




ScrapeGraphAI

Plataforma de automatización de extracción de datos web basada en grafos y LLM que transforma sitios web y documentos como PDF o HTML en JSON estructurado mediante lenguaje natural. Es ideal para desarrolladores, ingenieros de datos y equipos de producto que buscan eliminar el mantenimiento manual de selectores CSS/XPath, permitiendo una recolección de información dinámica, escalable y resistente a cambios en el diseño visual de las páginas, optimizando flujos de trabajo de inteligencia competitiva.

[Visitar Sitio Oficial](#) [Preguntar a ChatGPT](#) [Preguntar a Claude](#) [Preguntar a Grok](#)

Contenido del Dossier

- [Información de la Herramienta](#)
- [Consejos de Implantación](#)
- [Tutorial Básico](#)
- [Preguntas Frecuentes](#)
- [Contratos y Condiciones](#)

INFORMACIÓN DE LA HERRAMIENTA

Qué y para quién es

ScrapeGraphAI es una plataforma y librería de automatización de extracción de datos web basada en grafos y Modelos de Lenguaje Extensos (LLM). Permite transformar cualquier sitio web o documento (HTML, XML, PDF) en datos estructurados (JSON) utilizando lenguaje natural, eliminando la necesidad de escribir y mantener selectores CSS o XPath manuales. Está diseñado para desarrolladores, ingenieros de datos y equipos de producto que necesitan extraer información de la web de forma dinámica, escalable y sin el mantenimiento constante que requieren los scrapers tradicionales ante cambios en el diseño de las páginas.

Principal ventaja profesional

En mi opinión profesional, la razón definitiva para elegir ScrapeGraphAI es su arquitectura basada en grafos que delega la lógica de extracción al LLM. Esto reduce drásticamente el tiempo de desarrollo de semanas a minutos y, lo más importante, minimiza el mantenimiento técnico: si la web cambia visualmente, el LLM sigue entendiendo el contexto y extrayendo el dato correcto sin que el desarrollador tenga que intervenir.

Para quién no es

No es para empresas que busquen soluciones de bajo coste extremo para scraping masivo de datos estáticos y predecibles, donde un scraper tradicional de Python/BeautifulSoup es más eficiente energéticamente y económico. Tampoco es para usuarios sin conocimientos mínimos de programación (en su versión Open Source) o que no entiendan cómo definir un esquema de datos JSON.

funcionalidades clave

- SmartScraperGraph: Extracción de datos de una sola página mediante un prompt y una URL.
- SearchGraph: Capacidad de realizar búsquedas en motores y extraer datos de los mejores resultados automáticamente.
- ScriptCreatorGraph: Generación automática de scripts de Python para realizar la extracción de forma independiente.
- Gestión de Rendering: Soporte nativo para JavaScript (JS), modo Stealth para evitar bloqueos y rotación de proxies (en versión gestionada).
- Soporte Multi-modelo: Compatibilidad con OpenAI, Groq, Gemini, Azure y modelos locales vía Ollama.

Precios

- Versión Open Source (Gratuita): Bajo licencia MIT, permite uso ilimitado en infraestructura propia asumiendo los costes de los tokens de los LLM que se utilicen.
- Versión API Gestionada (Cloud):
 - Free Plan: 0€ (500 créditos gratuitos para pruebas).
 - Starter Plan: 20\$/mes (10.000 créditos).
 - Growth Plan: 100\$/mes (100.000 créditos).
 - Pro/Enterprise: Consultar precios para volúmenes superiores con soporte dedicado y SLA.

Perfil del usuario

- Empresas de eCommerce para monitorización de precios de la competencia.
- Departamentos de Marketing para análisis de tendencias y recopilación de leads.
- Equipos de Data Science para la creación de datasets de entrenamiento.
- Desarrolladores de Software que necesitan integrar datos externos en sus aplicaciones sin APIs oficiales.

