto) se podría vislumbrar en esta propuesta un medio para crear infinitos e inmensos grafos de conocimiento procesables por máquina. Se generaron grandes expectativas, algunas de las cuales no llegaron a materializarse. Otras en cambio, con el paso de los años y el desarrollo de herramientas, han cristalizado en ciertos instrumentos tecnológicos. Siendo sinceros, estas soluciones suelen circunscribirse a entornos muy concretos. El modelo de datos RDF, las ontologías *OWL*, *SKOS*, *SPARQL* son algunos ejemplos de ello.

Proyectos como *DBpedia*, y algunos años más tarde *Wikidata*, son el producto de la aplicación de conceptos y tecnologías de la web semántica. Otro tanto sucede con herramientas informáticas que generalmente se concreta en bases de datos de grafos o en sistemas para definir ontologías *OWL* y mantener *datasets* RDF. No puede hablarse de fracaso, sino más bien de concretar un nicho de aplicación en el que el software resulta eficiente, útil y ventajoso frente a alternativas de mayor recorrido y tradición.

En este contexto, el uso generalizado de los LLM (*Large Language Models*) y las herramientas de IA generativa basadas en procesos conversacionales plantea tensiones y oportunidades: ¿qué papel ocupan los grafos de conocimiento y la web de datos en esta nueva realidad? ¿Se vuelven obsoletos frente a la “web sintética”, donde los modelos generativos crean respuestas directamente sin necesidad de plantear el proceso de búsqueda de información iterativo? Más bien es posible que nos encontremos ante un escenario de convergencia híbrida en el que los datos enlazados, la web semántica y los LLM puedan complementarse mutuamente. En este sentido los grafos de conocimiento pueden actuar como herramientas para verificar la fiabilidad de la IA generativa o como un resultado formalizado de la misma.

2. La promesa no cumplida (o en suspenso) de la web semántica

Para entender la situación actual conviene remontarnos a los fundamentos y los bloqueos históricos de la web semántica. La idea de modelar los datos formalmente mediante un modelo de datos basado en tripletas (RDF) y ontologías (OWL) ha tenido una adopción lenta. Incluso es posible encontrar que muchos repositorios académicos, bibliotecas o instituciones culturales han seguido utilizando modelos de descripción (MARC, Dublin Core, esquemas locales) menos expresivos o limitados a ofrecer descripciones simples sin explotar la identificación de elementos y la definición de relaciones entre ellos. Es frecuente encontrar en la descripción de un repositorio que el autor de un recurso se exprese mediante un término de metadatos (por ejemplo, dcterms:creator) con un valor en vez de definir una relación con otro recurso que represente a dicho autor.

Esto puede deberse a barreras técnicas como la ausencia de herramientas estándares y abiertas sencillas de utilizar y mantener o la carencia de conocimientos profundos y avanzados en las tecnologías semánticas. No hay que olvidar tampoco el coste de adaptación: el paradigma imperante actualmente se fundamenta en la adopción generalizada del modelo relacional de bases de datos. Además, existe una ausencia de una cultura organizacional respecto a la publicación y mantenimiento de los datos abiertos.

Muchos conjuntos de datos abiertos RDF no cumplen con ciertas condiciones de interconectividad y calidad, lo que limita su uso real como recursos reutilizables.

Todo lo anterior ha provocado que no se hayan cumplido ciertas expectativas con la disponibilidad de aplicaciones visibles al gran público. Pese a todo, la apuesta semántica no es irrelevante: los grafos y los datos enlazados siguen ofreciendo una infraestructura latente sobre la que los sistemas de búsqueda ofrecerían respuestas más confiables a partir de conocimiento estructurado.

3. Los LLM: poderes, debilidades y brechas

Los modelos de lenguaje (como *GPT*, *LLaMA*, *Claude*, etc.) han transformado nuestra interacción con el conocimiento: los usuarios lanzan preguntas en lenguaje natural y se generan respuestas textuales aparentemente completas. Pero es necesario considerar algunos matices relevantes al respecto.

Los modelos “almacenan” conocimiento durante su entrenamiento de forma distribuida. Para ello se usan estructuras de vectores internos que no siempre representan de forma explícita de hechos concretos. Estas estructuras no siempre pueden verificarse o corregirse y son la fuente de errores que provocan respuestas incompletas o totalmente fabricadas (alucinaciones). Es decir, las aplicaciones que usan estos modelos pueden inventar afirmaciones que suenan plausibles, pero sin un respaldo fáctico real.

