



ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA (ICAI)
MÁSTER EN BIG DATA: TECNOLOGÍA Y ANALÍTICA
AVANZADA

TRABAJO FIN DE MÁSTER

GEO Analyzer - Sistema de Análisis de Visibilidad del
Máster en Big Data de ICAI en LLMs

Autor: Paula Arroyo Plaza

Director: Carlos Morrás Ruiz-Falcó

Madrid

Mayo de 2026

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título
Geo Analyzer - Sistema de Análisis de Visibilidad del Máster de Big Data de ICAI en
LLMs

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el

curso académico 2025/26 es de mi autoría, original e inédito y

no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido
tomada de otros documentos está debidamente referenciada.

Fdo.: Paula Arroyo Plaza

Fecha: 19/5/26



Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

Fdo.: Carlos Morrás Ruiz-Falcó

Fecha://



ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA (ICAI)
MÁSTER EN BIG DATA: TECNOLOGÍA Y ANALÍTICA
AVANZADA

TRABAJO FIN DE MÁSTER

GEO Analyzer - Sistema de Análisis de Visibilidad del
Máster en Big Data de ICAI en LLMs

Autor: Paula Arroyo Plaza

Director: Carlos Morrás Ruiz-Falcó

Madrid

Agradecimientos

A mi familia, por su apoyo incondicional a lo largo de todos estos años y por creer en mí en todo momento; nada de esto habría sido posible sin ellos. A mi tutor, Carlos Morrás Ruiz-Falcó, por su guía, su dedicación y su confianza durante el desarrollo de este proyecto. Y a la Universidad Pontificia Comillas – ICAI, por la formación recibida y por brindarme las herramientas y oportunidades que han hecho posible llegar hasta aquí. A todos ellos, mi más sincero agradecimiento.

GEO Analyzer - Sistema de Análisis de Visibilidad del Máster en Big Data de ICAI en LLMs

Autor: Arroyo Plaza, Paula

Director: Morrás Ruiz-Falcó, Carlos

Entidad Colaboradora: ICAI – Universidad Pontificia Comillas

RESUMEN DEL PROYECTO

Los modelos de lenguaje de gran escala (LLMs) se han consolidado como intermediarios principales en la búsqueda de información, lo que plantea una pregunta inédita para las instituciones educativas: ¿cómo es representado un programa formativo en las respuestas de ChatGPT, Claude o Gemini? Este TFM desarrolla GEO Analyzer, un sistema end-to-end que mide la visibilidad del Máster en Big Data de ICAI en los principales LLMs mediante 86 prompts $\times$ 3 modelos. Calcula métricas específicas de Generative Engine Optimization (GEO) y las visualiza en un dashboard interactivo con módulo de monitorización temporal. Los resultados evidencian un Score GEO de 2,4/10 con una brecha estructural en visibilidad orgánica frente a competidores como UC3M o UPM, y proporcionan un sistema reutilizable y escalable a cualquier programa o institución.

Palabras clave: Generative Engine Optimization (GEO), LLMs, ChatGPT, Claude, Gemini, visibilidad digital, educación superior, NLP.

1. Introducción

El lanzamiento de ChatGPT en noviembre de 2022 inició una transformación en la forma en que los usuarios buscan información: en octubre de 2025 ChatGPT supera los 800 millones de usuarios activos semanales (*Bellan & Forristal, 2025*) y procesa más de 2.500 millones de consultas diarias (*Singh, 2026*). Gartner pronostica una caída del 25% en el volumen de búsquedas en motores tradicionales antes de 2026, sustituidas por asistentes conversacionales que sintetizan la información en lugar de devolver enlaces (*Gartner Predicts Search Engine Volume Will Drop 25% by 2026, Due to AI Chatbots and Other Virtual Agents, 2024*). Este cambio de paradigma plantea una pregunta crítica para cualquier institución académica: cuando un potencial estudiante pregunta a un LLM por programas de posgrado, ¿cómo aparece —o no aparece— mi oferta formativa? La visibilidad en LLMs es opaca, probabilística y aún apenas estudiada, y constituye la motivación central del presente trabajo aplicado al Máster en Big Data de ICAI – Universidad Pontificia Comillas.

2. Definición del proyecto

El proyecto se articula en dos líneas complementarias. La primera, de carácter investigador, diseña un experimento controlado que evalúa la visibilidad del Máster mediante 86 prompts organizados en 8 bloques temáticos (recomendaciones generales, perfiles de estudiante y profesional, comparativas con competidores, consultas específicas sobre ICAI, etc.), ejecutados sobre los tres LLMs de mayor adopción del mercado: ChatGPT (GPT-4o) (*GPT-4o Model | OpenAI API, n.d.*), Claude (Sonnet 3.5) (*Introducing Claude 3.5 Sonnet, 2024*) y Gemini (2.0 Flash) (*Models | Gemini API, 2026*). La segunda, de carácter tecnológico, materializa el análisis en un sistema software funcional —GEO Analyzer— compuesto por un módulo de adquisición de respuestas vía APIs oficiales, un

módulo de procesamiento NLP que extrae menciones, fuentes y atributos cualitativos, y un dashboard web que sintetiza los resultados en métricas accionables y permite el seguimiento temporal mediante snapshots persistentes.

3. Descripción del modelo/sistema/herramienta

GEO Analyzer se concibe como una solución end-to-end con tres capas. La capa de adquisición automatiza el envío de los 86 prompts a las APIs de OpenAI, Anthropic y Google, almacenando las 258 respuestas (de las cuales 244 resultaron válidas) con timestamp y metadatos en formato JSON. La capa de procesamiento aplica técnicas de NLP basadas en spaCy y expresiones regulares para extraer las menciones de programas, normalizarlas a una entidad canónica, identificar las fuentes citadas (dominios y tipología) y calcular tres métricas GEO específicas para el dominio educativo: Tasa de Presencia Orgánica (TPO), Posición de Primera Mención (PPM) y Frecuencia de Mención (FM), agregadas en un Score GEO compuesto en escala 0-10. La capa de visualización se implementa como una aplicación web React + TypeScript con backend en Supabase Cloud, que ofrece ocho vistas interconectadas (Score, Radar semántico, análisis por bloque, por modelo, competitivo, urls, conclusiones e histórico) y un módulo de generación automática de insights mediante un Edge Function conectado a Gemini.

4. Resultados

El experimento revela un patrón claro: ICAI presenta una visibilidad orgánica del 2,2% en bloques sin mención explícita del programa, frente a tasas significativamente superiores de competidores como UC3M, UPM o UPC, que se mencionan espontáneamente en la mayoría de respuestas a consultas abiertas. En contraste, la visibilidad reactiva —cuando el prompt nombra ICAI directamente— alcanza el 94% en comparativas y el 97% en preguntas específicas, lo que indica que el problema no es de reconocimiento sino de activación espontánea. La calidad factual es sistemáticamente baja en los tres modelos: ningún LLM proporciona información completamente correcta sobre el Máster en preguntas concretas (precio, temario, convenios, modalidad), siendo Gemini el menos evasivo y Claude el más cauteloso. El Score GEO global de ICAI es 2,4/10, evidenciando una brecha de posicionamiento estructural pero no un problema de imagen, pues el tono de las menciones es mayoritariamente positivo o neutro. El análisis de fuentes muestra que uc3m.es, upm.es, elmundo.es y topuniversities.com son los dominios más citados por los LLMs como referencias de autoridad en programas de posgrado en España.

5. Conclusiones

El trabajo demuestra que la visibilidad en motores generativos puede medirse, comparada y monitorizada de forma sistemática, y que el GEO (*Aggarwal, P. et al., 2024*) emerge como una evolución necesaria del SEO clásico para un ecosistema en el que los LLMs sustituyen progresivamente al motor de búsqueda como punto de descubrimiento. En el caso de ICAI, los resultados identifican un déficit de visibilidad orgánica que no se explica por la calidad del contenido publicado ni por la imagen del programa, sino por su limitada capacidad de activación dentro de los pesos paramétricos de los modelos, agravada por sesgos geográficos e institucionales. Las recomendaciones derivadas se articulan en quick

wins (landing pages por perfil de estudiante, optimización de la página de salidas profesionales), acciones estratégicas a medio plazo (presencia activa en el ranking de El Mundo, contenido de autoridad sobre Big Data) y líneas de largo plazo (hub de networking, ciclo trimestral de monitorización GEO). El sistema desarrollado es reutilizable para cualquier programa o institución y abre líneas futuras de investigación en validación longitudinal del impacto de las intervenciones de contenido sobre la visibilidad en LLMs.

6. Referencias

- Aggarwal, P., Murahari, V., Rajpurohit, T., Kalyan, A., Narasimhan, K., & Deshpande, A. (2024). *GEO: Generative Engine Optimization. En KDD 2024 — Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (pp. 5-16). Association for Computing Machinery*. <https://doi.org/10.1145/3637528.3671900>
- Bellan, R., & Forristal, L. (2025, October 6). *Sam Altman says ChatGPT has hit 800M weekly active users*. TechCrunch. Retrieved April 9, 2026, from <https://techcrunch.com/2025/10/06/sam-altman-says-chatgpt-has-hit-800m-weekly-active-users/>
- Gartner Predicts Search Engine Volume Will Drop 25% by 2026, Due to AI Chatbots and Other Virtual Agents*. (2024, February 19). Gartner. Retrieved April 9, 2026, from <https://www.gartner.com/en/newsroom/press-releases/2024-02-19-gartner-predicts-search-engine-volume-will-drop-25-percent-by-2026-due-to-ai-chatbots-and-other-virtual-agents>
- GPT-4o Model | OpenAI API*. (n.d.). OpenAI Developers. Retrieved May 19, 2026, from <https://platform.openai.com/docs/models/gpt-4o>
- Introducing Claude 3.5 Sonnet*. (2024, June 21). Anthropic. Retrieved May 19, 2026, from <https://www.anthropic.com/news/claude-3-5-sonnet>
- Models | Gemini API*. (2026, May 7). Google AI for Developers. Retrieved May 19, 2026, from <https://ai.google.dev/gemini-api/docs/models>
- Singh, S. (2026, March 25). *ChatGPT Statistics (2026) – Active Users & Growth Data*. DemandSage. Retrieved April 9, 2026, from <https://www.demandsage.com/chatgpt-statistics/>

GEO Analyzer – Visibility Analysis System for the ICAI Master in Big Data in LLMs

Autor: Arroyo Plaza, Paula

Director: Morrás Ruiz-Falcó, Carlos

Entidad Colaboradora: ICAI – Universidad Pontificia Comillas

ABSTRACT

Large Language Models (LLMs) have established themselves as primary information intermediaries, raising an unprecedented question for educational institutions: how is an academic program portrayed in the responses of ChatGPT, Claude or Gemini? This Master's Thesis develops GEO Analyzer, an end-to-end system that measures the visibility of the Master in Big Data of ICAI in the leading LLMs through 86 prompts $\times$ 3 models, computes Generative Engine Optimization (GEO) specific metrics, and visualises them in an interactive dashboard with a temporal monitoring module. Results reveal a GEO Score of 2.4/10 with a structural gap in organic visibility against competitors such as UC3M or UPM, and provide a reusable system scalable to any program or institution.

Keywords: Generative Engine Optimization (GEO), LLMs, ChatGPT, Claude, Gemini, digital visibility, higher education, NLP.

1. Introduction

The launch of ChatGPT in November 2022 triggered a transformation in how users search for information: by October 2025, ChatGPT had surpassed 800 million weekly active users (*Bellan & Forristal, 2025*) and was processing more than 2.5 billion queries daily (*Singh, 2026*). Gartner forecasts a 25% decline in traditional search engine volume before 2026, replaced by conversational assistants that synthesise information instead of returning links (*Gartner Predicts Search Engine Volume Will Drop 25% by 2026, Due to AI Chatbots and Other Virtual Agents, 2024*). This paradigm shift raises a critical question for any academic institution: when a prospective student asks an LLM about postgraduate programs, how does my program appear — or fail to appear? Visibility in LLMs is opaque, probabilistic and still barely studied, and this constitutes the central motivation of the present work, applied to the Master in Big Data of ICAI – Universidad Pontificia Comillas.

2. Project Definition

The project is articulated along two complementary lines. The first, of a research nature, designs a controlled experiment that evaluates the visibility of the Master through 86 prompts organised into 8 thematic blocks (general recommendations, student and professional profiles, comparisons with competitors, ICAI-specific queries, etc.), executed against the three most widely adopted LLMs in the market: ChatGPT (GPT-4o) (*GPT-4o Model | OpenAI API, n.d.*), Claude (Sonnet 3.5) (*Introducing Claude 3.5 Sonnet, 2024*) and Gemini (2.0 Flash) (*Models | Gemini API, 2026*). The second, of a technological nature, materialises the analysis in a functional software system — GEO Analyzer — composed of

an acquisition module that calls the official APIs, an NLP processing module that extracts mentions, sources and qualitative attributes, and a web dashboard that synthesises the results into actionable metrics and supports temporal tracking through persistent snapshots.

3. System Description

GEO Analyzer is conceived as an end-to-end solution with three layers. The acquisition layer automates the dispatch of the 86 prompts to the OpenAI, Anthropic and Google APIs, storing the 258 responses (of which 244 were valid) with timestamp and metadata in JSON format. The processing layer applies NLP techniques based on spaCy and regular expressions to extract program mentions, normalise them to a canonical entity, identify cited sources (domains and typology), and compute three GEO metrics specific to the educational domain: Organic Presence Rate (OPR), First-Mention Position (FMP) and Mention Frequency (MF), aggregated into a composite GEO Score on a 0-10 scale. The visualisation layer is implemented as a React + TypeScript web application with a Supabase Cloud backend, offering eight interconnected views (Score, semantic Radar, analysis by block, by model, competitive, urls, conclusions and historical) and an automatic insight-generation module via an Edge Function connected to Gemini.

4. Results

The experiment reveals a clear pattern: ICAI shows an organic visibility of 2.2% in blocks without explicit mention of the program, compared to significantly higher rates from competitors such as UC3M, UPM or UPC, which are spontaneously mentioned in most responses to open queries. In contrast, reactive visibility — when the prompt names ICAI directly — reaches 94% in comparisons and 97% in specific questions, indicating that the issue is not one of recognition but of spontaneous activation. Factual quality is systematically low across the three models: no LLM provides fully correct information about the Master on specific questions (price, syllabus, partnerships, modality), with Gemini being the least evasive and Claude the most cautious. The global GEO Score for ICAI is 2.4/10, evidencing a structural positioning gap rather than an image problem, since the tone of mentions is predominantly positive or neutral. The source analysis shows that uc3m.es, upm.es, elmundo.es and topuniversities.com are the most cited domains by LLMs as authoritative references on postgraduate programs in Spain.

5. Conclusions

The work demonstrates that visibility in generative engines can be systematically measured, compared and monitored, and that GEO (*Aggarwal, P. et al., 2024*) emerges as a necessary evolution of classic SEO for an ecosystem in which LLMs progressively replace the search engine as the discovery touchpoint. In the case of ICAI, the results identify a gap in organic visibility that is not explained by the quality of the published content nor by the program's image, but by its limited activation capacity within the parametric weights of the models, exacerbated by geographic and institutional biases. The resulting recommendations are organised into quick wins (landing pages by student profile, optimisation of the career outcomes page), strategic medium-term actions (active presence in the El Mundo ranking, authority content on Big Data) and long-term lines (networking

hub, quarterly GEO monitoring cycle). The developed system is reusable for any program or institution and opens future research lines on the longitudinal validation of the impact of content interventions on LLM visibility.