Nivel técnico requerido

- Nivel técnico para uso: Medio (requiere conocimientos de Python o JS y manejo de prompts).
- Nivel técnico para instalación: Medio (instalación de librerías, gestión de claves API o configuración de contenedores para Ollama).
- Necesidades de soporte: Mínimas una vez configurado el entorno de ejecución o la conexión a la API.
- Competencias necesarias: Python, formato JSON, comprensión básica de cómo funcionan los LLM.

Ejemplos de uso profesional

- En las pruebas realizadas, he verificado que es ideal para automatizar el seguimiento de cambios en catálogos de proveedores externos sin API.
- Como profesional valoro su uso en la extracción de datos financieros de reportes PDF y su conversión directa a esquemas listos para bases de datos SQL.

- Implementación de sistemas de vigilancia competitiva que alertan vía Webhook cuando un competidor cambia sus condiciones de servicio.

Uso y distribución

- Librería Python (pip install scrapegraphai)
- SDK oficial para Python y JavaScript/TypeScript.
- Acceso vía API REST para la versión gestionada.
- Versión escritorio: Soporte para ejecución en local mediante Ollama para privacidad total.

Open source

El proyecto es de código abierto bajo licencia MIT, disponible en Github, lo que permite una total transparencia y personalización de los pipelines de extracción.

Integraciones

- Facilidad de integración: Alta (Low-code mediante SDK o Full-code para pipelines personalizados).
- API propia: Dispone de API REST documentada.
- Integración nativa con LangChain y soporte para múltiples proveedores de LLM.
- Ejemplos concretos: Integración con bases de datos vectoriales para sistemas RAG o automatizaciones en flujos de trabajo con herramientas tipo Airflow.

Notas finales

Veredicto técnico

Tras probar la herramienta, quiero destacar que es una de las soluciones más disruptivas en el ámbito del web scraping. Vale la pena especialmente para empresas que manejan fuentes de datos muy heterogéneas y cambiantes. Compensa el gasto de créditos o tokens por el ahorro masivo en horas de ingeniería de mantenimiento. Es una herramienta de gran utilidad que marca el fin de la era de los selectores CSS manuales.

información legal, licencias , contratos

- Licencia MIT para la librería open source (permite uso comercial, modificación y distribución).
- Cumplimiento SOC 2 Type II para la infraestructura cloud.
- Los datos extraídos son propiedad del usuario según los términos estándar de servicio de la API.

Otros

Es importante monitorizar el consumo de créditos en la versión cloud, ya que procesos complejos (como análisis de branding o capturas de pantalla) tienen costes significativamente mayores que la extracción de texto simple.

Fuentes consultadas:

- <https://scrapegraphai.com>
- <https://docs.scrapegraphai.com/introduction>
- <https://github.com/ScrapeGraphAI/Scrapegraph-ai>
- <https://github.com/ScrapeGraphAI/scrapegraph-py>

CONSEJOS DE IMPLANTACIÓN

Aplicación profesional

Según mi experiencia, ScrapeGraphAI es una herramienta disruptiva especialmente valiosa para empresas que operan en entornos de información volátil, como agregadores de precios, firmas de análisis de mercados financieros o startups de inteligencia artificial que alimentan sistemas RAG (Retrieval-Augmented Generation). Lo que más me gusta es su capacidad para romper la dependencia de los selectores CSS que suelen romperse semanalmente. En cuanto al presupuesto, aunque la librería es gratuita, es necesario prever un gasto operativo en tokens de LLM (OpenAI, Anthropic) o inversión en infraestructura local (GPUs) si se opta por Ollama. Para un volumen moderado de scraping, estimo un coste operativo inicial de entre 50 y 200 euros mensuales en créditos de API para obtener resultados fiables y rápidos.

Madurez digital requerida

- **Usuarios y equipo:** Requiere desarrolladores con fluidez en Python y, crucialmente, habilidades en "Prompt Engineering". El equipo debe entender la naturaleza probabilística de los LLM; a diferencia del scraping tradicional, el resultado puede variar ligeramente entre ejecuciones si no se definen bien los esquemas.
- **Empresa y departamentos:** Ideal para departamentos de IT o Data Science que ya gestionan claves de API y flujos de trabajo automatizados. No es una herramienta para usuarios finales de marketing sin apoyo técnico, ya que la configuración de los grafos de ejecución exige lógica de programación.