Por otro lado, existe una clara ausencia de trazabilidad. Una respuesta generada puede parecer convincente, pero no siempre se puede identificar la fuente o fuentes de donde proceden los fragmentos que se han generado en la respuesta. También es importante considerar que la incorporación de conocimiento emergente y actualizado precisa de mecanismos adicionales para re-entrenar los modelos o aplicar técnicas adicionales de actualización a partir de fuentes externas al modelo ya entrenado.

Pese a estos inconvenientes los LLM tienen ventajas innegables: procesamiento de lenguaje profundo, generalización de contexto, generación fluida, flexibilidad frente a consultas no previstas. Pero resultaría imprescindible que las respuestas generadas puedan vincularse a fuentes verificables para comprobar la fiabilidad de las respuestas de los sistemas de IA generativa. En este punto los grafos de conocimiento y los datos enlazados pueden resultar útiles.

4. Hibridando IA generativa y grafos de conocimiento: técnicas emergentes

En la actualidad existen trabajos que exploran cómo combinar LLM y tecnologías de la web semántica para mejorar la fiabilidad de las respuestas. Se trata de propuestas en las que se contempla la complementariedad entre el conocimiento implícito de los LLM y el explícito de los grafos de conocimiento (**Pan et al.**, 2023; **Cai et al.**, 2025). Algunas de estas estrategias más relevantes serían las siguientes:

Integración de grafos en procesos que usan técnicas RAG (Retrieval Augmented Generation). RAG es una técnica híbrida que combina LLM con sistemas de recuperación de información. Su objetivo es

que el modelo no dependa solo de su memoria interna, sino que pueda consultar fuentes externas en tiempo real antes de generar una respuesta. Ante una pregunta, primero se recupera información externa (documentos, fragmentos, bases de datos) y luego se usa ese contexto para alimentar al modelo generativo. Es aquí donde se podrían aplicar grafos de conocimiento. Por ejemplo, se podrían realizar consultas *SPARQL* en un grafo RDF para obtener un subgrafo relevante y utilizar los resultados para integrarlos en las respuestas que genere el sistema.

Generación semántica para extracción de triplets RDF. Otro enfoque es hacer que los LLM generen directamente triplets. Proyectos como *LLM4Schema.org* han experimentado en generar marcado *Schema.org* a partir de descripciones en texto natural (**Dang et al.**, 2025). También es posible usar técnica de parseado semántico para traducir preguntas efectuadas en lenguaje natural a consultas *SPARQL* realizadas en *Wikidata Query Service* (**Xu et al.**, 2023) y obteniendo una menor tasa de errores de alucinación. Con este mismo enfoque durante el *KBC Challenge 2023 (Knowledge Base Completion)*, se usaron LLMs para predecir objetos de triplets (relaciones) dados un sujeto y una relación y vinculándolos a entidades de *Wikidata*. También es posible combinar técnicas de minería de grafos y LLM para reorganizar la taxonomía de *Wikidata* (fusionar clases, eliminar relaciones problemáticas, etc).

Aplicación de los LLM como asistentes en la ingeniería del conocimiento. Esto implica el uso de los modelos LLM para asistir en tareas de curación, mapeo, validación, deduplicación, sugerencia de ontologías, detección de anomalías y enriquecimiento semántico. El objeto de esta asistencia puede centrarse en los procesos de ingeniería del conocimiento para la elaboración, extensión, alienamiento, fusión y verificación de ontologías (**Zhang et al.**, 2023; **Garijo et al.**, 2025). Incluso los LLM también podrían asistir en la generación o sugerencia de nuevos axiomas OWL o relaciones entre elementos (**Saeedizade; Blomqvist**, 2024).

Entrenamiento de modelos con datos estructurados. Se trataría del uso de datos estructurados explícitos para interiorizar en el seno del LLM los hechos de un modo más efectivo desde su creación. Se trata de mejorar las respuestas de los sistemas a partir del procesamiento de grafos de conocimiento limitando el problema que suponen las alucinaciones (**Moiseev et al.**, 2022).