6. References

- Aggarwal, P., Murahari, V., Rajpurohit, T., Kalyan, A., Narasimhan, K., & Deshpande, A. (2024). *GEO: Generative Engine Optimization. En KDD 2024 — Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (pp. 5-16). Association for Computing Machinery*. <https://doi.org/10.1145/3637528.3671900>
- Bellan, R., & Forristal, L. (2025, October 6). *Sam Altman says ChatGPT has hit 800M weekly active users*. TechCrunch. Retrieved April 9, 2026, from <https://techcrunch.com/2025/10/06/sam-altman-says-chatgpt-has-hit-800m-weekly-active-users/>
- Gartner Predicts Search Engine Volume Will Drop 25% by 2026, Due to AI Chatbots and Other Virtual Agents*. (2024, February 19). Gartner. Retrieved April 9, 2026, from <https://www.gartner.com/en/newsroom/press-releases/2024-02-19-gartner-predicts-search-engine-volume-will-drop-25-percent-by-2026-due-to-ai-chatbots-and-other-virtual-agents>
- GPT-4o Model | OpenAI API*. (n.d.). OpenAI Developers. Retrieved May 19, 2026, from <https://platform.openai.com/docs/models/gpt-4o>
- Introducing Claude 3.5 Sonnet*. (2024, June 21). Anthropic. Retrieved May 19, 2026, from <https://www.anthropic.com/news/claude-3-5-sonnet>
- Models | Gemini API*. (2026, May 7). Google AI for Developers. Retrieved May 19, 2026, from <https://ai.google.dev/gemini-api/docs/models>
- Singh, S. (2026, March 25). *ChatGPT Statistics (2026) – Active Users & Growth Data*. DemandSage. Retrieved April 9, 2026, from <https://www.demandsage.com/chatgpt-statistics/>

Índice de la memoria

Capítulo 1. Introducción	5
1.1 Motivación del proyecto	5
1.2 Objetivos	6
1.3 Alcance	7
Capítulo 2. Estado de la Cuestión	8
2.1 El dominio histórico de Google y el ecosistema SEO	8
2.2 La irrupción de los LLMs como motores de búsqueda generativos	9
2.3 Del SEO al GEO: el nuevo paradigma de visibilidad	10
2.4 Métricas de visibilidad en motores generativos	11
2.4.1 Métricas Propuestas	12
2.5 Visibilidad de programas formativos en LLMs: trabajos relacionados	13
Capítulo 3. Descripción de las Tecnologías	15
3.1 LLMs analizados (ChatGPT, Gemini, Claude)	17
3.1.1 ChatGPT (OpenAI) - GPT-4o	18
3.1.2 Google Gemini - Gemini 2.0 Flash	18
3.1.3 Claude - Sonnet 3.5 (Anthropic)	19
3.2 Herramientas de procesamiento y análisis de datos	20
3.2.1 Python y Librerías de NLP	20
3.3 Stack Frontend Y Plataforma De Desarrollo	21
3.4 Infraestructura Y Despliegue	23
Capítulo 4. Definición del Trabajo	26
4.1 Justificación	26
4.2 Objetivos	27
4.3 Metodología	28
4.3.1 Línea investigadora: análisis de visibilidad GEO	28
4.3.2 Línea de desarrollo software: sistema GEO Analyzer	33
4.4 Planificación y Estimación Económica	34
4.4.1 Planificación temporal	34
Capítulo 5. Sistema GEO Analyzer	39
5.1 Visión general del sistema	39
5.2 Flujo de funcionamiento	40
Capítulo 6. Investigación: Análisis de Visibilidad GEO	42
6.1 Diseño del experimento	42
6.1.1 Definición de queries de evaluación	43
6.1.2 Protocolo de consulta y ejecución	49
6.1.3 Variables de análisis y métricas GEO	50

Capítulo 7. Análisis de Resultados	53
7.1 Validación Del Sistema	53
7.2 Evaluación De Las Métricas GEO Obtenidas	53
7.3 Discusión Y Comparativa	65
7.4 Análisis Del Sesgo	67
Capítulo 8. Dashboard	73
8.1 Objetivo del Dashboard	73
8.2 Flujo De Funcionamiento Del Sistema	74
8.3 Arquitectura Funcional Del Dashboard	74
8.3.1 Vista General	75
8.3.2 Evaluación Global De Visibilidad	76
8.3.3 Análisis Semántico	79
8.3.4 Análisis por contexto de consulta	81
8.3.5 Análisis comparativo entre LLMs	83
8.3.6 Análisis competitivo	85
8.3.7 Urls	88
8.3.8 Generación de insights	90
8.3.9 Histórico	94
Capítulo 9. Conclusiones y Trabajos Futuros	99
9.1 Conclusiones	99
9.1.1 Impacto de los LLMs en la toma de decisiones	101
9.2 Limitaciones del trabajo	101
9.3 Líneas de trabajo futuro	102
Capítulo 10. Bibliografía	104
ANEXO I: GLOSARIO DE TÉRMINOS, SIGLAS Y ANGLICISMOS	106
ANEXO II: Prompts	111

Índice de figuras

Figura 1. Arquitectura en tres capas del sistema GEO Analyzer.....	15
Figura 2. Cuota de mercado de los principales LLMs analizados (ChatGPT, Gemini, Claude).....	17
Figura 3. Flujo end-to-end del sistema GEO Analyzer: de los prompts a las recomendaciones.....	40
Figura 4. Heatmap de visibilidad de programas por bloque temático (escala de azul: oscuro >70%, medio 30-70%, claro <30%, blanco = sin mención).....	54
Figura 5. Frecuencia total de menciones por programa y modelo de lenguaje (rojo = ChatGPT, naranja = Claude, azul = Gemini).....	55
Figura 6. Distribución agregada de menciones por comunidad autónoma (datos consolidados de los tres LLMs).....	69
Figura 7. Distribución de menciones por comunidad autónoma desagregada por modelo (ChatGPT, Claude, Gemini).....	70
Figura 8. Identidad visual del dashboard GEO Analyzer.....	73
Figura 9. Vista principal del dashboard: resumen ejecutivo y KPIs globales.....	75
Figura 10. Vista "Score GEO": cálculo y desglose del Score GEO global.....	76
Figura 11. Vista "Radar GEO": análisis semántico de las dimensiones de atribución por LLM.....	79
Figura 12. Detalle del Radar GEO de ICAI: dimensiones fuertes y brechas frente a competidores	80
Figura 13. Vista "Por bloque": tasa de mención de ICAI por bloque temático y modelo.....	81
Figura 14. Vista "Por modelo": perfil comparativo de ChatGPT, Claude y Gemini.....	83
Figura 15. Vista "Competidores": análisis competitivo agregado por LLM.....	85
Figura 16. Vista "Urls".....	88
Figura 17. Vista "Conclusiones": insights generados automáticamente con IA (Gemini).....	90
Figura 18. Vista "Recomendaciones": plan de acción priorizado por horizonte temporal (quick wins, medio plazo, largo plazo).....	91
Figura 19. Detalle del plan de acción: quick wins y métricas de impacto esperado.....	92
Figura 20. Vista "Histórico": evolución temporal del Score GEO y la tasa de mención mediante snapshots.....	94

Índice de tablas

Tabla 1. Comparativa técnica de los tres LLMs analizados. Elaboración propia a partir de la documentación oficial (GPT-4o Model OpenAI API, n.d.) (Introducing Claude 3.5 Sonnet, 2024) (Gemini Developer API Pricing Gemini API, 2026).....	20
Tabla 2. Objetivos específicos y resultados esperados del proyecto.....	28
Tabla 3. Diagrama de Gantt del proyecto GEO Analyzer.....	35
Tabla 4. Estimación económica.....	38
Tabla 5. Bloques temáticos del corpus de prompts, propósito analítico y número de prompts por bloque.....	45
Tabla 6. Programas competidores seleccionados para el bloque "comparativa".....	47
Tabla 7. Perfiles de usuario cubiertos en los bloques de perfil_estudiante y perfil_profesional.....	49
Tabla 8. Versiones de API utilizadas en el experimento para cada LLM.....	49
Tabla 9. Variables del dataset analítico analisis_menciones.csv.....	51
Tabla 10. Tasa de mención de ICAI por bloque temático y LLM.....	56
Tabla 11. Distribución nº de menciones de ICAI por tono, por LLM.....	57
Tabla 12. Calidad factual de las respuestas sobre el Máster de ICAI: correcta, incompleta, incorrecta y evasiva, por LLM.....	58
Tabla 13. Volumen de citación por modelo sobre las 60 consultas. La media se calcula sobre las respuestas válidas.....	59
Tabla 14. Distribución porcentual de las URLs citadas según el tipo de fuente. Porcentajes sobre el total de URLs de cada modelo.....	60
Tabla 15. Veinte dominios más citados en bloques reactivos (suma de los tres modelos; n = 30 prompts).....	61
Tabla 16. Veinte dominios más citados en bloques espontáneos (suma de los tres modelos; n = 30 prompts).....	62
Tabla 17. Veinte URLs exactas más citadas en bloques reactivos (normalizadas; n = 30 prompts)....	63
Tabla 18. Veinte URLs exactas más citadas en bloques espontáneos (normalizadas; n = 30 prompts).....	64
Tabla 19. Dominios dominantes por bloque temático.....	65
Tabla 20. Razones principales de mención de programas competidores según los LLMs y posición media.....	68
Tabla 21. Cálculo detallado del Score GEO de ICAI: tasa por bloque y modelo, peso y contribución ponderada.....	77

CAPÍTULO 1. INTRODUCCIÓN

1.1 MOTIVACIÓN DEL PROYECTO

En los últimos años, los Modelos de Lenguaje de Gran Escala (LLMs) han experimentado una adopción masiva y acelerada, transformando profundamente la manera en que los usuarios buscan, consumen y confían en la información. Herramientas como *ChatGPT*, *Google Gemini*, *Claude* o *Perplexity* no solo responden preguntas: actúan como intermediarios activos entre el usuario y el conocimiento, sintetizando contenidos, emitiendo recomendaciones y, en definitiva, determinando qué entidades, productos o programas formativos son mencionados o invisibilizados en sus respuestas.

Este cambio de paradigma plantea una pregunta crítica para cualquier institución educativa: ¿cómo aparece mi oferta formativa cuando un potencial estudiante pregunta directamente a un LLM? A diferencia del ecosistema clásico del motor de búsqueda donde la visibilidad se mide a través de rankings, clics e impresiones indexables, la visibilidad en LLMs opera bajo una lógica distinta, opaca y aún poco estudiada, que comienza a denominarse *Generative Engine Optimization* (GEO).

Esta transformación tiene una magnitud cuantificable que conviene contextualizar. Según la consultora Gartner, el volumen de búsquedas en motores tradicionales caerá un 25 % antes de finales de 2026, a medida que los usuarios migran hacia asistentes conversacionales de IA que actúan como «motores de respuesta sustitutos» (Gartner, 2024). Datos complementarios de Statcounter y Search Engine Land confirman que la cuota de Google ya cayó por debajo del 90 % por primera vez desde 2015 a finales de 2024, lo que indica que la disrupción no es una proyección a futuro sino un fenómeno ya

en curso. En este contexto, la ausencia de una métrica objetiva de visibilidad en el nuevo canal generativo equivale para cualquier institución educativa a operar a ciegas en uno de los puntos de descubrimiento de mayor crecimiento global, y constituye la motivación central del presente Trabajo de Fin de Máster.

1.2 OBJETIVOS

El objetivo principal de este trabajo es diseñar, desarrollar y validar GEO Analyzer, un sistema de análisis de visibilidad que permita, para cualquier programa formativo:

(1) MEDIR su nivel de visibilidad actual en los principales LLMs mediante métricas reproducibles; (2) EXPLICAR los factores que condicionan ese posicionamiento, distinguiendo entre causas estructurales (sesgos geográficos, temporales e institucionales de los modelos) y causas de contenido (presencia y calidad de la información publicada); y (3) PRESCRIBIR acciones concretas y priorizadas que el equipo de comunicación de la institución puede ejecutar para mejorar dicha visibilidad, así como (4) MONITORIZAR el impacto de esas acciones a lo largo del tiempo mediante un sistema de snapshots persistentes.

La aplicación al caso concreto del Máster en Big Data de ICAI – Universidad Pontificia Comillas valida el sistema y proporciona, como subproducto, un diagnóstico real con recomendaciones accionables para este programa específico. En definitiva, el sistema no se limita a producir una puntuación agregada de visibilidad, sino que persigue responder de forma operativa tres preguntas que el equipo de comunicación de cualquier programa formativo necesita resolver: ¿dónde está mi programa hoy en los principales LLMs?, ¿por qué está donde está (qué factores estructurales y de contenido explican ese posicionamiento)? y ¿qué acciones concretas, priorizadas y medibles puedo emprender para mejorarlo? El enfoque adoptado pretende, por tanto, conectar la métrica con la decisión, evitando el riesgo de generar un diagnóstico cuantitativo desconectado de la práctica.

1.3 ALCANCE

El presente proyecto abarca el análisis de la visibilidad del Máster en Big Data de ICAI en los tres LLMs de mayor cuota de mercado a la fecha de realización del trabajo, seleccionados por concentrar de forma agregada más del 80% del tráfico mundial de uso de IA generativa: ChatGPT (OpenAI), con 800 millones de usuarios activos semanales y más de 2.500 millones de consultas diarias (*TechCrunch*, 2025); Gemini (Google), con aproximadamente 400 millones de usuarios activos mensuales tras un crecimiento del 300% desde octubre de 2024 (*Views4You*, 2025); y Claude (Anthropic), que concentra el 21% del tráfico global de uso de LLMs con especial penetración en entornos empresariales (*Views4You*, 2025). Los tres modelos ofrecen además API pública estable, condición necesaria para la reproducibilidad del experimento. Otros sistemas como Perplexity AI, Grok o DeepSeek se excluyen del alcance inicial por su menor cuota de mercado y por presentar arquitecturas (sistemas de búsqueda en tiempo real en el caso de Perplexity) que requerirían un protocolo experimental diferente; quedan identificados como línea de trabajo futuro. El análisis se circunscribe a consultas relacionadas con la búsqueda de programas de posgrado en ciencia de datos, análisis de datos y Big Data en España.

CAPÍTULO 2. ESTADO DE LA CUESTIÓN

2.1 EL DOMINIO HISTÓRICO DE GOOGLE Y EL ECOSISTEMA SEO

Durante más de dos décadas, Google ha ejercido un dominio casi absoluto sobre el mercado de los motores de búsqueda a escala global. Según los datos recopilados por Statcounter, Google alcanzó su cota máxima de mercado en 2023, con un 92,90 % de todas las búsquedas mundiales, y aunque en el último trimestre de 2024 esta cifra cayó por debajo del 90 % por primera vez desde 2015 situándose en torno al 89,6 %, el buscador sigue procesando más de 5 billones de consultas al año, equivalentes a 9,5 millones de búsquedas por minuto. (*Search Engine Market Share Worldwide | Statcounter Global Stats, n.d.*) (*Search Engine Land, 2025*) En España y América Latina, la concentración es aún mayor. En el segmento móvil, la cuota de Google supera el 94 %, mientras que en desktop se mantiene por encima del 82 % a escala global. (*AboutChromebooks / StatCounter, 2025*) Este monopolio de facto ha convertido a la visibilidad en Google medida a través de la posición en las páginas de resultados de búsqueda (SERP) en uno de los activos estratégicos más valiosos para cualquier organización, institución educativa o negocio digital.

En respuesta a esta realidad, surgió hace más de tres décadas la disciplina del Search Engine Optimization (SEO), cuyo objetivo es mejorar la visibilidad orgánica de un sitio web en los resultados de los motores de búsqueda. Las métricas clásicas del SEO: posición media, tasa de clics (CTR), autoridad de dominio, perfil de backlinks, etc, han sido objeto de extensa investigación académica e industrial. Sin embargo, el propio ecosistema SEO ha

comenzado a experimentar una perturbación sin precedentes provocada por la irrupción de los modelos de lenguaje generativos.

2.2 LA IRRUPCIÓN DE LOS LLMs COMO MOTORES DE BÚSQUEDA GENERATIVOS

El lanzamiento de ChatGPT por OpenAI en noviembre de 2022 marcó un punto de inflexión en la historia de los sistemas de recuperación de información. La plataforma alcanzó 100 millones de usuarios activos mensuales, estableciendo un récord histórico de adopción que no había sido igualado por ninguna plataforma digital anterior. Desde entonces, su crecimiento no ha hecho sino acelerarse: a partir de datos oficiales de OpenAI reportados por su CEO Sam Altman en octubre de 2025, ChatGPT superó los 800 millones de usuarios activos semanales, procesando más de 2.500 millones de consultas diarias. *(Bellan & Forristal, 2025) (Singh, 2026).*

Este fenómeno no se limita a ChatGPT. Según datos de *Views4You* recogidos a mediados de 2025, Google Gemini cuenta con unos 400 millones de usuarios activos mensuales, con un crecimiento del 300 % desde octubre de 2024, impulsado por su integración nativa con el ecosistema Google. Por su parte, Claude (Anthropic) concentra el 21 % del tráfico global de uso de LLMs con una penetración especialmente alta en entornos empresariales, donde el 45 % de su tráfico API proviene de clientes corporativos, mientras que Perplexity AI se consolida como la alternativa preferida para búsquedas con referencias en tiempo real. *(Musk & Fraser, 2025).*

Lo que distingue a estos sistemas de los motores de búsqueda tradicionales es su capacidad de síntesis: en lugar de devolver una lista de enlaces relevantes, los motores generativos procesan múltiples fuentes y producen una respuesta integrada y contextualizada directamente en la interfaz conversacional. Este modo de interacción representa un cambio cualitativo en la relación entre el usuario y la información: el usuario ya no navega entre

resultados, sino que delega en el modelo la selección, ponderación y síntesis del conocimiento relevante.

La magnitud de esta transformación ha llevado a la consultora Gartner a pronosticar que el volumen de búsquedas en motores tradicionales caerá un 25 % antes de finales de 2026, a medida que los usuarios migran hacia asistentes conversacionales de inteligencia artificial que actúan como «motores de respuesta sustitutos». Según Alan Antin, Vicepresidente Analista de Gartner, este desplazamiento obliga a las organizaciones a repensar íntegramente sus estrategias de visibilidad digital. (*Gartner Predicts Search Engine Volume Will Drop 25% by 2026, Due to AI Chatbots and Other Virtual Agents, 2024*)

2.3 DEL SEO AL GEO: EL NUEVO PARADIGMA DE VISIBILIDAD

La necesidad de optimizar la visibilidad en motores generativos en lugar de en motores de búsqueda clásicos ha dado lugar a un nuevo campo de investigación y práctica denominado Generative Engine Optimization (GEO). El trabajo fundacional de este campo fue publicado en la conferencia KDD 2024 (la principal conferencia mundial de minería de datos y descubrimiento de conocimiento) por investigadores de Princeton University: Aggarwal et al. definen GEO como «*un nuevo paradigma para ayudar a los creadores de contenido a mejorar su visibilidad en las respuestas de los motores generativos*», proporcionando un marco de optimización de caja negra y métricas específicas de impresión para los GEs. (*Aggarwal, P. et al., 2024*) El artículo introdujo GEO-bench, un benchmark de 10.000 consultas procedentes de múltiples dominios (derecho, historia, ciencia, comercio electrónico, entre otros), y demostró experimentalmente que las estrategias GEO correctamente aplicadas son capaces de incrementar la visibilidad de una fuente hasta en un 40 % en las respuestas de los motores generativos. Entre los métodos más efectivos se encontraron la adición de citas y referencias verificables, la incorporación de estadísticas cuantitativas y el uso de texto fluido y bien estructurado. Llamativamente,

técnicas clásicas del SEO como el keyword stuffing mostraron efectos nulos o incluso negativos en el contexto GEO. (Aggarwal, P. et al., 2024) Las diferencias estructurales entre SEO y GEO son profundas. En el SEO tradicional, la visibilidad se mide a través de métricas observables y reproducibles: posición en SERP, CTR orgánico, número de impresiones. En GEO, la visibilidad adopta una naturaleza probabilística y contextual: la presencia de una entidad en la respuesta de un LLM depende de la representación que el modelo tiene de dicha entidad en sus pesos internos, del corpus con el que fue entrenado y de la formulación concreta de la consulta. Esto introduce una opacidad que hace que la medición de la visibilidad GEO sea un problema de investigación no trivial y que requiere metodologías específicas.