Plan orientativo de implantación

Pasos necesarios y estimaciones

- **Evaluación inicial (1 semana):** Identificación de las fuentes de datos objetivo y análisis de viabilidad técnica (detección de anti-bots, volumen de datos y complejidad del DOM).
- **Prueba de concepto - PoC (1-2 semanas):** Configuración de un entorno local con la librería y pruebas con modelos económicos (como GPT-4o-mini o modelos locales) para validar la precisión de la extracción.
- **Configuración y personalización (2 semanas):** Diseño de los esquemas JSON específicos para el negocio y configuración de sistemas de rotación de proxies si se atacan sitios con protecciones agresivas.
- **Puesta en producción y escalado (3 semanas):** Integración con la base de datos final o el pipeline de BI y establecimiento de límites de gasto para evitar sorpresas en la factura de los LLM.
- **Seguimiento (Continuo):** Auditoría periódica de la calidad del dato extraído, ya que los cambios drásticos en la estructura de la web pueden requerir ajustes en el prompt inicial.

Necesidades de formación del equipo

Es fundamental formar al equipo en el uso de esquemas Pydantic para validar los datos que devuelve el LLM y en la gestión de costes de inferencia. Al usarlo te das cuenta de que la mayor parte del tiempo no se gasta programando el scraper, sino refinando la descripción de lo que quieres extraer.

Perfiles necesarios

- **Perfiles técnicos necesarios:** Desarrollador Python Senior con experiencia en manejo de librerías asíncronas y APIs de inteligencia artificial.
- **Personal externo recomendado:** Un consultor experto en ética de datos y cumplimiento legal (RGPD) para asegurar que el scraping no vulnera términos de servicio sensibles.

Retorno de la inversión

- **Tiempos:** La reducción del tiempo de desarrollo es de hasta un 80% frente a métodos tradicionales. El mantenimiento técnico se reduce casi a cero, lo que libera a los ingenieros para tareas de mayor valor.
- **Cómo medirlo, KPIs:** Reducción en el número de "scripts rotos" por mes, tiempo medio de despliegue de un nuevo origen de datos y coste por registro extraído validado.

Otros

Mi experiencia en implantaciones me lleva a pensar que el mayor riesgo es el "alucinamiento" del modelo en webs muy densas. Recomiendo siempre activar la función de generación de capturas de pantalla o logs de los grafos durante la fase piloto para entender cómo está "razonando" la herramienta al navegar por la página. Además, es vital considerar el uso de modelos como Groq si la velocidad de extracción es la prioridad principal sobre el coste.

TUTORIAL BÁSICO

Instalación

ScrapeGraphAI se presenta en dos variantes: la biblioteca Open Source (para control total local) y el SDK de la API Cloud (para rapidez y escalabilidad).

- Librería Open Source (Local):

- Requiere Python e 3.9. Instala mediante pip `install scrapegraphai`.
- Es fundamental instalar las dependencias del navegador con `playwright install`.
- Si planeas usar modelos locales, instala **Ollama** y descarga los modelos necesarios (ej. `ollama pull llama3.2`).

- SDK de API Cloud (Recomendado para producción):

- Instala mediante pip `install scrapegraph-py`.
- Necesitas una API Key del Dashboard de ScrapeGraphAI.
- Configura la variable de entorno `SGAI_API_KEY` para simplificar la inicialización del cliente.

Uso en el día a día

Según mi experiencia, la curva de aprendizaje es mínima si entiendes la diferencia entre los tipos de grafos disponibles.

- **SmartScraperGraph:** Es la herramienta principal. Solo necesitas pasarle una URL y un prompt en lenguaje natural indicando qué datos quieres. No pierdas tiempo definiendo selectores CSS o XPath.
- **Markdown como estándar:** Al usarlo te das cuenta de que convertir la web a Markdown antes de procesarla con el LLM reduce drásticamente el consumo de tokens y mejora la precisión de la extracción.
- **Configuración Headless:** En desarrollo, desactiva el modo headless (`"headless": False`) en el `graph_config` para ver cómo interactúa el navegador con la página y depurar fallos visuales.