Razonamiento restringido por grafos. Algunos enfoques prefieren limitar las alucinaciones condicionando el proceso generativo a la existencia de caminos viables en el grafo de conocimiento o aplicando procesos iterativos que definan de forma progresiva el contexto de las respuestas del sistema (**Luo et al.**, 2024).

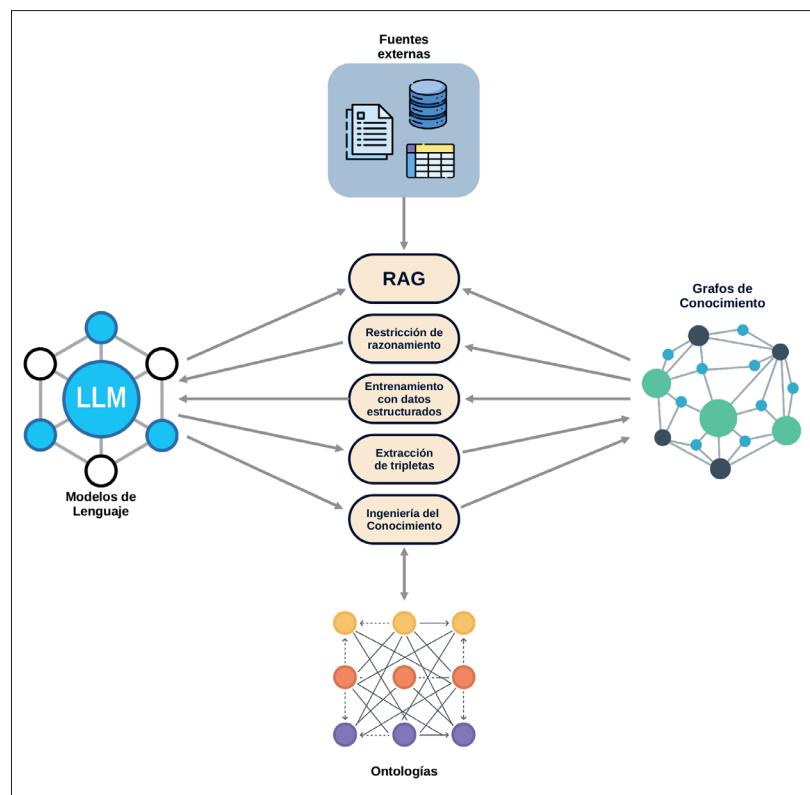


Figura 1. Sinergias entre los LLM y los grafos de conocimiento.
Fuente: elaboración propia

Se trata de trabajos teóricos a partir de los cuáles se han realizado desarrollos aplicados. La aplicación de tecnologías de la web semántica en entornos integrados con LLM permite la validación de datos obtenidos de informes y pruebas de verificación de tareas para chequear el cumplimiento de requisitos de ciertos procesos. Es el caso de sistemas de IA generativa para comparar los hechos reflejados en documentos no estructurados validándolos contra hechos estructurados explícitos de un grafo de conocimiento (**De-Santis et al.**, 2025). En ciertos entornos industriales se han planteado la aplicación de grafos de conocimiento como fuentes fiables para sistemas de LLM con fines de trazabilidad, verificación formal y reproducibilidad de resultados (**Sequeda; Allemang; Jacob**, 2025). En el ámbito de la arquitectura, ingeniería y la construcción incluso se ha llegado a plantear la transformación de datos relacionales en grafos de conocimiento RDF mucho más flexibles e interoperables (**Höltgen et al.**, 2025).

5. Wikidata como grafo de conocimiento fiable para la web sintética

Ciertamente los LLM permiten el desarrollo de sistemas de IA generativa que suelen producir un aparente impacto positivo en los resultados. Sin embargo, resulta muy cuestionable su precisión factual. Las alucinaciones y las respuestas sin trazabilidad siguen siendo un problema que requiere la incorporación de conocimiento externo para mejorar la precisión y adaptabilidad de las respuestas. Aunque es evidente que los grafos de conocimiento y los datos enlazados permiten aportar estabilidad y fiabilidad a estos sistemas, se precisan buenas prácticas semánticas por parte de la comunidad. Es decir, es necesaria la existencia de ontologías coherentes, vocabularios bien definidos, alineamientos globales, mecanismos de trazabilidad de las triplets mediante referencias de procedencia, revisión humana en la curación, validación cruzada de fuentes, etc.