Trabajos recientes como el de AutoGEO (ResearchGate, 2025) han extendido el marco de Aggarwal et al. hacia enfoques de aprendizaje automático que permiten reescribir automáticamente el contenido web para maximizar su inclusión en las respuestas generativas. Por otro lado, la línea de investigación sobre E-GEO (MIT/Columbia, 2025) traslada el problema al entorno del comercio electrónico, demostrando que los señales de optimización para GEO divergen significativamente del manual de SEO clásico. (Columbia University & MIT, 2025) (AutoGEO, 2025)

2.4 MÉTRICAS DE VISIBILIDAD EN MOTORES GENERATIVOS

Uno de los desafíos centrales del GEO es la definición de métricas de visibilidad adecuadas. A diferencia de los motores de búsqueda tradicionales, donde la posición en la SERP es un indicador claro y directamente observable, la noción de «visibilidad» en un LLM es multidimensional. Aggarwal et al. proponen el concepto de *impression score*, que combina tres componentes:

- el recuento ponderado de palabras de la fuente presentes en la respuesta generada, ajustado por la posición en la que aparecen

- la frecuencia de citación explícita
- una valoración subjetiva de la calidad de la representación, calculada mediante GPT-3.5. (Aggarwal, P. et al., 2024)

Investigaciones posteriores, como la de E-GEO (2025), han señalado que el impression score carece de interpretación económica directa, proponiendo en su lugar métricas basadas en el ranking posicional dentro de la respuesta del motor generativo, que resultan más reproducibles y directamente vinculables a comportamientos observables del usuario (como las tasas de conversión). (Columbia University & MIT, 2025)

2.4.1 MÉTRICAS PROPUESTAS

Las métricas académicas anteriores miden la visibilidad de forma agregada y son útiles para benchmarks generalistas, pero resultan insuficientes para guiar las decisiones operativas de un equipo de marketing universitario. Desde la perspectiva de un director de comunicación o admisiones, lo relevante no es solo "cuánto aparece mi programa" sino "POR QUÉ aparece (o no) y QUÉ puedo hacer al respecto". Sobre esta base, este trabajo propone un cuadro de métricas GEO específico para el dominio educativo, organizado en cuatro ejes accionables:

1. Visibilidad orgánica vs reactiva. Tasa de Presencia Orgánica (TPO) — aparición espontánea del programa en respuestas a prompts abiertos (sin mencionarlo) — y Tasa de Presencia Reactiva — aparición cuando el prompt nombra explícitamente el programa. La brecha entre ambas indica si el problema es de descubrimiento (orgánica baja, reactiva alta) o de imagen (ambas bajas).
2. Corrección y completitud factual. Para los atributos clave que un estudiante potencial pregunta antes de matricularse — precio, temario, modalidad, horarios, prácticas, salidas profesionales, calidad/ranking — qué porcentaje de respuestas son correctas, incompletas, evasivas o incorrectas. Esta métrica conecta directamente con la estrategia de contenido: si los LLMs no dan información completa sobre el precio, probablemente la página web del programa no lo expone de forma claramente extraíble.

3. Ranking competitivo frente a prompts estándar. Posición de Primera Mención (PPM) y Frecuencia de Mención (FM) del programa frente a competidores, para los 5-10 prompts que representan el comportamiento real del candidato ("¿qué máster en Big Data me recomiendas?", "compárame X con Y", etc.). Este ranking es el equivalente generativo del ranking SERP del SEO clásico.

4. Análisis de fuentes de autoridad. Qué dominios cita el LLM como respaldo de sus afirmaciones sobre el programa: el dominio institucional propio (comillas.edu), rankings de terceros (elmundo.es, topuniversities.com), portales de empleo, medios, etc. Esta métrica revela qué fuentes "educan" a los modelos sobre el programa y sobre cuáles hay margen de acción (presencia en rankings, RRPP en medios, etc.).

Estas cuatro dimensiones se operacionalizan en el cap 6.1.3 como métricas concretas (TPO, PPM, FM, calidad factual y análisis de fuentes) que alimentan el Score GEO agregado y las visualizaciones del dashboard.

2.5 VISIBILIDAD DE PROGRAMAS FORMATIVOS EN LLMs: TRABAJOS RELACIONADOS

La aplicación del paradigma GEO al ámbito educativo es un área de investigación emergente y con escasa cobertura en la literatura académica. Lo más próximo al objeto de este trabajo es el análisis de cómo los LLMs representan a instituciones académicas específicas. La investigación de Epoch AI (diciembre de 2025) sobre los patrones de uso de LLMs señala que el 58 % de los usuarios de IA utiliza estos sistemas principalmente para búsqueda de información, lo que incluye, de forma creciente, la búsqueda de programas formativos y recomendaciones educativas. (Ho, 2025)

Sin embargo, no existe a día de hoy ningún estudio publicado que evalúe sistemáticamente la visibilidad de programas de posgrado españoles en LLMs, constituyendo este trabajo una contribución original a dicho vacío.

En el plano del análisis de visibilidad de marca en LLMs, cabe destacar el trabajo de Kumar y Lakkaraju (2024), que demostró que es posible diseñar estrategias de prompting para aumentar la visibilidad de productos en las respuestas generativas, abriendo al mismo tiempo una línea de investigación sobre la manipulación ética y no ética de la visibilidad en estos sistemas. (Aggarwal, P. et al., 2024)(Kumar, A. & Lakkaraju, H., 2024) Este debate es relevante para el presente trabajo, que se posiciona en la vertiente de la medición objetiva y la propuesta de estrategias legítimas de mejora de contenido.

CAPÍTULO 3. DESCRIPCIÓN DE LAS TECNOLOGÍAS

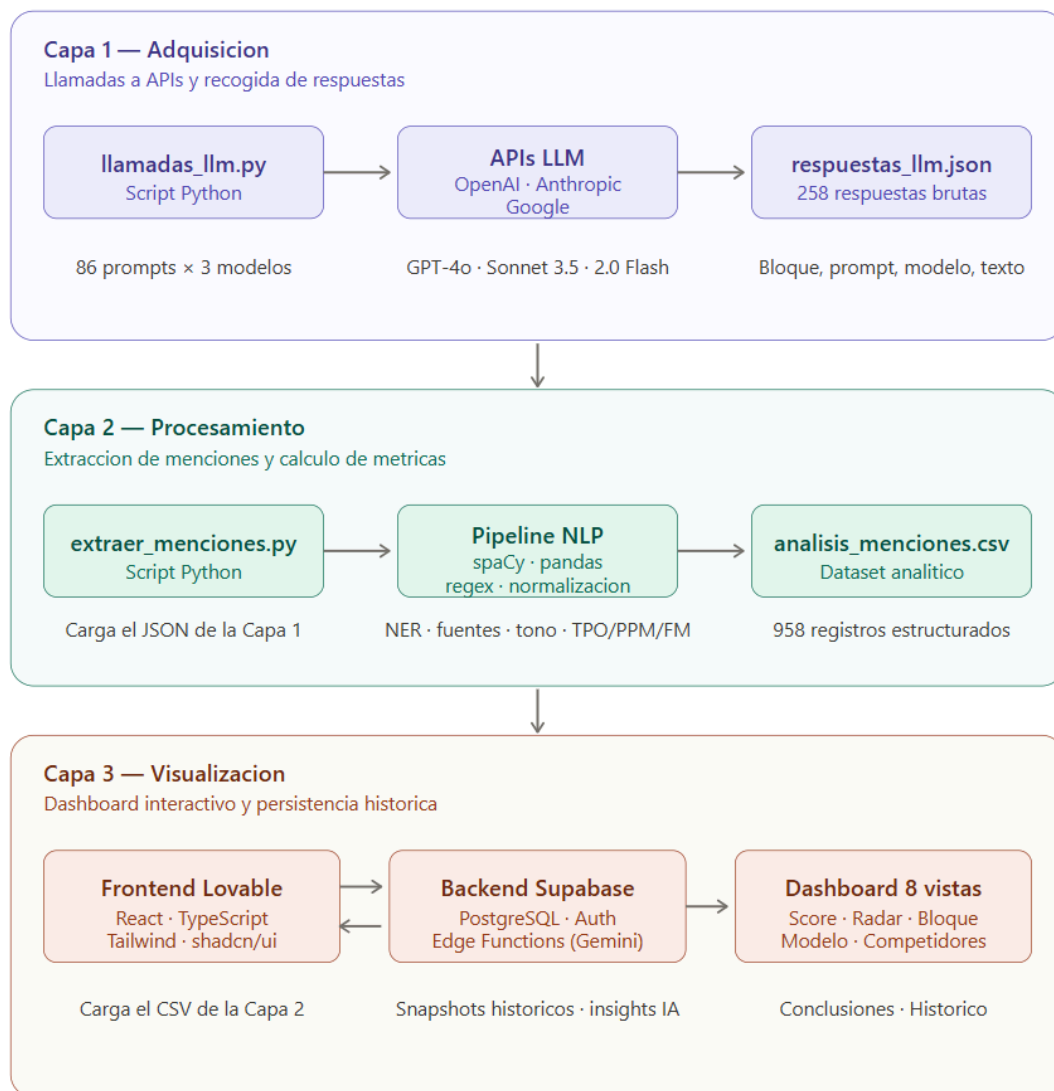


Figura 1. Arquitectura en tres capas del sistema GEO Analyzer

El sistema GEO Analyzer se ha diseñado como una solución end-to-end organizada en tres capas funcionales que se ejecutan en secuencia, representadas en la Figura 1. Cada capa transforma el producto de la anterior en una entrada de mayor valor analítico, desde las consultas crudas hasta el dashboard interactivo. Esta sección describe los componentes tecnológicos de cada capa, justificando las decisiones de diseño tomadas.

La Capa 1 — Adquisición (sección 3.1) automatiza la consulta a los LLMs y la recogida de respuestas. Un script Python (llamadas_ilm.py) ejecuta los 86 prompts del corpus contra las APIs oficiales de OpenAI (GPT-4o), Anthropic (Claude Sonnet 3.5) y Google (Gemini 2.0 Flash), almacenando las 258 respuestas brutas ($86 \text{ prompts} \times 3 \text{ modelos}$) junto con sus metadatos en un fichero JSON estructurado (respuestas_ilm.json). La selección de estos tres LLMs responde a su cuota de mercado mayoritaria y a la disponibilidad de API pública estable, condición necesaria para la reproducibilidad del experimento.

La Capa 2 — Procesamiento (sección 3.2) toma como entrada el JSON de respuestas y aplica un pipeline de NLP basado en spaCy, pandas y expresiones regulares. Un segundo script (extraer_menciones.py) realiza reconocimiento de entidades (NER) para detectar menciones de programas formativos, normaliza cada mención a una entidad canónica, identifica las fuentes citadas y calcula las tres métricas GEO específicas del trabajo (TPO, PPM y FM). El resultado es un dataset analítico tabular (analisis_menciones.csv) con 958 registros estructurados.

La Capa 3 — Visualización (secciones 3.3 y 3.4) consume el dataset analítico y lo materializa en una aplicación web full-stack: un frontend en React + TypeScript con Tailwind CSS y shadcn/ui, desplegado en Lovable Cloud, conectado a un backend en Supabase (PostgreSQL para persistencia, Auth para usuarios futuros, y Edge Functions con Gemini para la generación automática de insights). Esta capa expone un dashboard con ocho vistas analíticas más un módulo histórico de seguimiento temporal mediante snapshots persistentes.

Esta arquitectura en capas garantiza que cada componente sea sustituible o ampliable de forma independiente: introducir un nuevo LLM, cambiar el motor de NLP o reemplazar la

capa de visualización no exige rediseñar el resto del sistema. Las siguientes secciones detallan, para cada capa, las decisiones tecnológicas concretas y su justificación.

3.1 LLMs ANALIZADOS (CHATGPT, GEMINI, CLAUDE)

El análisis de visibilidad GEO requiere la evaluación sistemática de múltiples modelos de lenguaje de gran escala, cada uno con características, capacidades y comportamientos diferenciados. La selección de modelos se realizó atendiendo a dos criterios fundamentales: (1) cuota de mercado mayoritaria y disponibilidad mediante API pública, y (2) diversidad de arquitecturas y enfoques de entrenamiento para garantizar la robustez de los hallazgos.




Figura 2. Cuota de mercado de los principales LLMs analizados (ChatGPT, Gemini, Claude)

La selección de ChatGPT (GPT-4o), Google Gemini (2.0 Flash) y Claude (Sonnet 3.5) no es arbitraria; responde a que estos tres modelos representan los pilares fundamentales del ecosistema de búsqueda e inteligencia artificial actual, cubriendo más del 90% de la cuota de mercado combinada.

Para un estudio de optimización de motores generativos (GEO), la inclusión de este triunvirato es crítica debido a que sus motores de respuesta actúan de manera distinta ante

las fuentes de información web: mientras uno lidera la intención de búsqueda conversacional directa, otro está nativamente integrado con el motor de búsqueda más grande del mundo, y el tercero aplica filtros éticos y de veracidad ultra-estrictos que redefinen qué fuentes se consideran "confiables".

3.1.1 CHATGPT (OPENAI) - GPT-4o

ChatGPT, basado en el modelo GPT-4o desarrollado por OpenAI, representa el sistema más adoptado globalmente en términos de usuarios. Según datos de TechCrunch (2025), ChatGPT ha alcanzado 800 millones de usuarios activos semanales a octubre de 2025, procesando más de 2.500 millones de consultas diarias. El modelo fue entrenado con datos hasta abril de 2024 y utiliza una arquitectura de transformador optimizada para generación de lenguaje fluido y coherente. (OpenAI, 2025; TechCrunch, 2025)

En el contexto de este experimento, se utilizó la versión API gpt-4o, que ofrece:

- Mayor velocidad de respuesta comparada con versiones anteriores
- Soporte avanzado para context windows de hasta 128,000 tokens
- Capacidades mejoradas de razonamiento y síntesis de información
- Disponibilidad de función de visión para procesamiento de imágenes (no utilizada en este trabajo)

3.1.2 GOOGLE GEMINI - GEMINI 2.0 FLASH

Google Gemini representa el segundo modelo más adoptado globalmente, con aproximadamente 400 millones de usuarios activos mensuales a mediados de 2025, tras un crecimiento del 300% desde octubre de 2024 impulsado por su integración nativa en el ecosistema Google. La familia Gemini fue diseñada con un enfoque multimodal desde su concepción y se entrena continuamente con datos más recientes que ChatGPT, lo que potencialmente le confiere ventajas en información factual actualizada (Views4You, 2025; Google, 2025).

Para este análisis se utilizó Gemini 2.0 Flash, la variante optimizada para velocidad y eficiencia dentro del portafolio de Google, lanzada como modelo de producción a inicios

de 2025. Esta versión fue diseñada específicamente para casos de uso de alto volumen y baja latencia, ofreciendo:

- Inferencia ultrarrápida con tiempos de respuesta significativamente menores que Gemini 1.5 Pro, optimizada para consultas en tiempo real y aplicaciones interactivas
- Capacidades multimodales nativas que permiten procesar texto, imágenes, audio y video en una sola consulta
- Integración profunda con Google Search mediante grounding opcional, lo que permite recuperar información actualizada y verificable en tiempo real
- Ventana de contexto de 1 millón de tokens, permitiendo procesar documentos extensos y mantener conversaciones largas con latencia controlada
- Conocimiento base actualizado hasta agosto de 2024, complementado con la posibilidad de acceder a información más reciente a través de su integración con el buscador
- Salidas estructuradas y uso de herramientas (function calling), facilitando su integración en flujos de trabajo automatizados

3.1.3 CLAUDE - SONNET 3.5 (ANTHROPIC)

Claude, desarrollado por Anthropic, concentra el 21% del tráfico global de uso de LLMs con una penetración especialmente alta en entornos empresariales, donde el 45% de su tráfico API proviene de clientes corporativos. A diferencia de ChatGPT y Gemini, Claude adopta un enfoque de constitucional AI (Constitutional AI), entrenamiento que enfatiza la seguridad, honestidad y utilidad. Esto se traduce en un comportamiento más conservador ante incertidumbre factual. (*Views4You, 2025; Anthropic, 2025*)

Se utilizó Claude Sonnet 3.5, que ofrece:

- Balance óptimo entre velocidad y capacidad de razonamiento
- Context window de 200,000 tokens (el mayor de los tres modelos)
- Comportamiento más cauteloso ante datos no verificables
- Mejor desempeño en tareas de análisis detallado y escritura técnica

Aspecto	ChatGPT (GPT-4o)	Gemini 2.0 Flash	Claude Sonnet 3.5
Proveedor	OpenAI	Google	Anthropic
Context Window	128,000 tokens	1,000,000+ tokens	200,000 tokens
Enfoque Principal	Síntesis fluida	Multimodal	Constitutional AI
Fecha de corte	Octubre 2023	Junio 2024	Abril 2024

Tabla 1. Comparativa técnica de los tres LLMs analizados. Elaboración propia a partir de la documentación oficial (*GPT-4o Model* | *OpenAI API*, n.d.) (*Introducing Claude 3.5 Sonnet*, 2024) (*Gemini Developer API Pricing* | *Gemini API*, 2026)

3.2 HERRAMIENTAS DE PROCESAMIENTO Y ANÁLISIS DE DATOS

El análisis de visibilidad GEO se basa en un experimento controlado cuya configuración es parametrizable mediante tres variables: (1) el conjunto de prompts a ejecutar, (2) el número y categoría de bloques temáticos en que se agrupan, y (3) el conjunto de LLMs a interrogar.

La instancia concreta del experimento ejecutado en este trabajo utiliza $N = 86$ prompts agrupados en 8 bloques temáticos (definidos con detalle en el Cap 6.1.1), ejecutados sobre 3 LLMs (ChatGPT, Claude y Gemini, justificados en el Cap 3.1), lo que da un total de $86 \times 3 = 258$ respuestas.