Trucos de experto

- **Esquemas JSON:** Para asegurar que tu aplicación no rompa, define siempre un esquema de salida. En mi opinión profesional, confiar ciegamente en el formato libre del LLM es un error; usa pydantic o esquemas JSON explícitos en el prompt.
- **Optimización de FetchConfig:** No actives el renderizado de JavaScript (`mode: "js"`) ni el modo stealth por defecto. Mi experiencia me lleva a pensar que es mejor empezar con el modo fast y solo escalar a configuraciones complejas si el sitio bloquea la petición o el contenido es dinámico.
- **Uso de múltiples formatos:** Con la API Cloud, puedes solicitar Markdown, capturas de pantalla y extracción estructurada en una sola llamada. Esto ahorra costes y tiempo de ejecución comparado con hacer peticiones por separado.

Posibles problemas/incidencias

- **Consumo de Recursos:** La versión Open Source con modelos locales es extremadamente exigente con la RAM y la GPU. Si no tienes hardware dedicado, utiliza las APIs de OpenAI, Anthropic o la propia nube de ScrapeGraph.
- **Timeouts en sitios SPA:** Las aplicaciones de una sola página (React, Vue) a menudo requieren un tiempo de espera. Si la extracción falla o devuelve datos vacíos, aumenta el parámetro `wait` en el `fetch_config`.
- **Incompatibilidades de versión:** Asegúrate de que la versión de `scrapegraphai` sea compatible con la de `playwright`. Si encuentras errores de navegación, ejecuta `playwright install --with-deps` para asegurar que todas las librerías del sistema estén presentes.

Otros

- **Integración RAG:** La salida en formato Markdown está optimizada para ser indexada directamente en bases de datos vectoriales, facilitando la creación de sistemas de Answer Engine sobre datos web actualizados.
- **Elegir entre Local y Cloud:** Según mi experiencia es necesario evaluar el volumen. Para scraping masivo (>1000 páginas/día), la infraestructura cloud gestiona mejor las rotaciones de proxy y los retos de bot detection que una implementación local básica.

PREGUNTAS FRECUENTES

¿Qué es ScrapeGraphAI y en qué se diferencia de las herramientas de scraping tradicionales?

ScrapeGraphAI es una librería de automatización de extracción de datos web que utiliza Modelos de Lenguaje Extensos (LLM) y lógica basada en grafos. A diferencia de las herramientas tradicionales que dependen de selectores CSS o XPath rígidos, ScrapeGraphAI interpreta el contenido de forma semántica, lo que permite extraer datos de sitios web y documentos (HTML, XML, PDF) sin necesidad de actualizar el código cuando el diseño de la página cambia.

¿Qué requisitos técnicos son necesarios para implementar esta tecnología?

El uso de la librería requiere un nivel técnico medio, con conocimientos en programación Python o JavaScript/TypeScript. Los desarrolladores deben estar familiarizados con el manejo de prompts para LLM, la gestión de claves API y el formato de datos JSON. Para ejecuciones en local, es necesario conocer la configuración de entornos y herramientas como Ollama.

¿Es posible utilizar ScrapeGraphAI de forma gratuita?

Sí, existen dos vías principales. La librería es Open Source bajo licencia MIT, lo que permite su descarga y uso gratuito desde GitHub, aunque el usuario debe asumir los costes de los tokens de los LLM que conecte. Por otro lado, la versión API gestionada en la nube ofrece un plan gratuito limitado a 500 créditos para realizar pruebas iniciales.

¿Qué modelos de lenguaje son compatibles con la plataforma?

La herramienta ofrece un soporte multi-modelo versátil, siendo compatible con proveedores comerciales como OpenAI (GPT), Azure, Google Gemini y Groq. Además, permite la integración con modelos locales a través de Ollama, facilitando el procesamiento de datos en entornos privados.

¿Cómo garantiza la herramienta la privacidad y seguridad de los datos?