En este punto cabría afirmar que *Wikidata* se ha consolidado como el grafo de conocimiento más reutilizado del mundo. Contiene más de 100 millones de entidades interconectadas y da soporte a *Wikipedia*, a decenas de proyectos culturales y a modelos de IA. Esto último no sorprende, puesto que los proyectos *Wikimedia* son una fuente de datos muy utilizada por los desarrolladores de IA. *Wikipedia* y *Wikidata* han sido pilares en el entrenamiento de modelos como *BERT*, *GPT* o *LLaMa* y están presentes en la mayoría de los corpus de pre-entrenamiento y ajuste de los LLM (**Johnson; Kaffee; Redi**, 2024). Adicionalmente no hay que perder de vista la potencialidad que ofrece *Wikidata* de verificación de los datos del grafo de conocimiento mediante las referencias a recursos de información externos.

De un modo más concreto, la integración entre IA generativa y *Wikidata* abre un horizonte sugerente, pero también plantea retos considerables. El primero de ellos, alcanzar un alto grado de escalabilidad para realizar consultas (tanto vectoriales como *SPARQL*) de un modo interoperable y que resulten eficientes sobre grandes volúmenes de datos en crecimiento. De hecho, se ha desarrollado una API *GraphQL* para *Wikidata*. Esto permite elaborar consultas más sencillas para aplicaciones y entornos que requieren facilidad de explotación del grafo de conocimiento (*Wikimedia Foundation*, 2025). Algo también a resaltar es la división de *Wikidata*, a efectos de realizar consultas *SPARQL* en *WDQS*, en dos grafos: el grafo principal y el grafo académico (**Lubiana; Raspberry; Mietchen**, 2025).

También se está experimentando con la generación de una base de datos de vectores a partir del grafo de conocimiento de *Wikidata* mediante un sistema IA que funciona en doble sentido: generación de los vectores y traducción de las peticiones de los usuarios a consultas procesables por el sistema (**Ang**, 2025). En esta misma línea, el proyecto *Wikidata Embedding* permite transformar las entidades y relaciones del grafo en vectores semánticos multilingües (*Wikimedia Foundation*, 2024). Este proyecto marca un punto de inflexión. La base vectorial permitiría búsquedas por significado semántico en lugar de por palabra clave, y se integra fácilmente en arquitecturas de RAG. En otras palabras,

Wikidata se convierte en un repositorio “listo para IA”, capaz de alimentar modelos generativos con información actualizada, verificable y multilingüe. Un ejemplo de aplicación de este proyecto se puede ver *Wikidata Vector Database* (figura 2).

No obstante, el uso de la aplicación de *Wikidata* en la IA generativa plantea ciertas dudas, como los conflictos entre distintas versiones de los datos del grafo de conocimiento. Pensemos que el objetivo no es solo ofrecer una respuesta X, sino también indicarle que dicha respuesta proviene de la tripleta (Qn, Pm, Qk). Esto conlleva ciertas dificultades cuya solución no es única ni trivial. Como se ha apuntado anteriormente, la actualización y sincronización de un modelo entrenado requiere de herramientas especializadas. Por otro lado, *Wikidata* también tiene problemas de curación, lo que lleva a encontrar vandalismo, sesgos y errores en el grafo de conocimiento. Los datos enlazados no son perfectos, la incorrección, incompletitud o parcialidad puede suponer un riesgo real en el desarrollo de los LLM. Estos problemas de “calidad del grafo” pueden agravarse considerando su desarrollo desigual en determinados dominios de conocimiento específicos, lo cual choca con el enfoque de los LLM que son más amplios.

6. Conclusiones

La hibridación entre grafos de conocimiento y sistemas generativos marca un punto de inflexión en la forma en que producimos, consultamos y organizamos información. La llamada “web sintética”, podría entenderse como una capa conversacional capaz de generar texto a partir de modelos avanzados sin sustituir a la web semántica. La amplía. La exige. La vuelve aún más necesaria. Los modelos de lenguaje aportan fluidez y versatilidad. Los datos estructurados aportan precisión, coherencia y un anclaje verificable. La unión de ambos elementos permite crear sistemas más fiables que combinan creatividad y estructura.