Procesar este volumen requiere un stack tecnológico capaz de orquestar llamadas concurrentes a tres APIs distintas, parsear las respuestas en lenguaje natural, extraer las menciones de programas y normalizarlas, y agregar los resultados en métricas comparables. Las herramientas seleccionadas se describen a continuación.

3.2.1 PYTHON Y LIBRERÍAS DE NLP

Python 3.10+ se seleccionó como lenguaje principal debido a su ecosistema maduro de librerías científicas. Las librerías utilizadas incluyen:

- pandas: Manipulación y análisis de datos tabular. Proporciona DataFrames para operaciones eficientes sobre archivos CSV y JSON.

- `spacy`: Biblioteca de NLP industrial-grade para tokenización, reconocimiento de entidades (NER) y procesamiento de texto.
- `re` (regex): Expresiones regulares para detección de menciones de programas con patrones variables.
- `json`: Serialización y deserialización de respuestas de APIs.
- `datetime`: Timestamp y gestión de versiones temporales del dataset.

3.3 *STACK FRONTEND Y PLATAFORMA DE DESARROLLO*

3.3.1 *Lovable Cloud: Plataforma de Desarrollo Full-Stack*

Lovable Cloud es una plataforma de desarrollo de aplicaciones web construida sobre tecnologías modernas (React, Supabase, Vite) que proporciona un entorno integrado para crear y desplegar aplicaciones web sin necesidad de configuración manual de infraestructura.

Características principales:

- Desarrollo Full-Stack Integrado: Permite crear simultáneamente frontend (React + Tailwind) y backend (Supabase Edge Functions) sin salir del entorno.
- SupaBase Integrado: Proporciona una instancia de PostgreSQL + Auth + Real-time por defecto, eliminando la necesidad de configurar servidores de base de datos.
- Edge Functions: Funciones serverless ejecutadas en Supabase para lógica backend, específicamente usadas en GEO Analyzer para generación de conclusiones con Gemini 2.0 Flash.
- Deploy Automático: Integración con Git que permite despliegue automático con cada push a producción.
- Iteración Rápida: Hot reload y dev mode que permiten prototipado rápido sin compilación manual.

En el contexto de un TFM con ciclos de desarrollo iterativos y ágiles, la utilización de Lovable aporta varias ventajas clave. En primer lugar, permite un prototipado rápido sin la carga adicional asociada a tareas de DevOps. Además, ofrece un backend preconfigurado, evitando la necesidad de desarrollar una API REST desde cero.

Por otro lado, su simplicidad operativa, basada en el uso de un único proveedor como Supabase, reduce significativamente la complejidad derivada de la integración de múltiples servicios. Asimismo, proporciona escalabilidad automática mediante Edge Functions, facilitando la gestión de llamadas a APIs externas como OpenAI, Anthropic o Google.

Como alternativa, se podría haber optado por soluciones como Next.js combinado con Firebase o AWS Lambda. Sin embargo, estas opciones implican un mayor esfuerzo de configuración manual en aspectos como la arquitectura serverless, la autenticación y el despliegue, lo que habría incrementado la complejidad del desarrollo.

3.3.2 React 18, TypeScript

Se optó por React 18 como framework para el desarrollo del frontend debido a varias razones fundamentales. En primer lugar, destaca por la madurez de su ecosistema, que ofrece una amplia disponibilidad de librerías de componentes y herramientas de testing consolidadas.

Asimismo, la integración con TypeScript permite garantizar un mayor control de tipos, especialmente relevante en el cálculo y manejo de métricas dentro de la aplicación. Por último, el uso de componentes reutilizables facilita el desarrollo de un dashboard modular, mejorando la mantenibilidad y escalabilidad del sistema.

3.3.3 Tailwind CSS, shadcn/ui

Para la capa de estilos se ha empleado Tailwind CSS, un framework de tipo utility-first que permite definir la apariencia de la interfaz sin necesidad de escribir CSS personalizado.

Este enfoque acelera significativamente el desarrollo y contribuye a mantener una consistencia visual en toda la aplicación.

Por otro lado, se ha utilizado shadcn/ui como colección de componentes preconstruidos en React, tales como tarjetas (Card), pestañas (Tabs), botones (Button) y diálogos (Dialog), entre otros. Estos componentes se integran de forma nativa con Tailwind CSS, lo que facilita la construcción de interfaces coherentes, accesibles y altamente reutilizables, especialmente en el desarrollo del dashboard.

3.3.4 Herramientas de Visualización

Para la representación gráfica de los datos se ha utilizado Recharts, una librería de gráficos para React construida sobre D3.js. Esta herramienta permite generar visualizaciones interactivas de forma sencilla y flexible, siendo empleada en el desarrollo de distintos tipos de gráficos dentro de la aplicación, como mapas de calor (heatmaps) de visibilidad por bloque o modelo, gráficos de barras para analizar la frecuencia de menciones, gráficos de radar (Radar GEO) y visualizaciones de evolución temporal.

En cuanto a la iconografía, se ha optado por Lucide React, una librería de iconos en formato SVG que ofrece una amplia variedad de recursos visuales. Su integración con Tailwind CSS permite adaptar fácilmente los iconos en términos de tamaño y color, contribuyendo a una interfaz consistente y visualmente coherente.

3.4 INFRAESTRUCTURA Y DESPLIEGUE

3.4.1 SupaBase

Supabase se ha empleado como solución de *Backend as a Service (BaaS)*, actuando como la capa backend integral de la aplicación GEO Analyzer. Esta elección permite abstraer gran parte de la complejidad asociada al desarrollo backend, proporcionando servicios listos para su uso y facilitando la escalabilidad del sistema.

Base de datos (PostgreSQL)

SupaBase integra una base de datos relacional basada en PostgreSQL, utilizada para el almacenamiento estructurado de la información. En el contexto de GEO Analyzer, esta base de datos permite gestionar potencialmente las sesiones de análisis (especialmente en futuras versiones), así como registrar auditorías de las llamadas a APIs externas. Además, ofrece mecanismos de escalabilidad automática que garantizan un rendimiento adecuado ante incrementos en la carga.

Edge Functions

Las Edge Functions de Supabase son funciones *serverless* que se ejecutan de forma distribuida en su red global, permitiendo procesar lógica backend sin necesidad de gestionar infraestructura propia.

En GEO Analyzer, se ha implementado una Edge Function denominada *geo-conclusions*, cuya finalidad es automatizar la generación de conclusiones a partir de los datos analizados. Concretamente, esta función se encarga de invocar la API Gemini 2.0 Flash mediante un *prompt* estructurado, generar un análisis narrativo en lenguaje natural y procesar la respuesta en formato JSON para su posterior uso en el frontend.

Autenticación (SupaBase Auth)

Supabase también proporciona un sistema de autenticación integrado que permite la gestión de usuarios mediante el uso de tokens JWT seguros. Aunque esta funcionalidad no es crítica en la versión actual del sistema, se contempla su incorporación en futuras iteraciones para habilitar características como el registro de usuarios y la persistencia de sesiones personalizadas.

3.4.2 Deployment y Hosting

La arquitectura adoptada, basada en Lovable y Supabase, permite un proceso de despliegue sencillo y automatizado, apoyándose en servicios gestionados para cada capa de la aplicación.

En concreto, el frontend desarrollado en React se despliega en la plataforma Vercel, optimizada para aplicaciones modernas basadas en frameworks JavaScript. Por su parte, el backend, incluyendo la base de datos y las Edge Functions, se aloja en Supabase Cloud, lo que garantiza una integración nativa entre los distintos servicios backend.

Adicionalmente, el sistema permite la configuración de un dominio personalizado —como, por ejemplo, el dominio institucional `comillas.edu`—, facilitando su integración en entornos académicos o corporativos.

El proceso de despliegue sigue un flujo automatizado basado en integración continua. Cada commit realizado en el repositorio activa un webhook en Vercel, que inicia el proceso de build de la aplicación. Una vez completada la compilación, el sistema realiza automáticamente el despliegue de la nueva versión, garantizando así una actualización rápida y eficiente del sistema.

CAPÍTULO 4. DEFINICIÓN DEL TRABAJO

4.1 JUSTIFICACIÓN

El presente trabajo nace de la confluencia de dos tendencias que se desarrollan en paralelo y cuya intersección genera una oportunidad de investigación inédita en el contexto español. Por un lado, el auge exponencial de los LLMs como intermediarios de información, donde ChatGPT ha superado los 800 millones de usuarios activos semanales (Bellan & Forristal, 2025) y Gartner prevé una caída del 25 % en el volumen de búsquedas en motores tradicionales antes de 2026 (*Gartner Predicts Search Engine Volume Will Drop 25% by 2026, Due to AI Chatbots and Other Virtual Agents, 2024*). Por otro, la ausencia total de herramientas o estudios que evalúen sistemáticamente cómo los programas de posgrado españoles son representados por estos modelos.

Desde el punto de vista institucional, la justificación es igualmente sólida. El Máster en Big Data de ICAI compite por captar talento con otros programas nacionales e internacionales en un mercado formativo altamente digitalizado. En este contexto, no disponer de una métrica objetiva de visibilidad en los sistemas de IA conversacional equivale a operar a ciegas en uno de los canales de descubrimiento de mayor crecimiento global. El 58 % de los usuarios de herramientas de IA las emplea principalmente para búsqueda de información (Ho, 2025), lo que incluye, de forma creciente, decisiones de elección de programa formativo.

A nivel académico, la justificación se apoya en la identificación de un vacío en la literatura, aunque el campo GEO dispone ya de un trabajo fundacional referenciado: Aggarwal et al. (*KDD 2024*)(Aggarwal, P. et al., 2024), su aplicación al dominio de la

educación superior española no ha sido abordada en ningún estudio previo. Este TFM realiza por tanto una contribución original doble: empírica, al generar datos reales sobre visibilidad de un programa concreto en múltiples LLMs; y tecnológica, al desarrollar una herramienta reproducible y escalable para realizar dicho análisis de forma automatizada.

Finalmente, desde la perspectiva del propio programa de Máster en Big Data, este proyecto constituye una demostración aplicada de las competencias adquiridas a lo largo de la formación: diseño de experimentos de análisis de datos, integración de APIs, procesamiento de lenguaje natural, visualización de datos con Tableau, etc.

4.2 OBJETIVOS

El Objetivo general es diseñar, desarrollar y validar GEO Analyzer, un sistema de análisis de visibilidad que permita medir de forma sistemática y reproducible cómo el Máster en Big Data de ICAI es representado por los principales LLMs disponibles en el mercado, e identificar los factores que condicionan dicha visibilidad.

Objetivo específico	Resultado esperado
Revisar el estado del arte en SEO, GEO y visibilidad en LLMs.	Marco teórico consolidado con referencias bibliográficas verificadas.
Diseñar un protocolo de consulta estructurado para medir la visibilidad del Máster en múltiples LLMs.	Conjunto de queries validadas con protocolo de ejecución documentado.
Definir y calcular métricas de visibilidad GEO adaptadas al dominio educativo.	Score de visibilidad compuesto: presencia nominal, calidad descriptiva, posición relativa y consistencia entre modelos.
Analizar los resultados y comparar el posicionamiento del Máster de ICAI frente a programas competidores.	Análisis estadístico descriptivo y comparativo con visualizaciones interpretables.

Implementar el sistema GEO Analyzer con módulos de consulta, análisis y visualización.	<i>Aplicación web full-stack con frontend React/TypeScript y backend Supabase, que integra las APIs de OpenAI, Anthropic y Google y expone un dashboard interactivo con persistencia de snapshots.</i>
Proponer recomendaciones de mejora de visibilidad GEO basadas en evidencia empírica.	Informe de recomendaciones accionables para el equipo de comunicación del programa.

Tabla 2. Objetivos específicos y resultados esperados del proyecto

4.3 METODOLOGÍA

La metodología del proyecto se estructura en torno a dos líneas de trabajo paralelas y complementarias: la línea investigadora y la línea de desarrollo software. Ambas se desarrollan siguiendo un enfoque iterativo que permite incorporar los hallazgos de la investigación al diseño del sistema de forma continua.

4.3.1 Línea investigadora: análisis de visibilidad GEO

La metodología de investigación sigue un diseño experimental de tipo observacional y comparativo, articulado en las siguientes fases:

1. Diseño del protocolo de consulta. Se definirá un conjunto de queries de evaluación representativas de las búsquedas que un potencial estudiante realizaría a un LLM para encontrar programas de posgrado en big data y ciencia de datos en España.

```
# _____
# CONFIGURACIÓN DEL ESTUDIO
# _____

nicho = "máster en Big Data o Ciencia de Datos"
master_objetivo = "Máster en Big Data de ICAI (Universidad Pontificia Comillas)"

competidores = [
    "Máster en Big Data de ICAI (Universidad Pontificia Comillas)",
    "Máster en Data Science de KSchool",
```

```
"Máster en Big Data y Data Science de la Universidad Autónoma de
Madrid (UAM)",
"Máster en Big Data de la Universidad Politécnica de Madrid (UPM)",
"Máster en Big Data y Business Analytics de la Universidad
Complutense de Madrid (UCM)",
"Máster en Ciencia de Datos e Ingeniería de Computadores de la
Universidad de Granada (UGR)",
"Máster en Big Data Analytics de la Universidad de Valencia (UV)",
"Máster Universitario en Data Science de la Universitat Oberta de
Catalunya (UOC)",
"Máster en Big Data y Data Science de UNIR",
"Máster en Data Science y Big Data de la Universidad de Alcalá
(UAH)",
"Máster en Big Data de la Barcelona School of Management (UPF)",
]

# _____
# PERFILES DE USUARIO
# _____

perfiles_estudiante = [
    "un recién graduado en ingeniería de telecomunicaciones",
    "un graduado en ingeniería informática",
    "un estudiante de matemáticas o estadística recién graduado",
    "alguien con grado en ingeniería que quiere especializarse en datos",
]

perfiles_profesional = [
    "un ingeniero de software con experiencia que quiere pasarse a
datos",
    "un profesional del sector tecnológico que quiere reorientarse hacia
Big Data",
    "un analista de datos junior que quiere formarse mejor",
    "un ingeniero de telecomunicaciones trabajando que busca reciclarse",
]

# _____
# TEMPLATES POR BLOQUE
# _____

templates_recomendacion = [
    "¿Cuál es el mejor {} en España?",
    "¿Qué {} me recomiendas cursar en España?",
    "¿Cuáles son los {} más valorados en España?",
    "¿Cuál es el {} más reconocido por las empresas en España?",
    "Dame un ranking de los mejores {} en España",
    "¿Qué {} tienen mejor salida laboral en España?",
]

templates_perfil_estudiante = [
    "Soy {} y quiero hacer un {}. ¿Cuál me recomiendas en España?",
    "Tengo el perfil de {} y me interesa el {}. ¿Qué programa español me
conviene más?",
    "Como {}, ¿qué {} en España se adapta mejor a mi perfil?",
```

```

]

templates_perfil_profesional = [
    "Soy {} y quiero hacer un {}. ¿Cuál me recomiendas en España?",
    "Trabajo como {} y quiero especializarme con un {}. ¿Qué opciones hay en España?",
    "Como {}, ¿qué {} español me ayudaría más a avanzar profesionalmente?",
]

pares_comparacion = [
    ("Máster en Big Data de ICAI", "Máster en Data Science de KSchool"),
    ("Máster en Big Data de ICAI", "Máster en Big Data y Data Science de la UAM"),
    ("Máster en Big Data de ICAI", "Máster en Big Data de la UPM"),
    ("Máster en Big Data de ICAI", "Máster en Data Science de la UOC"),
    ("Máster en Big Data de ICAI", "Máster en Big Data y Data Science de UNIR"),
]

templates_comparativa = [
    "Compara el {} con el {} en términos de calidad y salidas laborales",
    "¿Cuál es mejor, el {} o el {}?",
    "¿En qué se diferencian el {} y el {}?",
    "Si tuviera que elegir entre el {} y el {}, ¿cuál me recomiendas?",
]

preguntas_especificas = [
    f"¿Qué temario tiene el {master_objetivo}?",
    f"¿Cuáles son las salidas profesionales del {master_objetivo}?",
    f"¿Cuánto cuesta el {master_objetivo}?",
    f"¿Qué requisitos de acceso tiene el {master_objetivo}?",
    f"¿Está bien valorado el {master_objetivo} por las empresas?",
    f"¿Qué empresas contratan a los egresados del {master_objetivo}?",
    f"¿Es presencial u online el {master_objetivo}?",
    f"¿Qué diferencia al {master_objetivo} de otros másteres similares?",
    f"¿Tiene el {master_objetivo} convenios con empresas o prácticas?",
    f"¿Qué opinan los alumnos del {master_objetivo}?",
]

# _____
# GENERACIÓN
# _____

def main():
    prompts = []

    for template in templates_recomendacion:
        prompts.append({"bloque": "recomendacion_general", "prompt": template.format(nicho)})

    for template in templates_perfil_estudiante:
        for perfil in perfiles_estudiante:
            prompts.append({"bloque": "perfil_estudiante", "prompt":

```



```
template.format(perfil, nicho), "perfil": perfil))

for template in templates_perfil_profesional:
    for perfil in perfiles_profesional:
        prompts.append({"bloque": "perfil_profesional", "prompt":
template.format(perfil, nicho), "perfil": perfil))

for par in pares_comparacion:
    for template in templates_comparativa:
        prompts.append({"bloque": "comparativa", "prompt":
template.format(par[0], par[1]), "par": list(par)})

for pregunta in preguntas_especificas:
    prompts.append({"bloque": "especifico_icaei", "prompt": pregunta})

with open('prompts.json', 'w', encoding='utf-8') as f:
    json.dump(prompts, f, indent=2, ensure_ascii=False)

bloques = {}
for p in prompts:
    b = p["bloque"]
    bloques[b] = bloques.get(b, 0) + 1

print(f"{len(prompts)} prompts generados:")
for bloque, n in bloques.items():
    print(f"    · {bloque}: {n}")

return prompts

if __name__ == "__main__":
    main()
```

generate_prompts.py

La estrategia de diseño de estos prompts se basa en la segmentación de la intención de búsqueda del usuario, cubriendo desde la exploración inicial hasta la decisión final. La decisión de estructurar los prompts mediante este script responde a tres pilares fundamentales:

a) Representatividad de los "Buyer Personas"

En lugar de generar preguntas genéricas, el script utiliza perfiles específicos (ingenieros, matemáticos, analistas junior). Esto permite evaluar si la IA es capaz de adaptar sus recomendaciones según el *background* académico y la experiencia profesional del usuario. Al diferenciar entre estudiantes recién graduados (que buscan empleabilidad y base técnica) y profesionales en activo (que buscan

reciclaje y prestigio), se garantiza que la respuesta del modelo sea puesta a prueba bajo contextos de necesidad real.

b) **Análisis Competitivo y de Diferenciación**

La inclusión de un bloque de comparativas directas entre el máster objetivo (ICAI) y sus competidores clave busca simular el escenario de "duelo de programas" que realizan los usuarios antes de matricularse. Esto no solo mide la objetividad de la IA, sino que permite extraer cuáles son los puntos fuertes y débiles percibidos en el mercado para cada par de instituciones, facilitando un análisis de posicionamiento relativo.

c) **Exhaustividad en las Dudas Operativas**

El bloque de consultas específicas está diseñado para atacar las dudas pragmáticas que suelen ser los "puntos de fricción" en la conversión: precio, modalidad, requisitos de acceso y convenios de prácticas. Al automatizar estas variantes, nos aseguramos de que la base de conocimientos de la IA sea precisa en los datos fácticos de ICAI, evitando alucinaciones en aspectos críticos como el coste o el temario del programa.

d) **Estructura Escalable y Sistemática**

Finalmente, el uso de templates permite una generación masiva pero controlada. Esta estructura garantiza que, ante cualquier cambio en el mercado o la aparición de un nuevo competidor, el sistema sea escalable. La organización por bloques facilita un análisis posterior de resultados mucho más limpio, permitiendo identificar en qué áreas (recomendación, comparación o información técnica) la IA ofrece un mejor desempeño.