Para proyectos con estrictos requisitos de privacidad, ScrapeGraphAI permite la ejecución local mediante modelos open-source, evitando que los datos salgan de la infraestructura propia. En su versión cloud, la plataforma cumple con el estándar de seguridad SOC 2 Type II, y los términos de servicio establecen que los datos extraídos son propiedad exclusiva del usuario.

¿Qué sucede si el sitio web objetivo tiene protecciones contra bots o mucho contenido en JavaScript?

ScrapeGraphAI incluye funcionalidades avanzadas para manejar estos escenarios, como soporte nativo para el renderizado de JavaScript (JS) y un modo 'Stealth' diseñado para evitar bloqueos. En la versión API gestionada, también se incluye la rotación automática de proxies para mejorar la tasa de éxito en la extracción.

¿Es eficiente utilizar esta herramienta para scraping masivo de datos estáticos?

No es la opción más recomendable para casos donde los datos son altamente predecibles y el volumen es masivo, ya que el coste computacional y económico de los LLM es superior a métodos tradicionales como BeautifulSoup o Scrapy. Su valor diferencial reside en la gestión de fuentes heterogéneas, cambiantes o documentos complejos donde el ahorro en mantenimiento técnico compensa el coste de los tokens.

¿Qué capacidades ofrece para la generación de scripts autónomos?

Mediante la función ScriptCreatorGraph, la herramienta puede generar automáticamente scripts de Python independientes basados en la lógica de extracción definida. Esto permite a los desarrolladores obtener código ejecutable que no dependa constantemente de la infraestructura de grafos de la librería principal para tareas específicas.

¿Cómo se integra ScrapeGraphAI en flujos de trabajo profesionales ya existentes?

La plataforma ofrece una alta integración mediante SDKs oficiales y una API REST documentada. Es compatible con ecosistemas como LangChain para sistemas de Generación Aumentada por Recuperación (RAG) y puede orquestarse en pipelines de datos complejos utilizando herramientas como Apache Airflow o bases de datos vectoriales.

CONTRATOS Y CONDICIONES

Opinión inicial

Tras analizar los contratos y condiciones de ScrapeGraphAI, nos encontramos ante una herramienta de **impacto legal medio-alto** para una empresa española. Si bien la librería técnica es excelente y utiliza una licencia MIT (muy permisiva), el uso profesional de su versión Cloud implica una transferencia internacional de datos a EE.UU. (jurisdicción fuera del EEE). Según los documentos consultados, el cumplimiento recae casi íntegramente en el usuario: la plataforma se define como un "facilitador", pero prohíbe explícitamente el uso de su tecnología para saltarse medidas de seguridad (paywalls o captchas) sin autorización, lo que podría generar conflictos de responsabilidad civil si no se gestiona con cautela. En mi opinión profesional, es una solución robusta en seguridad (certificación SOC 2), pero requiere una auditoría previa de las fuentes que se van a extraer para evitar infracciones de propiedad intelectual o de la Ley de Datos de la UE.

Principales recomendaciones

- **Auditoría de Robots.txt:** Antes de configurar cualquier "grafo" de extracción, es imperativo verificar que el sitio de origen no prohíba contractualmente el acceso automatizado. ScrapeGraphAI traslada contractualmente esta responsabilidad al usuario.
- **Minimización de datos en Prompts:** Al usar LLMs externos (OpenAI, Anthropic), evita incluir datos personales o información confidencial de la empresa en el prompt de extracción, ya que estos datos viajan a terceros proveedores.
- **Configuración Local para Datos Sensibles:** Si la empresa maneja datos críticos, recomiendo usar la implementación local mediante **Ollama**, evitando así que los datos salgan de la infraestructura de la empresa y eliminando el riesgo de transferencia internacional.
- **Revisión de Cláusulas de Propiedad:** Verificar que los términos de servicio del sitio web scrapeado permiten el uso comercial de los datos extraídos para evitar demandas por competencia desleal o infracción de propiedad intelectual.