Esta combinación abre un campo de trabajo amplio para profesionales y desarrolladores de distintos perfiles. Ya no se trata solo de programar interfaces o diseñar algoritmos. Se trata de construir infraestructura conceptual y técnica. Se trata de garantizar que la IA generativa pueda apoyarse en datos públicos, organizados, mantenidos y editados con criterios claros.

El camino hacia este modelo híbrido se puede iniciar con acciones muy concretas. Una estrategia clara consiste en crear grafos locales adaptados a las necesidades de cada institución o proyecto. Estos grafos pueden describir autores, obras, actividades, procesos, recursos o cualquier otro dominio específico. Una vez construidos, pueden exponerse mediante APIs o servicios de consulta que sirvan de base para asistentes conversacionales, buscadores internos o sistemas de recomendación.

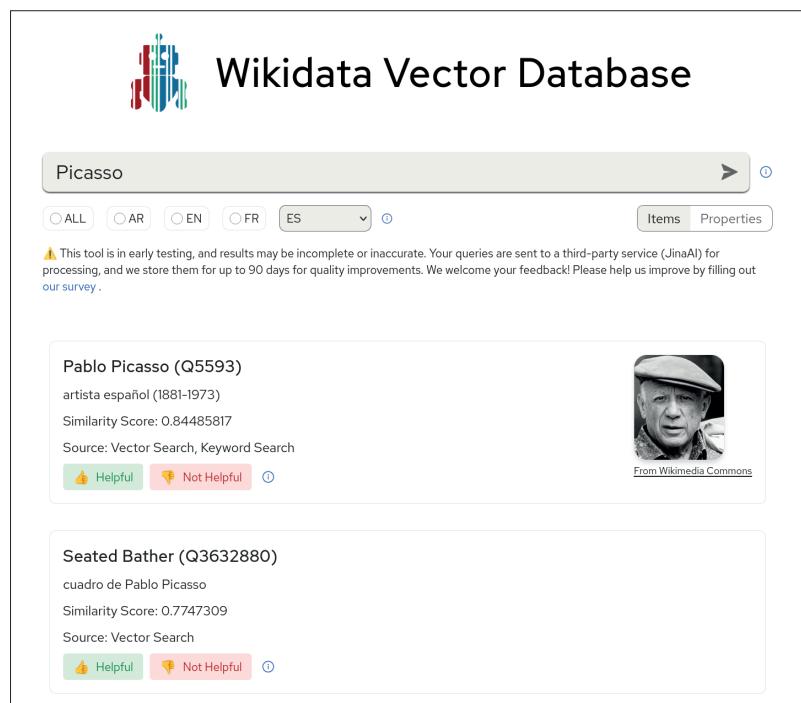


Figura 2. Ejemplo de búsqueda con *Wikidata Vector Database*.
<https://wd-vectordb.wmcloud.org>

La formación técnica también es un aspecto crítico en este escenario. Entender conceptos como RDF, ontologías, *embeddings*, razonamiento limitado, RAG o alineamiento semántico no es algo superfluo o que caen en conocimientos puramente técnicos. Son conocimientos sobre herramientas prácticas que permiten entender (y en su caso diseñar) el funcionamiento de sistemas que integran datos estructurados con modelos generativos.

Tampoco hay que perder de vista el papel clave de los proyectos de curación híbrida. En ellos, la IA generativa podría detectar inconsistencias o sugerir nuevas relaciones para completar el grafo de conocimiento. Los profesionales humanos se podrían centrar en filtrar, revisar y validar las propuestas. Este enfoque combina velocidad y criterio: la máquina ayuda a mirar más lejos y más rápido y las personas garantizan la calidad, el sentido y la corrección.

Adicionalmente, el uso de vocabularios y estándares comunes permite asegurar que los grafos locales puedan conectarse con recursos globales. Esto facilita la interoperabilidad y evita duplicaciones. Publicar metadatos, catálogos o estadísticas como datos enlazados añade un nivel más de apertura y permite que los modelos generativos trabajen con bases de conocimiento bien estructuradas.

Todos estos procesos mencionados anteriormente requieren una visión clara de gobernanza y transparencia. Los sistemas generativos deben indicar de dónde obtienen la información y cómo la combinan. La trazabilidad no es solo un requisito técnico. Es una garantía de confianza. Permite auditar los procesos y corregir errores cuando aparecen.