2. **Definición de métricas GEO.** Se adaptará el *impression score* al dominio educativo, incorporando dimensiones de veracidad, completitud, posición relativa y consistencia entre modelos.

3. **Ejecución del experimento.** Las consultas se lanzarán de forma sistemática contra las APIs de ChatGPT (GPT-4o), Claude (Sonnet) y Gemini (2.0 Flash).

4. **Análisis estadístico.** Se aplicarán técnicas de análisis de texto (NLP) para la extracción automática de menciones, y análisis estadístico descriptivo y comparativo sobre las métricas GEO calculadas.

5. **Elaboración de recomendaciones.** Los resultados se traducirán en recomendaciones concretas de mejora de la presencia del Máster en los LLMs, fundamentadas en la evidencia empírica obtenida.

4.3.2 Línea de desarrollo software: sistema GEO Analyzer

El desarrollo del sistema GEO Analyzer sigue una metodología ágil ligera (inspirada en Scrum), con iteraciones quincenales y entregables incrementales. Las fases del desarrollo son:

1. **Análisis de requisitos.** Definición de requisitos funcionales y no funcionales del sistema a partir de los objetivos de investigación y las necesidades del equipo del Máster.
2. **Diseño arquitectónico.** El sistema se estructura en tres módulos: (1) módulo de consulta a LLMs (integración de APIs), (2) módulo de análisis y cálculo de métricas GEO (Python/NLP), y (3) módulo de visualización e informes (React + TypeScript en Lovable Cloud).
3. **Implementación iterativa.** Desarrollo del código con Python como lenguaje principal, siguiendo buenas prácticas de ingeniería de software (control de versiones en Git, documentación de código, pruebas unitarias).
4. **Validación y pruebas.** Verificación de la corrección funcional del sistema mediante casos de prueba definidos, y validación de los resultados contra análisis manuales de referencia.

4.4 PLANIFICACIÓN Y ESTIMACIÓN ECONÓMICA

4.4.1 Planificación temporal

El proyecto se desarrolla en un periodo de seis meses, de enero a junio de 2026, con una dedicación estimada de 20 horas semanales. La Tabla3 muestra la distribución temporal de las actividades principales mediante un diagrama de Gantt simplificado.

Actividad / Fase	Ene	Feb	Mar	Abr	May
F1 – Revisión bibliográfica y estado del arte	•	•			
F2 – Diseño del protocolo de consulta GEO		•	•		
F3 – Definición de métricas GEO		•	•		
F4 – Análisis de requisitos del sistema		•			
F5 – Diseño arquitectónico del sistema			•		
F6 – Implementación módulo de consulta a LLMs			•	•	
F7 – Ejecución del experimento y recogida de datos				•	
F8 – Implementación módulo de análisis/NLP				•	•
F9 – Análisis estadístico de resultados					•
F10 – Implementación módulo de visualización					•
F11 – Elaboración de recomendaciones					•

F12 – Validación, pruebas y ajustes				•	
F13 – Redacción de la memoria del TFM			•	•	•

Tabla 3. Diagrama de Gantt del proyecto GEO Analyzer

4.4.2 Estimación económica

La estimación de costes del proyecto incluye exclusivamente los costes directos asociados al uso de APIs de LLMs, infraestructura cloud y licencias de software. No se incluye el coste laboral del autor, dado que el trabajo se enmarca en la formación académica. No obstante, se incluye una nota de referencia sobre el coste equivalente de mercado para contextualizar el valor del esfuerzo invertido.

El volumen estimado de tokens consumidos se calcula sobre la base de 500 consultas por modelo, con una longitud media de 800 tokens de entrada y 1.200 tokens de salida por consulta. Los precios utilizados corresponden a las tarifas publicadas por cada proveedor en el primer trimestre de 2025: (*OpenAI API Pricing, n.d.*) (*Pricing - Claude API Docs, n.d.*) (*Gemini Developer API Pricing | Gemini API, 2026*)

La tabla siguiente recoge la estimación económica completa del proyecto:

Concepto	Detalle / Justificación	Coste unitario	Coste total (€)
A. Costes de APIs de LLMs (fase de investigación)			
API OpenAI — GPT-4o	500 consultas × (800 input + 1.200 output tokens). Precio: \$2,50/M input · \$10,00/M output (<i>OpenAI API Pricing, n.d.</i>)	\$0,014 / consulta	~7,00 \$

API Anthropic — Claude Sonnet	500 consultas × misma estructura de tokens. Precio: \$3,00/M input · \$15,00/M output (<i>Pricing - Claude API Docs</i> , n.d.)	\$0,021 / consulta	~10,00 \$
API Google — Gemini 2.0 Flash	500 consultas × misma estructura de tokens. Precio: \$0,1/M input · \$0,4/M output (<i>Gemini Developer API Pricing Gemini API</i> , 2026)	\$0,00056 / consulta	~0,3 \$
Subtotal A — APIs LLMs (fase investigación)			~17,3 \$
B. Costes de APIs de LLMs (fase de desarrollo / pruebas)			
Llamadas de desarrollo y pruebas	Estimación: 30 % adicional sobre el volumen de investigación para iteraciones de desarrollo, depuración y validación del sistema.	—	~10,35 \$ (~9,5 €)
Subtotal B — APIs LLMs (desarrollo)			~10,35 \$ (~9,5 €)
C. Infraestructura cloud			
Google Cloud / AWS Free Tier	Ejecución del backend Python en instancia t2.micro (AWS) o equivalente. Capa gratuita aplicable durante los 6 meses del proyecto.	0 € / mes	0,00 €
Almacenamiento de datos (S3 / GCS)	SupaBase (BaaS)	0 €	0 €

Subtotal C —			0 €
Infraestructura cloud			
D. Licencias de software			
Python + librerías open source	Python, pandas, openai, anthropic, google-generativeai, spacy.... Todas con licencia gratuita (MIT / Apache 2.0).	0 €	0,00 €
Tableau Public	Versión gratuita para uso académico y publicación de visualizaciones.	0 €	0,00 €
Lovable Cloud	Plan gratuito	0 €	0 €
Microsoft Excel	Licencia académica incluida en el paquete Microsoft 365 disponible a través de ICAI.	0 €	0,00 €
Git / GitHub	Control de versiones. Plan gratuito para repositorios privados.	0 €	0,00 €
Subtotal D — Licencias			0,00 €
Resumen de costes			
COSTE TOTAL ESTIMADO DEL PROYECTO			~27,65€ *

Tabla 4. Estimación económica

CAPÍTULO 5. SISTEMA GEO ANALYZER

5.1 VISIÓN GENERAL DEL SISTEMA

El presente trabajo no se limita a un análisis puntual de visibilidad, sino que propone el desarrollo de GEO Analyzer, un sistema integral orientado a la medición, interpretación y optimización de la presencia de una entidad en motores generativos.

GEO Analyzer se concibe como una solución end-to-end compuesta por tres capas principales:

- Capa de adquisición de datos, encargada de generar consultas estructuradas a distintos modelos de lenguaje (LLMs) y recoger sus respuestas.
- Capa de procesamiento y análisis, donde se transforman las respuestas en métricas cuantificables de visibilidad (menciones, scores, posicionamiento relativo, etc.).
- Capa de visualización y decisión, materializada en un dashboard interactivo que permite interpretar los resultados y derivar acciones estratégicas.

Este enfoque permite no solo analizar el estado actual de visibilidad, sino también establecer un sistema reproducible y escalable para su monitorización continua.

5.2 FLUJO DE FUNCIONAMIENTO




Figura 3. Flujo end-to-end del sistema GEO Analyzer: de los prompts a las recomendaciones

La Figura 3 presenta el flujo end-to-end de GEO Analyzer, desde la formulación de los prompts iniciales hasta la entrega de recomendaciones estratégicas al equipo de marketing. El sistema se compone de cuatro bloques funcionales que se ejecutan en secuencia y que se desarrollan en detalle a lo largo de los siguientes capítulos:

(1) Definición y consulta: se elabora el conjunto de prompts, se envían sistemáticamente vía API a ChatGPT, Claude y Gemini siguiendo el protocolo descrito en el Cap. 6.1.2, y se almacenan las respuestas en bruto en un fichero JSON estructurado (`respuestas_llm.json`).

(2) Motor de análisis GEO: el núcleo del sistema. Procesa el JSON aplicando técnicas de NLP para detectar menciones de programas, normalizarlas a entidades canónicas, extraer las fuentes citadas y calcular las métricas específicas TPO, PPM y FM. El resultado es un dataset analítico tabular que alimenta toda la capa de visualización.

(3) Dashboard interactivo: materializa los resultados en siete vistas analíticas (Score, Radar semántico, análisis por bloque, por modelo, competitivo, conclusiones, histórico) accesibles para perfiles no técnicos como directores de marketing o responsables académicos.

(4) Capa de IA generativa: una Edge Function conectada a Gemini sintetiza automáticamente los resultados cuantitativos en conclusiones narrativas y recomendaciones priorizadas, cerrando el ciclo desde el dato hasta la acción.

Este diseño en capas garantiza que cada componente sea sustituible o ampliable de forma independiente: añadir un nuevo LLM al experimento, incorporar nuevos prompts o redefinir las métricas no requiere rediseñar el resto del sistema, lo que hace de GEO Analyzer una herramienta reutilizable para cualquier programa o institución más allá del caso de uso de ICAI.

CAPÍTULO 6. INVESTIGACIÓN: ANÁLISIS DE VISIBILIDAD GEO

6.1 DISEÑO DEL EXPERIMENTO

El experimento se diseñó como un estudio observacional comparativo cuyo objetivo es medir y cuantificar la visibilidad del Máster en Big Data de ICAI en los principales modelos de lenguaje de gran escala disponibles en el mercado a fecha de febrero-marzo de 2026.

El experimento replica, de forma controlada y sistemática, el comportamiento real de un usuario que consulta a un LLM en distintos escenarios de búsqueda: desde preguntas abiertas sobre el mejor máster en big data en España, hasta comparativas directas entre programas específicos o consultas con perfil de usuario detallado. Esta variedad de escenarios permite diferenciar la visibilidad reactiva de ICAI de la visibilidad orgánica, que es la que aparece cuando el modelo no recibe ninguna señal directa sobre ICAI y decide o no incluirlo por sí mismo.

El diseño contempla dos rondas experimentales con propósitos diferenciados. La ronda principal evalúa la visibilidad orgánica y reactiva del programa mediante el corpus completo de 86 prompts ejecutados sobre los tres modelos, sin acceso a búsqueda web, de modo que las respuestas reflejen el conocimiento paramétrico de cada LLM (258 respuestas, de las cuales 244 resultaron válidas). Sobre esta ronda se calcula el Score GEO y las métricas de presencia, tono y calidad factual. Una segunda ronda, de auditoría de fuentes, persigue un objetivo distinto: determinar sobre qué evidencia concreta apoyan los modelos sus recomendaciones. Para ello se habilitó la herramienta de búsqueda web en tiempo real en las tres APIs y se reformularon los prompts para exigir la cita explícita de

las URLs de procedencia. Por restricciones de presupuesto de API, esta segunda ronda se limitó a un subconjunto de 60 prompts distribuidos entre los mismos bloques temáticos —30 de bloques reactivos y 30 de bloques espontáneos—, tamaño suficiente para caracterizar los patrones de citación sin replicar el corpus completo. Los resultados de esta segunda ronda se presentan de forma diferenciada en el apartado 7.2.5 y siguientes.

6.1.1 DEFINICIÓN DE QUERIES DE EVALUACIÓN

El diseño del conjunto de queries de evaluación es la piedra angular del experimento. La selección de prompts determina qué tipo de visibilidad se mide, en qué contextos y con qué intensidad de señal sobre el programa objeto de estudio. Para garantizar la validez y la representatividad del experimento, se siguieron tres criterios de diseño:

1. **Representatividad del comportamiento real del usuario.** Los prompts deben replicar consultas que un potencial estudiante realizaría de forma natural a un asistente conversacional, tanto en su formulación como en su intención informativa.
2. **Variedad de tipologías de intención.** El conjunto debe cubrir distintos niveles de especificidad (desde búsquedas abiertas hasta comparativas concretas) y distintos perfiles de usuario (recién graduado, profesional en activo).
3. **Control del nivel de señal sobre ICAI.** Es necesario incluir prompts que no mencionen a ICAI en absoluto (para medir visibilidad orgánica) junto a prompts que lo nombran explícitamente (para medir visibilidad reactiva y calidad de la representación).

El resultado es un corpus de 86 prompts organizados en ocho bloques temáticos, almacenados en el fichero *prompts.json* con estructura *{bloque, prompt}*. Todos los prompts incluyen además una instrucción explícita de solicitud de fuentes verificables, con el objetivo de enriquecer el análisis con datos sobre las fuentes que cada LLM utiliza para fundamentar sus respuestas.

Bloque	Propósito analítico	Prompts
recomendación general	Consultas abiertas sobre el mejor o más reconocido máster en Big Data o Ciencia de Datos en España, sin mencionar ningún programa. Incluye preguntas de ranking, valoración empresarial y salida laboral.	6
perfil_estudiante	Prompts en primera persona de recién graduados en ingeniería (telecomunicaciones, informática, matemáticas o ingeniería genérica) que buscan un máster en Big Data. Tres variantes sintácticas por perfil: 'Soy un...', 'Tengo el perfil de...' y 'Como un...'.	12
perfil_profesional	Análogo al anterior con perfiles de profesionales en activo: ingeniero de software que migra a datos, profesional tecnológico que se reorienta, analista junior, ingeniero de telecomunicaciones que busca reciclarse. Mis tres variantes sintácticas.	12
empleabilidad_sueldos	Preguntas sobre sueldo medio de graduados, salidas profesionales, tasa de empleabilidad, sectores de destino y tiempo de inserción laboral de los másteres en Big Data en España. No mencionan ICAI.	6

rankings_reputacion	Preguntas sobre rankings nacionales (El Mundo, QS) y reputación sectorial de los másteres en Big Data. Cuatro prompts incluyen referencia explícita a ICAI; dos son genéricos sobre el mercado.	6
networking_empresas	Consultas sobre convenios con empresas, bolsa de trabajo, red de contactos con el sector tecnológico y prácticas en empresa. Tres prompts son genéricos; tres preguntan específicamente por los convenios del Máster de ICAI.	6
comparativa	Comparativas directas entre el Máster en Big Data de ICAI y siete competidores (KSchool, UAM, UC3M, UCM, UPM, UOC, UNIR). Cuatro variantes por par: comparación neutral, evaluación de cuál es mejor, análisis de diferencias y recomendación condicionada.	28
especifico_icai	Preguntas factuales sobre el Máster de ICAI: temario, salidas profesionales, precio, requisitos de acceso, valoración empresarial, empresas contratantes, modalidad, diferenciadores, convenios y opiniones de alumnos.	10
TOTAL		86

Tabla 5. Bloques temáticos del corpus de prompts, propósito analítico y número de prompts por bloque

Diseño de variantes sintácticas

Una decisión metodológica clave fue la inclusión de variantes sintácticas para los bloques de perfil. Cada perfil de usuario se formula de tres maneras distintas —primera persona directa, declaración de perfil y perspectiva de tercera persona— con el objetivo de controlar el efecto que la formulación concreta del prompt tiene sobre la respuesta del LLM. Investigaciones previas en el campo del prompting han demostrado que pequeñas variaciones en la sintaxis pueden producir respuestas sensiblemente diferentes en los modelos generativos. Esta variedad permite calcular métricas de visibilidad más robustas, al promediar los resultados entre formulaciones y reducir el sesgo asociado a una única redacción.