Ley de Inteligencia Artificial (AI Act)

- **Clasificación:** Se considera un sistema de IA de propósito general (GPAI) cuando se integra con modelos como GPT-4 o Gemini.
- **Obligaciones:** Al ser una herramienta de extracción y estructuración, no entra en categorías de "alto riesgo" (salvo que se use para perfiles biométricos o decisiones automatizadas de crédito/empleo), pero debe cumplir con las obligaciones de transparencia: los usuarios deben saber que el contenido ha sido procesado por IA.
- **Prohibiciones:** Está prohibido usar esta tecnología para scraping indiscriminado de imágenes faciales de internet para crear bases de datos de reconocimiento facial (Art. 5 AI Act).

Privacidad y protección de datos

- **Responsabilidades:** La empresa usuaria actúa como **Responsable del Tratamiento** de los datos extraídos. ScrapeGraphAI actúa como **Encargado del Tratamiento** en su versión Cloud.
- **Ubicación de los datos:** Principalmente en servidores de Estados Unidos para la versión gestionada (Cloud).
- **Transferencia internacional:** Existe transferencia a EE.UU. Se requiere verificar si cuentan con el Marco de Privacidad de Datos (Data Privacy Framework) o firmar Cláusulas Contractuales Tipo (SCCs) adicionales, ya que su política de privacidad estándar menciona el tratamiento fuera del EEE.
- **Derechos ARCO:** La empresa debe garantizar que puede identificar y borrar datos personales extraídos si un interesado ejerce su derecho de supresión, algo complejo en datasets desestructurados.

Propiedad intelectual

- **Propiedad de datos:** El usuario mantiene la propiedad de los datos de entrada y de los resultados (Outputs) generados por la herramienta.
- **Propiedad intelectual del resultado:** Según los términos consultados, ScrapeGraphAI no reclama derechos sobre la estructura de datos generada, permitiendo al usuario su explotación comercial.
- **Respeto a terceros:** El uso de la herramienta para extraer contenido protegido por derechos de autor (textos creativos, bases de datos protegidas por derecho sui generis) puede ser ilegal si no se cuenta con autorización o no aplica una excepción legal (como el Data Mining para investigación).

Usos y prohibiciones

- **Usos admitidos:** Extracción de precios, monitorización de catálogos públicos, análisis de sentimiento de noticias y estructuración de documentos internos (PDF/HTML).

- **Usos prohibidos:** Evasión de muros de pago (paywalls), bypass de sistemas anti-bot sin permiso, extracción de datos de salud o menores sin base legal, y cualquier actividad que degrade el rendimiento del servidor de destino.

Seguridad y certificaciones

- **Seguridad:** Cifrado AES-256 en reposo y TLS 1.2+ en tránsito.
- **Certificaciones:** Han obtenido la certificación **SOC 2 Type II** (verificado en julio de 2026), lo que garantiza controles estrictos sobre la disponibilidad, integridad y confidencialidad de la plataforma.

Otros

- **Gestión de Créditos:** En la versión Cloud, el coste no es solo por ejecución, sino por complejidad (captura de pantalla vs texto), lo que requiere un control financiero estricto para evitar sobrecostes imprevistos.
- **Licencia Open Source:** La librería principal en GitHub usa **Licencia MIT**, lo que permite a la empresa modificar el código fuente para adaptarlo a sus necesidades de cumplimiento internas sin pagar royalties.

Fuentes consultadas:

- [Términos de Servicio oficiales](#)
- [Política de Privacidad y RGPD](#)
- [Certificación SOC 2 Type II](#)
- [Repositorio Oficial GitHub - Licencia MIT](#)
- [Documentación Técnica y API](#)

Para más información y herramientas:

Explora look4.tools para descubrir las mejores soluciones tecnológicas del mercado.

[Inicio](#) [Todas las herramientas](#) [Categorías](#)

Este documento ofrece recomendaciones generadas mediante análisis humano y sistemas de IA automatizados. La información tiene carácter meramente informativo y no constituye asesoramiento legal, profesional ni garantía de resultados. Las marcas, logotipos y nombres comerciales pertenecen a sus respectivos propietarios y se utilizan únicamente con fines identificativos.