La integración entre grafos y modelos generativos representa una oportunidad real. No es una idea abstracta ni un escenario lejano. Es un espacio de trabajo concreto donde desarrolladores, diseñadores de sistemas, arquitectos de datos e investigadores pueden aportar valor inmediato. Si se avanza de forma colaborativa y con una visión de futuro, es posible construir una infraestructura híbrida sólida. Una infraestructura capaz de sostener sistemas conversacionales más útiles, más comprensibles y responsables.

7. Referencias

- Ang, Alan** (2025). "Wikidata-Wikimedia's knowledge graph in a world of generative AI". *Wikimedia Commons*. [https://commons.wikimedia.org/wiki/File:Wikidata-Wikimedia%27s_knowledge_graph_in_a_world_of_generative_AI_\(2025\).pdf](https://commons.wikimedia.org/wiki/File:Wikidata-Wikimedia%27s_knowledge_graph_in_a_world_of_generative_AI_(2025).pdf)
- Cai, Linyue; Yu, Chaojia; Kang, Yongqi; Fu, Yu; Zhang, Heng; Zhao, Yong** (2025). "Practices, opportunities and challenges in the fusion of knowledge graphs and large language models". *Frontiers in computer science*, v. 7, 1590632. <https://doi.org/10.3389/fcomp.2025.1590632>
- Dang, Minh-Hoanh; Pham, Thi-Hoang-Thi; Molli, Pascal; Skaf-Molli, Hala; Gaignard, Alban** (2025). "LLM4Schema.org: Generating Schema.org markups with Large Language Models". *Semantic web: Interoperability, usability, applicability*, v. 16, n. 6. <https://doi.org/10.1177/22104968251382172>
- De-Santis, Antonio; Balduini, Marco; De-Santis, Federico; Proia, Andrea; Leo, Arsenio; Bambrilla, Marco; Della-Valle, Emanuele** (2025). "Integrating Large Language Models and knowledge graphs for extraction and validation of textual test data". In: Demartini, Gianluca; Hose, Katja; Acosta, Maribel; Palmonari, Matteo; Cheng, Gong; Skaf-Molli, Hala; Ferranti, Nicolas; Hernández, Daniel; Hogan, Aidan (eds.). *The Semantic Web – ISWC 2024* (Lecture Notes in Computer Science, vol. 15233). Springer. https://doi.org/10.1007/978-3-031-77847-6_17
- Garijo, Daniel; Poveda-Villalón, María; Amador-Domínguez, Elvira; Wang, ZiYuan; García-Castro, Raúl; Corcho, Oscar** (2025). "LLMs for ontology engineering: A landscape of tasks and benchmarking challenges". In: Alharbi, Reham; De-Berardinis, Jacopo; Groth, Paul; Meroño-Peñuela, Albert; Simperi, Elena; Tamma, Valentina (eds.). *Proceedings of the special session on harmonising generative AI and semantic web technologies (IWAIS 2024) co-located with the 23rd International Semantic Web Conference (ISWC 2024)*. CEUR Workshop Proceedings, v. 3953. <https://ceur-ws.org/Vol-3953/364.pdf>

La web sintética no sustituye a la web semántica: la amplía y la vuelve aún más necesaria

Höltgen, Lea; Zentgraf, Sven; Hagedorn, Philipp; König, Markus (2025). "Utilizing large language models for semantic enrichment of infrastructure condition data: a comparative study of GPT and Llama models". *AI in civil engineering*, v. 4, art. 14. <https://doi.org/10.1007/s43503-025-00055-9>

Johnson, Isaac; Kaffee, Lucie-Aimée; Redi, Miriam (2024). "Wikimedia data for AI: a review of *Wikimedia* datasets for NLP tasks and AI-assisted editing". In: Kaffee, Lucie-Aimée, Fan, Angela; Gwadabe, Tajuddeen; Johnson, Isaac; Petroni, Fabio; Van-Strien, Daniel (eds.). *Proceedings of the first workshop on advancing natural language processing for Wikipedia* (pp. 91–101). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2024.wikinlp-1.14>