Las tres variantes aplicadas a cada perfil son las siguientes:

- **Variante A — Primera persona directa:** *"Soy un recién graduado en ingeniería de telecomunicaciones y quiero hacer un máster en Big Data o Ciencia de Datos. ¿Cuál me recomiendas en España?"*
- **Variante B — Declaración de perfil:** *"Tengo el perfil de un recién graduado en ingeniería de telecomunicaciones y me interesa el máster en Big Data o Ciencia de Datos. ¿Qué programa me conviene más?"*
- **Variante C — Perspectiva de tercera persona:** *"Como un recién graduado en ingeniería de telecomunicaciones, ¿qué máster en Big Data o Ciencia de Datos en España se adapta mejor a mi perfil?"*

Selección de competidores en el bloque comparativa

La selección de estos siete competidores responde al criterio de relevancia inicial fijado por el equipo del Máster: programas con presencia consolidada en el segmento de posgrado en Big Data y Ciencia de Datos en España y que representan distintos perfiles institucionales (universidad pública, universidad privada, escuela online).

En sucesivas iteraciones del análisis sería conveniente ampliar este conjunto incorporando, en primer lugar, dos competidores especialmente relevantes por proximidad geográfica y

por su fuerte presencia en rankings empresariales y de tecnología: IE Business School / IE University y Universidad Rey Juan Carlos. En segundo lugar, otros programas que han emergido en los resultados del experimento cómo mencionados orgánicamente por los LLMs con frecuencia significativa — Universidad de Navarra, Universidad del País Vasco (UPV/EHU), Universidad de Granada, Universidad de Barcelona y ESADE — podrían incorporarse al conjunto de comparativas controladas para enriquecer el análisis competitivo.

El sistema GEO Analyzer está diseñado precisamente para que esta ampliación sea trivial: basta con añadir nuevos pares al fichero prompts.json y relanzar el experimento.

Programa	Institución	Tipo
Máster en Data Science	KSchool	Escuela privada
Máster en Big Data y Data Science	Universidad Autónoma de Madrid (UAM)	Universidad pública
Máster en Big Data Analytics	Universidad Carlos III de Madrid (UC3M)	Universidad pública
Máster en Big Data y Business Analytics	Universidad Complutense de Madrid (UCM)	Universidad pública
Máster en Big Data	Universidad Politécnica de Madrid (UPM)	Universidad pública
Máster en Data Science	Universitat Oberta de Catalunya (UOC)	Universidad online
Máster en Big Data y Data Science	Universidad Internacional de La Rioja (UNIR)	Universidad online

Tabla 6. Programas competidores seleccionados para el bloque "comparativa"

Para cada uno de estos siete pares ICAI - competidor se generaron cuatro variantes de prompt, resultando en los 28 prompts del bloque comparativo. Las cuatro variantes cubren distintos frames de decisión: comparación neutral ("*¿en qué se diferencian?*"), evaluación directa ("*¿cuál es mejor?*"), recomendación condicionada ("*si tuviera que elegir, ¿cuál me recomiendas?*") y análisis de calidad y salidas laborales ("*compara en términos de calidad y salidas laborales*").

Perfiles de usuario cubiertos

Los ocho perfiles de usuario cubiertos en los bloques de perfil representan los segmentos de potenciales estudiantes más frecuentes en un máster de estas características. La Tabla 7 los clasifica por tipología.

Tipología	Bloque	Perfil exacto
Recién graduado	perfil_estudiante	Ingeniería de telecomunicaciones
Recién graduado	perfil_estudiante	Ingeniería informática
Recién graduado	perfil_estudiante	Matemáticas o estadística
Recién graduado	perfil_estudiante	Ingeniería (genérico), quiere especializarse en datos
Profesional en activo	perfil_profesional	Ingeniero de software con experiencia que migra a datos
Profesional en activo	perfil_profesional	Profesional del sector tecnológico que se reorienta a Big Data
Profesional en activo	perfil_profesional	Analista de datos junior que busca formación avanzada
Profesional en activo	perfil_profesional	Ingeniero de telecomunicaciones en activo que busca reciclarse

Tabla 7. Perfiles de usuario cubiertos en los bloques de perfil_estudiante y perfil_profesional

6.1.2 PROTOCOLO DE CONSULTA Y EJECUCIÓN

La ejecución del experimento se llevó a cabo mediante un script Python (*llamadas_llm.py*) que automatiza el envío de los 86 prompts a cada uno de los tres modelos analizados, registrando las respuestas en formato JSON junto con el timestamp de ejecución. El número total de llamadas a API realizadas fue de 258 (86 prompts $\times$ 3 modelos).

Los tres modelos de lenguaje analizados fueron seleccionados por su cuota de adopción mayoritaria entre usuarios finales y su disponibilidad mediante API pública: ChatGPT (OpenAI), Claude (Anthropic) y Gemini (Google), detallados en el Cap 3.1. La Tabla 6 detalla las versiones exactas utilizadas en el experimento.

Proveedor	Modelo	Versión API	Nº llamadas
OpenAI	ChatGPT	gpt-4o	86
Anthropic	Claude	claude-3-5-sonnet-20241022	86
Google	Gemini	gemini-2.0-flash	86
TOTAL LLAMADAS			258

Tabla 8. Versiones de API utilizadas en el experimento para cada LLM

Las respuestas completas se almacenaron en el fichero *respuestas_llm.json*, con la estructura *{prompt, bloque, perfil, par, respuestas: {chatgpt, claude, gemini}, timestamp}*, que sirve como dato de origen (*raw data*) de todo el análisis posterior.

Una consideración relevante del protocolo es que los LLMs no tienen memoria entre sesiones: cada uno de los 86 prompts se ejecutó de forma independiente, sin contexto conversacional acumulado. Esto garantiza que cada respuesta refleja el conocimiento almacenado en los pesos del modelo sobre el programa, sin interferencia de respuestas

anteriores dentro del mismo experimento. Esta condición replica fielmente el escenario de un usuario que abre una nueva conversación con el asistente.

6.1.3 Variables de análisis y métricas GEO

A partir de las respuestas brutas almacenadas en *respuestas_llm.json*, se construyó el dataset analítico *analisis_menciones_corregido_final.csv* mediante un script de extracción y normalización (*extraer_menciones.py*). El dataset final contiene 958 registros, con una fila por cada programa mencionado en cada respuesta, y las siguientes variables:

Variable	Descripción	Tipo / Valores
bloque	Tipología del prompt que generó la respuesta	Categórica (8 valores)
perfil	Perfil de usuario especificado en el prompt, cuando aplica	Texto libre / vacío
llm	Modelo de lenguaje que generó la respuesta	chatgpt claude gemini
programamencionado_limpio	Nombre canónico normalizado del programa detectado en la respuesta	Categórica (21 programas)
posicion_primera_mencion	Posición de carácter en el texto de la respuesta donde aparece por primera vez el programa. Valores menores indican que el programa aparece antes (mayor prominencia).	Numérica entera (≥ 0)
frecuencia_menciones	Número de veces que el programa es referenciado a lo largo de toda la respuesta,	Numérica entera (≥ 1)

	como indicador de intensidad de la mención.	
es_icai	Indicador binario que señala si el programa detectado corresponde al Máster en Big Data de ICAI — Comillas.	Boolean (True / False)
fuelle	URL citada por el LLM en asociación con el programa mencionado, cuando el prompt solicitaba fuentes verificables.	URL / vacío

Tabla 9. Variables del dataset analítico analisis_menciones.csv

A partir de estas variables base, el análisis calcula tres métricas GEO adaptadas al dominio educativo:

– **Tasa de presencia orgánica (TPO):** porcentaje de respuestas orgánicas en las que el programa aparece mencionado de forma espontánea, es decir, sin que el prompt nombre a ICAI ni a la institución. Se calcula sobre las 90 respuestas orgánicas del experimento, resultantes de los 30 prompts de los bloques recomendacion_general, perfil_estudiante y perfil_profesional (6 + 12 + 12), cada uno respondido por los tres modelos evaluados (ChatGPT, Claude y Gemini).

Se verificó que ninguno de estos prompts nombra a ICAI, por lo que cada aparición refleja una decisión autónoma del modelo y no una respuesta inducida por la formulación de la pregunta. Esto convierte a la TPO en la métrica más relevante para el diagnóstico GEO, ya que mide la visibilidad real del programa en condiciones de búsqueda sin señal.

A efectos de este indicador se contabiliza como mención cualquier referencia identificable a la oferta de posgrado en datos de la Universidad Pontificia Comillas, incluidas las variantes en las que el modelo la atribuye a ICADE en lugar de a ICAI, ya que ambas remiten a la misma institución; bajo este criterio, la TPO de ICAI es del 2,2 % (2

menciones sobre 90 respuestas orgánicas). Cabe señalar, además, que ambas menciones fueron producidas por un único modelo (Claude), mientras que ChatGPT y Gemini no mencionaron a la institución en ninguna respuesta orgánica. Esta cifra contrasta de forma acusada con la de los principales competidores madrileños sobre el mismo conjunto de prompts: la UC3M alcanza una TPO en torno al 65,6 % (59/90) y la UPM en torno al 56,7 % (51/90).

- **Posición de primera mención (PPM):** posición de carácter en la respuesta donde aparece por primera vez el programa. Una posición menor indica que el programa aparece antes en el texto, lo que en términos de experiencia de usuario equivale a mayor prominencia. Este indicador complementa la TPO al medir no solo si el programa aparece, sino *cuándo* aparece dentro de la respuesta.
- **Frecuencia de mención (FM):** número total de referencias al programa a lo largo de la respuesta completa. Una frecuencia alta indica que el modelo dedica más espacio relativo al programa, lo que puede correlacionar con una percepción de mayor relevancia o con la estructura de la respuesta (por ejemplo, si el LLM desarrolla un análisis más detallado del programa).

La distinción entre visibilidad reactiva y orgánica es analíticamente fundamental. Los bloques comparativa y especifico_icaí generan visibilidad reactiva: el prompt menciona a ICAI explícitamente, por lo que la aparición del programa en la respuesta es esperable y no constituye evidencia de posicionamiento GEO. Los bloques recomendacion_general, perfil_estudiante y perfil_profesional generan visibilidad orgánica: el LLM decide autónomamente si incluir o no a ICAI en su respuesta, lo que refleja fielmente su representación interna del programa y constituye la evidencia empírica central de este trabajo.

CAPÍTULO 7. ANÁLISIS DE RESULTADOS

7.1 VALIDACIÓN DEL SISTEMA

Antes de interpretar los resultados, es necesario verificar que el sistema GEO Analyzer funcione correctamente y que los datos recogidos sean fiables y completos.

De las 258 llamadas a API ejecutadas (86 prompts $\times$ 3 modelos), 244 (94,6%) generaron respuesta válida. Los 14 fallos restantes corresponden a errores transitorios de la API de Gemini (`503 UNAVAILABLE`) durante el periodo de carga del servicio, sin afectar a ChatGPT (86/86 ok) ni Claude (86/86 ok).

Los 14 prompts con error en Gemini se distribuyen así: comparativa (6), recomendacion_general (2), perfil_estudiante (2), perfil_profesional (2), networking_empresas (1), especifico_icaei (1).

El análisis posterior se realiza sobre el conjunto de 244 respuestas válidas; cuando se calculan tasas por modelo el denominador para Gemini se ajusta en consecuencia para no introducir sesgo.

7.2 EVALUACIÓN DE LAS MÉTRICAS GEO OBTENIDAS

7.2.1 Visibilidad Por Bloques

Cómo leer la Figura 4: cada fila representa un programa de Big Data, identificado por sus siglas. Cada columna representa uno de los 8 bloques temáticos de prompts. La intensidad del color azul mide la frecuencia con la que el programa aparece en respuestas a prompts

de ese bloque (azul oscuro = >70%, azul medio = 30-70%, azul claro = <30%, blanco = nunca aparece). Lectura clave: una fila uniformemente clara indica un programa con visibilidad baja; una fila con celdas oscuras concentradas en pocos bloques indica un programa con visibilidad nicho (fuerte en algunos contextos, ausente en otros). ICAI es un caso claro del segundo tipo: oscuro solo en los bloques reactivos ('comparativa' y 'especifico_ica') y blanco en los bloques orgánicos.




Figura 4. Heatmap de visibilidad de programas por bloque temático (escala de azul: oscuro >70%, medio 30-70%, claro <30%, blanco = sin mención)

Cómo leer la Figura 5: Gráfico de barras de frecuencia. El eje X mide el número total de menciones del programa a lo largo de todos los prompts del experimento. Cada barra está dividida en tres segmentos de color, uno por modelo: rojo = ChatGPT, naranja = Claude, azul = Gemini. Lectura clave: la longitud total de la barra refleja la visibilidad total del programa; el reparto entre los tres colores indica si el programa es mencionado por igual en los tres modelos o si tiene mejor visibilidad en uno concreto. UC3M, UPM y UPC lideran con barras casi totalmente 'completas' en los tres colores; ICAI muestra una barra de longitud media con sesgo hacia el azul (Gemini) y el rojo (ChatGPT), y prácticamente nula contribución del naranja (Claude).




Figura 5. Frecuencia total de menciones por programa y modelo de lenguaje (rojo = ChatGPT, naranja = Claude, azul = Gemini)

El análisis competitivo distingue dos categorías de competidores: los competidores controlados (KSchool, UAM, UC3M, UCM, UPM, UOC y UNIR), incluidos a priori en el bloque comparativa con 4 variantes de prompt cada uno; y los competidores emergentes (IE Business School, ESADE, entre otros), que aparecen espontáneamente en las respuestas de los modelos a prompts de los bloques orgánicos. La presencia de IE como competidor emergente con tasa de mención muy elevada ($\approx 100\%$ en algunos contextos) es uno de los hallazgos más relevantes del estudio: revela que la batalla GEO real para ICAI no se libra solo contra las universidades públicas, sino también contra escuelas de negocio con fuerte presencia en rankings empresariales.

El análisis de visibilidad desagregado por bloques temáticos revela patrones diferenciados en la cobertura de programas. Los gráficos de heatmap y frecuencia de menciones muestran que:

- UC3M, UPM e IE concentran la mayor parte de las menciones espontáneas en bloques orgánicos (recomendacion_general y perfil)
- ICAI presenta visibilidad únicamente en bloques reactivos donde se menciona explícitamente
- Competidores secundarios como UPC, UOC y UNIR tienen presencia dispersa según contexto

7.2.2 Análisis desagregado por modelo: ChatGPT, Claude y Gemini

La Tabla 10 desagrega la tasa de mención de ICAI por bloque temático, las filas corresponden a los ocho bloques temáticos del experimento; las columnas, a los tres LLMs evaluados. Cada celda muestra el porcentaje de respuestas válidas de ese modelo en ese bloque en las que ICAI aparece mencionado. El código de color facilita la lectura rápida: verde para tasas $\geq 50\%$ (visibilidad alta), naranja entre 1% y 49% (visibilidad parcial) y rojo para 0% (ausencia total). El público objetivo de esta tabla son perfiles directivos y de marketing: el patrón que conviene retener es la dicotomía entre las dos filas verdes —*comparativa* y *específico_ICAI*, donde ICAI sí se menciona porque el prompt lo nombra— y las filas mayoritariamente rojas de los bloques orgánicos.

Bloque	ChatGPT	Claude	Gemini
comparativa	100%	100%	100%
empleabilidad_sueldos	0%	0%	0%
especifico_icai	100%	100%	100%
networking_empresas	50%	66%	40%
perfil_estudiante	0%	0%	0%
perfil_profesional	0%	8%	0%
rankings_reputacion	50%	50%	50%
recomendacion_general	0%	17%	0%

Tabla 10. Tasa de mención de ICAI por bloque temático y LLM

Gemini es el modelo que muestra mayor cobertura en los bloques reactivos, con una tasa de mención del 100% en *especifico_icai* y del 100% en *comparativa*. No obstante, al igual que ChatGPT, su tasa orgánica es del 0% en los bloques de perfil y recomendación general: Gemini no menciona a ICAI en ningún contexto de búsqueda abierta.

Claude presenta el comportamiento más matizado con un 17% en *recomendacion_general* y 8% en *perfil_profesional*.

ChatGPT muestra el comportamiento más polarizado: tasa del 100 % en los bloques donde ICAI se menciona explícitamente, pero 0 % en todos los bloques orgánicos. GPT-4o reconoce el programa cuando se le pregunta directamente, pero nunca lo recupera de forma autónoma.

La convergencia de este patrón entre los tres modelos refuerza la solidez del diagnóstico: no se trata de una idiosincrasia de un modelo concreto, sino de un patrón estructural.

7.2.3 Frecuencia y posición de primera mención

Cuando ICAI sí aparece en una respuesta —fundamentalmente en los bloques reactivos—, su frecuencia media de mención y su posición de primera mención son comparables a las de los programas competidores analizados en el mismo contexto. Esto indica que la calidad de la representación, una vez activada, es adecuada.

El análisis de posición de primera mención en el bloque comparativo muestra que ICAI tiende a aparecer en posiciones intermedias dentro de la respuesta, siendo los competidores de mayor reconocimiento (UC3M, UPM) quienes ocupan las posiciones más tempranas. El déficit de ICAI reside, por tanto, en el umbral de activación orgánica, no en la calidad del contenido generado cuando se le interpela directamente.

7.2.4 Tono de la información sobre ICAI

Modelo	Positivo	Neutro	Negativo	Total
ChatGPT	28 (97%)	1 (3%)	0 (0%)	29
Claude	6 (18%)	28 (82%)	0 (0%)	34
Gemini	24 (92%)	1 (4%)	1 (4%)	26

Tabla 11. Distribución nº de menciones de ICAI por tono, por LLM

ChatGPT menciona a ICAI en tono positivo en el 97 % de los casos, y Gemini en el 92 %. Claude, por su parte, presenta un 82 % de menciones neutras. Gemini es el único registro de valoración negativa de todo el experimento, anecdótico en términos estadísticos—. En

conjunto, no se registra ningún patrón de valoración negativa sistemática por parte de ningún modelo.

7.2.5 *Análisis de fuentes citadas*

Una de las limitaciones recurrentes señaladas en el análisis principal de este trabajo era la imposibilidad de saber sobre qué información concreta apoyaban los modelos de lenguaje sus recomendaciones. Saber qué páginas web consulta y cita realmente un sistema de inteligencia artificial cuando aconseja un programa de posgrado es especialmente valioso: permite auditar la calidad y la independencia de las fuentes, detectar posibles sesgos de marca o de autocita, y entender hasta qué punto la recomendación reproduce el ecosistema editorial existente (rankings, agregadores de posgrados, prensa) en lugar de un criterio propio.

Como se anticipó en la metodología (4.3.1), el análisis de fuentes corresponde a la segunda ronda experimental, diferenciada de la ronda principal de 86 prompts. Por este motivo se decidió repetir el experimento introduciendo dos cambios sustanciales. Primero, se modificaron los prompts añadiendo una instrucción explícita que obliga al modelo a basar la respuesta en información verificable y a adjuntar, en un apartado final, la lista de URLs concretas de procedencia de cada dato. Segundo, se habilitó en las tres APIs la herramienta de búsqueda web en tiempo real (web_search en OpenAI y Anthropic, y Google Search grounding en Gemini), de modo que las respuestas dejaran de depender únicamente del conocimiento paramétrico del modelo. Por restricciones de presupuesto la nueva ejecución se limitó a 60 prompts, distribuidos entre los mismos bloques temáticos del estudio original.

Tras procesar las 60 respuestas de cada modelo se extrajeron, normalizaron y clasificaron todas las direcciones citadas. La tabla 13 resume el volumen obtenido. Conviene leer estas cifras teniendo en cuenta las respuestas con error de API (límite de cuota o saturación temporal del servicio), que reducen el número de respuestas válidas en Claude y Gemini.

Modelo	Respuestas válidas	Errores de API	URLs citadas	Dominios únicos	Media URLs/resp.
ChatGPT	60	0	553	56	9.2

Claude	55	5	240	58	4.4
Gemini	56	4	368	68	6.6

Tabla 13. Volumen de citación por modelo sobre las 60 consultas. La media se calcula sobre las respuestas válidas.

El primer hallazgo es que la densidad de citación difiere mucho entre modelos. ChatGPT es el más prolífico (9,2 URLs por respuesta de media), Gemini se sitúa en una posición intermedia (6,6) y Claude es el más parco (4,4). Sin embargo, esta mayor verbosidad de ChatGPT no implica mayor diversidad: con 56 dominios únicos frente a los 68 de Gemini, ChatGPT repite más las mismas fuentes. La diversidad de fuentes y el volumen de citas no van, por tanto, de la mano.

Más relevante que el número de enlaces es su naturaleza. Cada dominio se clasificó en cinco categorías: webs oficiales de universidad o escuela de negocios (incluidos los micrositos propios de cada máster), prensa y rankings periodísticos, agregadores y portales de posgrados, bootcamps y centros de formación privados, y un grupo residual. La tabla 14 muestra el reparto porcentual por modelo.

Tipo de fuente	ChatGPT	Claude	Gemini
Universidad / Escuela (oficial)	47.4%	38.3%	59.5%
Prensa / Rankings periodísticos	0%	5.8%	13%
Agregador / Portal de posgrados	39.1%	40.8%	13.3%
Bootcamp / Centro privado	8%	2.1%	5.4%
Otros	5.6%	12.9%	8.7%

Tabla 14. Distribución porcentual de las URLs citadas según el tipo de fuente. Porcentajes sobre el total de URLs de cada modelo.

Aquí emergen perfiles de comportamiento claramente diferenciados. Gemini es el modelo que más se apoya en fuentes oficiales (59,5 % de sus citas son webs de universidades o escuelas) y el único que recurre de forma apreciable a prensa y rankings reconocidos (13 %, sobre todo El Mundo), lo que sugiere una estrategia de citación más institucional. ChatGPT reparte sus citas casi a partes iguales entre webs oficiales (47,4 %) y agregadores de posgrados (39,1 %), apoyándose mucho en portales comerciales del tipo quecursar.com o yaq.es. Claude es el que menos descansa en fuentes oficiales (38,3 %) y el que más

diversifica hacia agregadores (40,8 %) y prensa, ofreciendo el reparto más equilibrado pero también el menos verificable institucionalmente.

El análisis de las fuentes se presenta en dos niveles de granularidad complementarios. El nivel de dominio identifica en qué sitios web se apoyan los modelos (p. ej. comillas.edu); el nivel de URL exacta identifica la página concreta dentro de ese sitio (p. ej. la ficha del Máster Universitario en Big Data, y no la portada de la universidad). Este segundo nivel responde a la pregunta de en qué página específica entre cada modelo, y revela información que el agregado por dominio oculta: un mismo dominio puede recibir citas repartidas entre varias páginas distintas, y cada modelo tiende a fijar páginas diferentes.

Cada nivel se desglosa además en dos subconjuntos según la naturaleza del prompt: bloques reactivos (consultas que nombran explícitamente a ICAI o a la Universidad Pontificia Comillas: comparativa y específico de ICAI, n = 30 prompts) y bloques espontáneos (consultas orgánicas sin condicionar institución: recomendación general, perfil de estudiante y perfil profesional, n = 30 prompts). Las URLs se han normalizado unificando variantes de una misma página (con o sin parámetros de rastreo del tipo ?utm_source=openai, y con o sin barra final), de modo que cada fila representa una página real y no una variante de cadena.

La tabla 15 recoge los veinte dominios más citados en los bloques reactivos. Nombrar la institución en el prompt arrastra de forma masiva la respuesta hacia su dominio oficial.

#	Dominio	Citas	ChatGPT	Claude	Gemini
1	comillas.edu	195	93	29	73
2	unir.net	33	26	1	6
3	kschool.com	26	17	2	7
4	masteruambigdata.com	20	16	3	1
5	uoc.edu	15	14	1	0
6	elmundo.es	11	0	0	11
7	upm.es	11	6	0	5
8	estudios.uoc.edu	11	0	0	11
9	emagister.com	10	4	3	3
10	docenzia.com	8	4	4	0
11	tumaster.com	8	7	1	0

12	thedataschools.com	7	7	0	0
13	mastermania.com	7	0	4	3
14	educacion.gob.es	6	0	0	6
15	ebootcamp.net	5	4	1	0
16	maadm.etsisi.upm.es	5	5	0	0
17	uam.es	4	0	2	2
18	aprendemas.com	4	2	1	1
19	yaq.es	3	0	2	1
20	nosolomaster.com	3	0	3	0

Tabla 15. Veinte dominios más citados en bloques reactivos (suma de los tres modelos; n = 30 prompts).

La tabla 16 recoge los veinte dominios más citados en los bloques espontáneos. Al aislar las consultas orgánicas, *comillas.edu* desaparece del Top 20 y emergen agregadores comerciales y la Universidad Carlos III de Madrid como referente público.

#	Dominio	Citas	ChatGPT	Claude	Gemini
1	quecursar.com	59	48	11	0
2	yaq.es	45	45	0	0
3	uc3m.es	44	11	7	26
4	nosolomaster.com	42	42	0	0
5	educapption.com	32	32	0	0
6	elmundo.es	31	0	0	31
7	fib.upc.edu	24	4	0	20
8	iic.uam.es	20	20	0	0
9	masterdatascienceucm.com	18	10	8	0
10	mastermania.com	18	3	10	5
11	dondeestudiar.eu	16	4	12	0
12	topuniversities.com	16	0	0	16
13	ie.edu	15	0	0	15
14	unav.edu	14	8	6	0
15	muycomputerpro.com	14	0	14	0
16	cybereop.com	13	0	13	0
17	mundoposgrado.com	12	0	9	3
18	upc.edu	11	6	1	4
19	opendatacanarias.es	10	0	10	0
20	masterbigdataucm.com	10	0	10	0

Tabla 16. Veinte dominios más citados en bloques espontáneos (suma de los tres modelos; n = 30 prompts).

Las tablas 17 y 18 descienden al nivel de página concreta. La columna Modelo dominante indica qué modelo aporta más citas a esa URL, lo que evidencia que cada sistema tiende a fijar páginas distintas dentro de un mismo dominio.

La tabla 17 muestra las veinte URLs exactas más citadas en bloques reactivos. El dato más relevante es que el dominio comillas.edu no concentra sus citas en una única página: se reparten entre la ficha del Máster Universitario en Big Data (/postgrados/master-universitario-en-big-data, 80 citas), su versión en inglés, y la ficha de un máster distinto («Tecnología y Analítica Avanzada»). ChatGPT y Gemini privilegian páginas diferentes del mismo sitio.

#	URL exacta (normalizada, sin parámetros de rastreo)	Citas	Modelo dominante
1	comillas.edu/postgrados/master-universitario-en-big-data	80	ChatGPT (53)
2	kschool.com/master/master-ciencia-datos	19	ChatGPT (17)
3	comillas.edu/postgrado/master-en-big-data-tecnologia-y-analitica-avanzada	17	Gemini (16)
4	unir.net/ingenieria/master-visual-analytics-big-data	17	ChatGPT (12)
5	comillas.edu/en/postgraduate/master-universitario-en-big-data	16	ChatGPT (16)
6	comillas.edu/postgrados/master-en-big-data-tecnologia-y-analitica-avanzada	16	ChatGPT (16)
7	masteruambigdata.com/el-master	12	ChatGPT (11)
8	unir.net/ingenieria/master-big-data-ciencia-datos	12	ChatGPT (12)
9	tumaster.com/Master-en-Big-Data-Tecnologia-y-Analitica-Avanzada-MBD-mmasinfo1643701.htm	8	ChatGPT (7)
10	thedataschools.com/master-data-science/icai-comillas.html	7	ChatGPT (7)
11	masteruambigdata.com/	7	ChatGPT (4)
12	uoc.edu/es/estudios/masters/master-universitario-data-science.html	7	ChatGPT (7)
13	docenzia.com/master-en-big-data-tecnologia-y-analitica-avanzada-universidad-pontificia-comillas	7	ChatGPT (4)
14	estudios.uoc.edu/es/masters-universitarios/data-science/presentacion	6	Gemini (6)
15	uoc.edu/es/estudios/masters/master-universitario-data-science	6	ChatGPT (5)
16	educacion.gob.es/ruct/consultatitulo	6	Gemini (6)
17	ebootcamp.net/masters/kschool-master-data-science	5	ChatGPT (4)

18	upm.es/Estudiantes/Estudios_Titulaciones/Estudios_Master/Programas	5	ChatGPT (5)
19	maadm.etsisi.upm.es/	5	ChatGPT (5)
20	emagister.com/master-big-data-tecnologia-analitica-avanzada-mbd-cursos-3449850.htm	5	Claude (3)

Tabla 17. Veinte URLs exactas más citadas en bloques reactivos (normalizadas; n = 30 prompts).

La tabla 18 muestra las veinte URLs exactas más citadas en bloques espontáneos. Aquí cada modelo fija una página de referencia propia: ChatGPT recurre de forma casi invariable a la misma ficha de quecursar.com; Gemini, a la página de ranking de elmundo.es y a la ficha oficial de la UC3M; y Claude, a páginas de ranking divulgativo (cybereop.com, muycomputerpro.com).

#	URL exacta (normalizada, sin parámetros de rastreo)	Citas	Modelo dominante
1	quecursar.com/masters/big-data-y-data-science	48	ChatGPT (48)
2	nosolomaster.com/big-data	42	ChatGPT (42)
3	yaq.es/master/ciencia-e-ingenieria-de-datos	40	ChatGPT (40)
4	educapption.com/mejores-master-big-data	32	ChatGPT (32)
5	uc3m.es/master/big-data-analytics	25	Gemini (24)
6	iic.uam.es/innovacion/master-big-data-madrid	20	ChatGPT (20)
7	masterdatascienceucm.com/	18	ChatGPT (10)
8	uc3m.es/master/big-data	17	ChatGPT (10)
9	elmundo.es/especiales/mejores-master/informatica-software.html	14	Gemini (14)
10	muycomputerpro.com/2026/03/02/ranking-mejor-master-ia-esic	13	Claude (13)
11	unav.edu/web/master-en-big-data-science	12	ChatGPT (6)
12	cybereop.com/ranking-mejores-master-big-data-espana.html	12	Claude (12)
13	topuniversities.com/business-masters-rankings/business-analytics	12	Gemini (12)
14	dondeestudiar.eu/master/big-data	10	Claude (10)
15	opendatacanarias.es/master-big-data	10	Claude (10)
16	masterbigdataucm.com/	10	Claude (10)
17	mundoposgrado.com/ranking-master-big-data	9	Claude (9)

18	piweek.es/formacion/mbit-school	9	ChatGPT (9)
19	aprenderbigdata.com/mejor-master-big-data	8	Claude (6)
20	hosting04.uc3m.es/gdc/indicadores/titulaciones/master/CentroPostgrado_322.pdf	8	ChatGPT (8)

Tabla 18. Veinte URLs exactas más citadas en bloques espontáneos (normalizadas; n = 30 prompts).

El descenso al nivel de URL confirma y matiza las conclusiones del análisis por dominio. Primero, el sesgo reactivo no solo concentra las citas en el dominio objetivo, sino que las fija en una página concreta de captación del programa, lo que refuerza la interpretación de que el enunciado predetermina la evidencia recuperada. Segundo, y a diferencia de lo que sugería el agregado por dominio, sí aparecen fuentes primarias institucionales —aunque de forma minoritaria—: el registro oficial de títulos del Ministerio de Educación (educacion.gob.es/ruct/consultatitulo) y un PDF de indicadores oficiales de la UC3M figuran entre las veinte URLs más citadas. Procede por tanto matizar la afirmación de ausencia total de fuentes académicas primarias: existen, pero son marginales frente al ecosistema divulgativo y comercial dominante.

Un número muy elevado de las URLs citadas por ChatGPT incorporaba el parámetro `?utm_source=openai`. Este marcador, añadido por la infraestructura de búsqueda del modelo, constituye evidencia directa de que ChatGPT navegó la web en tiempo real para esas respuestas en lugar de responder desde su conocimiento paramétrico, y deja una huella auditable de su recuperación de información. En el caso de Gemini, las cifras reflejan únicamente las URLs presentes en el cuerpo de la respuesta y no sus metadatos de grounding; en los prompts sin dichos metadatos no es posible determinar si el modelo consultó la web, opacidad que es en sí misma un hallazgo sobre su falta de trazabilidad. Se han excluido del recuento las URLs de documentación técnica interna de los proveedores por no constituir fuentes educativas.

El cruce de las URLs con los bloques temáticos muestra que la fuente predominante cambia según lo que se pregunte, lo que confirma que estos sistemas no aplican un repositorio fijo sino que reorientan la búsqueda en función del enunciado.

Bloque temático

Tres dominios más citados (nº de citas)

Recomendación general	nosolomaster.com (15); quecursar.com (13); educapption.com (13)
Perfil estudiante	quecursar.com (35); yaq.es (19); uc3m.es (19)
Perfil profesional	uc3m.es (28); upc.edu (19); yaq.es (17)
Comparativa	comillas.edu (104); unir.net (35); uoc.edu (27)
Específico ICAI	comillas.edu (95); emagister.com (10); docenzia.com (7)

Tabla 19. Dominios dominantes por bloque temático.

Los bloques orientados a un perfil de usuario (recién graduado, profesional que se reorienta, etc.) se apoyan sobre todo en agregadores comerciales (quecursar.com, yaq.es, nosolomaster.com) y en la UC3M; las comparativas disparan las citas a webs oficiales de las universidades comparadas; y el bloque específico colapsa sobre el dominio institucional. La fuente no es neutra respecto a la pregunta: el tipo de consulta predetermina el tipo de evidencia que el modelo va a buscar y, por tanto, el sesgo que arrastrará la respuesta.

Conviene matizar la métrica de Gemini. En los 42 prompts sin metadatos de grounding no es posible determinar si Gemini consultó la web o respondió desde su conocimiento paramétrico; las URLs analizadas para Gemini reflejan lo que el modelo declara citar, no necesariamente lo que consultó. Esta opacidad es en sí misma un hallazgo sobre la (falta de) trazabilidad de Gemini. Por ello el análisis de dominios de Gemini se ha basado, como se explicó, en las URLs reales del cuerpo de la respuesta —un dato más fiable que el grounding para auditar qué cita realmente el modelo, aunque no garantice que sea todo lo que consultó.

7.3 DISCUSIÓN Y COMPARATIVA

7.3.1 Posicionamiento de ICAI frente a programas competidores

La comparativa entre ICAI y los siete programas competidores analizados confirma una brecha de posicionamiento GEO estructural. En los bloques orgánicos, UC3M, UPM y UPC concentran la mayor parte de las menciones espontáneas. UC3M es el programa más frecuentemente mencionado a lo largo de todo el experimento, atribuido principalmente a

su ranking y perfil técnico; IE destaca por reputación en perfil de negocio; y UPC por reputación y orientación tecnológica.

ICAI, en cambio, no cuenta con un vector de atribución dominante que emerja de forma orgánica en las respuestas. Cuando aparece, lo hace principalmente asociado a rankings o networking, pero con una frecuencia insuficiente para constituir un patrón robusto. En los bloques reactivos donde ICAI sí es mencionado, el tono es positivo y la valoración comparable a la de sus competidores directos, lo que descarta un problema de imagen y apunta a un problema de presencia digital estructurada.