Lubiana, Tiago; Rasberry, Lane; Mietchen, Daniel (2025). "The *Wikidata* query service split and its impact on the scholarly graph". In: Chaves-Fraga, David; Heibi, Ivan; Garijo, Daniel; Collarana, Diego; Salatino, Angelo; Vahdati, Sahar (eds.). *Proceedings of the SEMANTiCS Conference 2025*, Vienna, Austria (03–05 Sept.). CEUR Workshop Proceedings, v. 4064. <https://ceur-ws.org/Vol-4064/PD-paper3.pdf>

Luo, Linhao; Zhao, Zicheng; Haffari, Gholamreza; Gong, Chen; Pan, Shirui (2024). "Graph-constrained Reasoning: Faithful Reasoning on Knowledge Graphs with Large Language Models". arXiv preprint arXiv:2410.13080. <https://doi.org/10.48550/arXiv.2410.13080>

Moiseev, Fedor; Dong, Zhe; Alfonseca, Enrique; Jaggi, Martin (2022). "SKILL: Structured Knowledge Infusion for Large Language Models". In: Carpuat, Marine; De-Marneffe, Marie-Catherine; Meza-Ruiz, Ivan-Vladimir (eds.). *Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies* (pp. 1581–1588). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2022.nacl-main.113>

Pan, Jeff Z.; Razniewski, Simon; Kalo, Jan-Christoph; Singhania, Sneha; Chen, Jiaoyan; Dietze, Stefan; Jabeen, Hajira; Omelianenko, Janna; Zhang, Wen; Lissandrini, Matteo; Biswas, Russa; De-Melo, Gerard; Bonifati, Angela; Vakaj, Edlira; Dragoni, Mauro; Graux, Damien (2023). "Large Language Models and Knowledge Graphs: Opportunities and challenges". *Transactions on graph data and knowledge*, v. 1, n. 1. <https://doi.org/10.4230/TGDK.1.1.2>

Saeedizade, Mohammad-Javad; Blomqvist, Eva (2024). "Navigating ontology development with Large Language Models". In: Meroño-Peñuela, Albert; Dimou, Anastasia; Troncy, Raphaël; Hartig, Olaf; Acosta, Maribel; Alam, Mehwish; Paulheim, Heiko; Lisena, Pasquale (eds.). *The Semantic Web. ESWC 2024* (Lecture Notes in Computer Science, v. 14664). Springer. https://doi.org/10.1007/978-3-031-60626-7_8

Sequeda, Juan; Allemand, Dean; Jacob, Bryon (2025). "Knowledge graphs as a source of trust for LLM-powered enterprise question answering". *Journal of Web Semantics*, v. 85, 100858. <https://doi.org/10.1016/j.websem.2024.100858>

Zhang, Bohui; Reklos, Ioannis; Jain, Nitisha; Meroño-Peñuela, Albert; Simperl, Elena (2023). "Using Large Language Models for Knowledge Engineering (LLMKE): A case study on *Wikidata*". In: Razniewski, Simon; Kalo, Jan-Christoph; Singhania, Sneha; Pan, Jeff Z. (eds.). *Joint proceedings of the 1st workshop on Knowledge Base Construction from Pre-Trained Language Models (KBC-LM) and the 2nd challenge on Language Models for Knowledge Base Construction (LM-KBC) (KBC-LM + LM-KBC 2023)*, Athens, Greece, November 6, 2023. CEUR Workshop Proceedings, Vol. 3577. <https://ceur-ws.org/Vol-3577/paper8.pdf>

Wikimedia Foundation (2024). "Wikidata: Embedding Project". Wikidata. https://www.wikidata.org/wiki/Wikidata:Embedding_Project

Wikimedia Foundation (2025). "Wikidata: Wikibase GraphQL prototype". Wikidata. https://www.wikidata.org/wiki/Wikidata:Wikibase_GraphQL_prototype

Xu, Silei; Liu, Shicheng; Culhane, Theo; Pertseva, Elizaveta; Wu, Meng-Hsi; Semnani, Sina; Lam, Monica (2023). "Fine-tuned LLMs know more, hallucinate less with few-shot sequence-to-sequence semantic paarsing over *Wikidata*". In: Bouamor, Houda; Pino, Juan; Bali, Kalika (eds.). *Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing* (pp. 5778–5791). Association for Computational Linguistics. <https://doi.org/10.18653/v1/2023.emnlp-main.353>