Programa	Menciones	Razones principales	Pos. media
Universidad Carlos III de Madrid (UC3M) - Máster en Big Data Analytics	9	ranking(7), perfil_tecnico(1), empleabilidad(1)	1.7
IE Business School - Master in Business Analytics and Data Science	9	ranking(3), perfil_negocio(2), reputacion(2)	2.9
Universitat Politècnica de Catalunya (UPC) - Master in Data Science	9	reputacion(4), perfil_tecnico(3), ranking(1)	2.6
Master en Big Data Analytics - IE University	7	empleabilidad(3), prestigio(1), perfil_negocio(1)	1.7
ESADE - MSc in Business Analytics	7	empleabilidad(2), ranking(2), perfil_negocio(2)	3.4
Master en Ciencia de Datos - Universidad de Barcelona (UB)	6	contenido(1), ranking(1), reputacion(2)	2.3

Universitat Politècnica de Catalunya (UPC) - Master en Ciencia de Datos	6	perfil_tecnico(3), reputacion(3)	3.5
Master en Ciencia de Datos - Universidad Carlos III de Madrid (UC3M)	5	contenido(1), perfil_tecnico(1), reputacion(1)	1.8
Master en Ciencia de Datos - IE Business School	5	perfil_negocio(3)	4.2
Master en Ciencia de Datos - Universidad Autónoma de Madrid (UAM)	5	perfil_negocio(3), perfil_tecnico(1), reputacion(1)	1.2

Tabla 20. Razones principales de mención de programas competidores según los LLMs y posición media

El análisis cualitativo de las menciones revela que los competidores son mencionados principalmente por su presencia en rankings (especialmente El Mundo), su perfil técnico o de negocio (según especialización), y su reputación empresarial percibida. ICAI, cuando aparece, se menciona principalmente en contextos de rankings y networking, pero sin un vector de diferenciación claro.

7.4 ANÁLISIS DEL SESGO

La interpretación de los resultados obtenidos mediante el análisis GEO requiere la identificación y evaluación de posibles sesgos estructurales que puedan estar influyendo en los patrones observados. Este aspecto resulta especialmente relevante en estudios comparativos que se apoyan en modelos de lenguaje de gran tamaño (LLMs), los cuales operan como sistemas de caja negra y pueden incorporar distorsiones derivadas de sus datos de entrenamiento y mecanismos internos de inferencia.

En este contexto, el presente apartado analiza tres fuentes principales de sesgo: geográfico, temporal e institucional, con el objetivo de determinar en qué medida afectan a la visibilidad observada de los programas evaluados.

7.4.1 Sesgo Geográfico

Se plantea la hipótesis de que los modelos de lenguaje (LLMs) presentan una sobre-representación de instituciones ubicadas en Madrid, posiblemente derivada de una mayor disponibilidad de datos o de una mayor densidad informativa asociada a este entorno geográfico.

Una posible fuente de sesgo geográfico adicional sería la geolocalización del cliente desde el que se lanzaron las consultas (España). Sin embargo, en este experimento dicho efecto es despreciable por dos razones. En primer lugar, las consultas se realizaron a través de la API oficial de cada proveedor (OpenAI, Anthropic y Google), donde la respuesta del modelo no se condiciona por la dirección IP del cliente, a diferencia de lo que ocurre en algunos productos de consumo. En segundo lugar, y de forma más determinante, el 100% de los prompts ya incorpora el contexto "España" de forma explícita —ya sea mediante la palabra "España" (presente en 40 de los 86 prompts) o mediante referencias a instituciones inequívocamente españolas (ICAI, UAM, KSchool, Comillas, etc.). Es decir, la acotación geográfica está introducida deliberadamente en el contenido del prompt, no derivada de la ubicación del usuario. Por tanto, el sesgo geográfico analizado en este apartado no se refiere a la influencia de la IP, sino a cómo los modelos distribuyen las menciones entre comunidades autónomas y ciudades una vez fijado el contexto España, lo cual refleja sesgos estructurales de los corpus de entrenamiento y no artefactos del entorno de consulta.




Figura 6. Distribución agregada de menciones por comunidad autónoma (datos consolidados de los tres LLMs)

La Figura 6 muestra la distribución agregada de menciones por comunidad autónoma, considerando los tres modelos en su conjunto. La intensidad cromática representa el volumen acumulado de menciones a programas universitarios ubicados en cada región. Se observan tres niveles claramente diferenciados: la Comunidad de Madrid concentra el mayor volumen (azul oscuro), seguida de Cataluña (azul medio); el resto de comunidades con presencia académica relevante en Big Data —Andalucía, Castilla y León, Comunidad Valenciana, Navarra, etc.— quedan agrupadas en un nivel claramente inferior (verde claro). Sobre el subconjunto de 949 menciones cuyo programa pudo asignarse inequívocamente a una comunidad autónoma española, Madrid acumula el 61,7%, Cataluña el 33,1% y el resto del territorio nacional solo el 5,1%, lo que evidencia una concentración bipolar Madrid-Cataluña con un factor de 1,87 a favor de Madrid.

De los 958 registros del dataset, 9 no pudieron asignarse a una comunidad autónoma (programas extranjeros o ambiguos) y se excluyeron del análisis geográfico, quedando 949.




Figura 7. Distribución de menciones por comunidad autónoma desagregada por modelo (ChatGPT, Claude, Gemini)

La Figura 7 desglosa la misma información por modelo de lenguaje (ChatGPT en azul, Claude en naranja, Gemini en rojo), permitiendo evaluar si el sesgo geográfico es estructural —compartido por los tres— o responde al comportamiento idiosincrático de algún sistema concreto. La inspección revela un patrón cualitativamente convergente: los tres modelos concentran entre el 89% y el 98% de sus menciones en el eje Madrid-Cataluña, lo que confirma que el sesgo no es un artefacto de un proveedor particular sino una característica estructural compartida. Esta convergencia entre tres modelos entrenados de forma independiente por OpenAI, Anthropic y Google refuerza la hipótesis de que el sesgo refleja la composición de los corpus de entrenamiento, donde la información sobre instituciones madrileñas y catalanas tiene una representación significativamente mayor que la del resto del territorio.

No obstante, se observan diferencias cuantitativas relevantes entre modelos. Gemini presenta el sesgo madrileño más intenso (66,9% de menciones a Madrid, ratio

Madrid/Cataluña de 2,17), seguido de Claude (60,0%, ratio 1,58) y ChatGPT (58,3%, ratio 1,87). Claude es el modelo que concede mayor peso relativo a Cataluña (37,9%), mientras que ChatGPT es el único que mantiene una presencia apreciable del resto del territorio nacional (10,5% frente al ~2% de los otros dos), recogiendo programas de Castilla y León, Andalucía, Comunidad Valenciana o Navarra.

7.4.2 Sesgo Temporal

Otra posible fuente de sesgo reside en las diferencias en la fecha de corte del conocimiento (*knowledge cutoff*) de los distintos modelos. En teoría, aquellos modelos con acceso a información más reciente deberían reflejar con mayor precisión cambios recientes en la visibilidad de las instituciones.

Sin embargo, el análisis empírico revela un resultado contraintuitivo: el modelo con conocimiento más actualizado (Gemini) no muestra una mayor tasa de mención orgánica para ICAI en comparación con modelos anteriores como Claude. Esto indica que la baja visibilidad no se debe a una falta de presencia en los datos recientes, sino a una limitada capacidad de recuperación espontánea por parte del modelo.

Este hallazgo refuerza la hipótesis de que el problema principal no es de disponibilidad de información, sino de posicionamiento semántico dentro del espacio de representación del modelo. En consecuencia, estrategias basadas únicamente en la generación de contenido reciente podrían no ser suficientes si no se alinean con los mecanismos de recuperación de los LLMs.

7.4.3 Sesgo Institucional

Se ha analizado también la posible existencia de un sesgo en función del tipo de institución. Los resultados muestran que, aunque la diferencia en número total de menciones entre universidades públicas y privadas es limitada, sí existe una divergencia significativa en términos de mención orgánica.

En el caso de ICAI, este sesgo actúa como un factor amplificador de su problema de visibilidad. No obstante, los datos indican que no constituye la causa principal, ya que el volumen total de menciones no es bajo en términos absolutos. El déficit se concentra en la falta de menciones orgánicas, lo que apunta nuevamente a un problema de posicionamiento en los vectores que los LLMs priorizan.

El análisis conjunto de los distintos sesgos permite estimar su contribución relativa al rendimiento observado. En términos agregados, se estima que los sesgos podrían estar reduciendo el TPO de ICAI. No obstante, incluso corrigiendo este efecto, la brecha respecto a universidades líderes como UC3M seguiría siendo considerable. Esto indica que los sesgos identificados actúan como factores amplificadores, pero no explican por sí mismos el déficit de visibilidad.

CAPÍTULO 8. *DASHBOARD*



Figura 8. Identidad visual del dashboard GEO Analyzer

8.1 *OBJETIVO DEL DASHBOARD*

El dashboard desarrollado constituye la interfaz principal de interacción con GEO Analyzer y está diseñado para transformar los resultados del análisis en insights accionables para perfiles no técnicos, como equipos de marketing o responsables académicos.

A diferencia de una simple visualización de datos, el dashboard actúa como una herramienta de apoyo a la toma de decisiones estratégicas, permitiendo identificar:

- El nivel de visibilidad del programa en distintos LLMs
- Las fortalezas y debilidades en función del tipo de consulta
- La posición relativa frente a competidores
- Las diferencias de comportamiento entre modelos

8.2 *FLUJO DE FUNCIONAMIENTO DEL SISTEMA*

El funcionamiento del dashboard sigue un flujo estructurado:

1. Carga de datos (respuestas de LLMs en formato JSON)
2. Procesamiento automático mediante el motor de análisis GEO
3. Cálculo de métricas agregadas y específicas
4. Visualización interactiva
5. Generación automática de conclusiones y recomendaciones mediante IA

Este flujo permite automatizar completamente el proceso de análisis, reduciendo el esfuerzo manual y aumentando la reproducibilidad.

8.3 *ARQUITECTURA FUNCIONAL DEL DASHBOARD*

El dashboard se estructura en múltiples vistas interconectadas, cada una orientada a responder una pregunta específica de negocio:

- Vista global (Score GEO): proporciona una medida agregada de visibilidad ponderada
- Análisis semántico (Radar GEO): identificar qué atributos valora cada modelo
- Análisis por bloque: permite entender en qué contextos aparece o no el programa
- Análisis por modelo: revela diferencias entre LLMs
- Análisis competitivo: posiciona el programa frente a alternativas
- Análisis URLs: detecta urls más consultadas

Esta organización modular permite al usuario explorar el problema desde diferentes perspectivas, facilitando una comprensión profunda del fenómeno GEO.

8.3.1 VISTA GENERAL



Figura 9. Vista principal del dashboard: resumen ejecutivo y KPIs globales

La página de inicio del dashboard presenta un resumen ejecutivo de los hallazgos principales. Los elementos clave incluyen:

- **Score GEO Total:** Métrica sintética de 0-10 que resume la visibilidad global de ICAI. Calculada como: $\Sigma (\text{tasa}_{\text{bloque, modelo}} \times \text{peso}_{\text{bloque}}) / \Sigma (100 \times \text{peso} \times 3) \times 10$
- **Contadores KPI:** 86 prompts analizados, 244 respuestas válidas (258 lanzadas, 14 fallos transitorios de Gemini), 127 menciones totales de ICAI, tasa de mención global del 52%. Esta tasa global incluye los bloques reactivos (comparativa y específico_ICAI, donde el prompt nombra a ICAI explícitamente). La tasa de presencia orgánica (TPO), calculada sólo sobre bloques que no mencionan ICAI, es del **2,2%** — es el indicador real de visibilidad espontánea que el Score GEO penaliza
- **Navegación Principal:** Pestañas laterales que permiten acceder a: Score GEO, Radar GEO, Por Bloque, Por Modelo, Competidores, Conclusiones, Recomendaciones.

8.3.2 EVALUACIÓN GLOBAL DE VISIBILIDAD

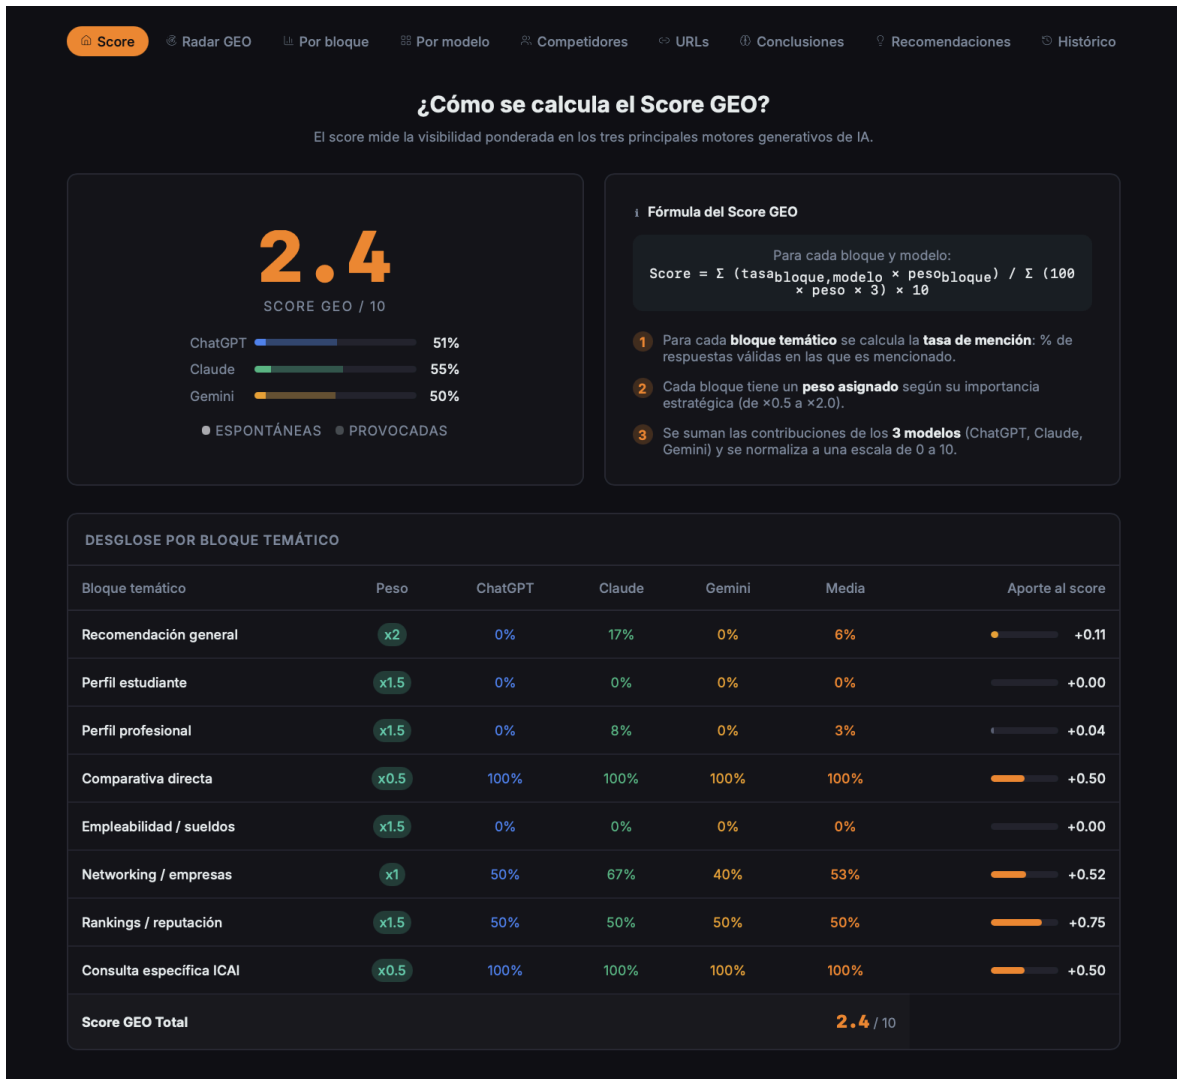


Figura 10. Vista "Score GEO": cálculo y desglose del Score GEO global

El Score GEO se calcula como una media ponderada de la tasa de mención de ICAI en cada uno de los 8 bloques temáticos, agregada sobre los 3 modelos y normalizada a una escala 0-10. Cada bloque recibe un peso que refleja su importancia estratégica: los bloques de visibilidad orgánica (recomendación general, perfiles, empleabilidad, rankings) reciben pesos $\geq 1,5$ porque son los que reflejan el posicionamiento real del programa en la "mente" del modelo, mientras que los bloques reactivos (comparativa, específico_ICAI) reciben

peso 0,5 porque la mención es esperable y no aporta evidencia de visibilidad GEO. La fórmula completa es:

Bloque	Peso	ChatGPT	Claude	Gemini	Σ tasas	Σ × peso
Recomendación general	2,0	0	17	0	17	34
Perfil estudiante	1,5	0	0	0	0	0
Perfil profesional	1,5	0	8	0	8	12
Comparativa directa	0,5	100	100	100	300	150
Empleabilidad / sueldos	1,5	0	0	0	0	0
Networking / empresas	1,0	50	67	40	157	157
Rankings / reputación	1,5	50	50	50	150	225
Consulta específica ICAI	0,5	100	100	100	300	150

Tabla 21. Cálculo detallado del Score GEO de ICAI: tasa por bloque y modelo, peso y contribución ponderada

Fórmula: $\text{Score GEO} = \frac{\sum (\text{tasa}_{\text{bloque, modelo}} \times \text{peso}_{\text{bloque}})}{\sum (100 \times \text{peso} \times 3)} \times 10$

Para el caso de ICAI:

Paso 1 — Numerador: contribución de cada bloque

Para cada bloque, sumo las tasas de los 3 modelos y multiplico por el peso: **Numerador : Σ (tasabloque,modelo × pesobloque) -> 34 + 0 + 12 + 150 + 0 + 157 + 225 + 150 = 728**

Paso 2 — Denominador: máximo teórico

Denominador : $\Sigma (100 \times \text{peso} \times 3) \times 10 \rightarrow$ Suma de pesos = $2,0 + 1,5 + 1,5 + 0,5 + 1,5 + 1,0 + 1,5 + 0,5 = 10,0$; $100 \times 3 \times 10,0 = 3\,000$

Paso 3 — Cálculo final

Score GEO_ICAI = $728/3000 \times 10 = 2,43$

El Score GEO permite comparación temporal: si ICAI implementa estrategias de mejora de contenido, un nuevo análisis trimestral debería reflejar incrementos en las tres dimensiones, permitiendo ROI cuantificable de inversiones en visibilidad GEO.

8.3.3 ANÁLISIS SEMÁNTICO

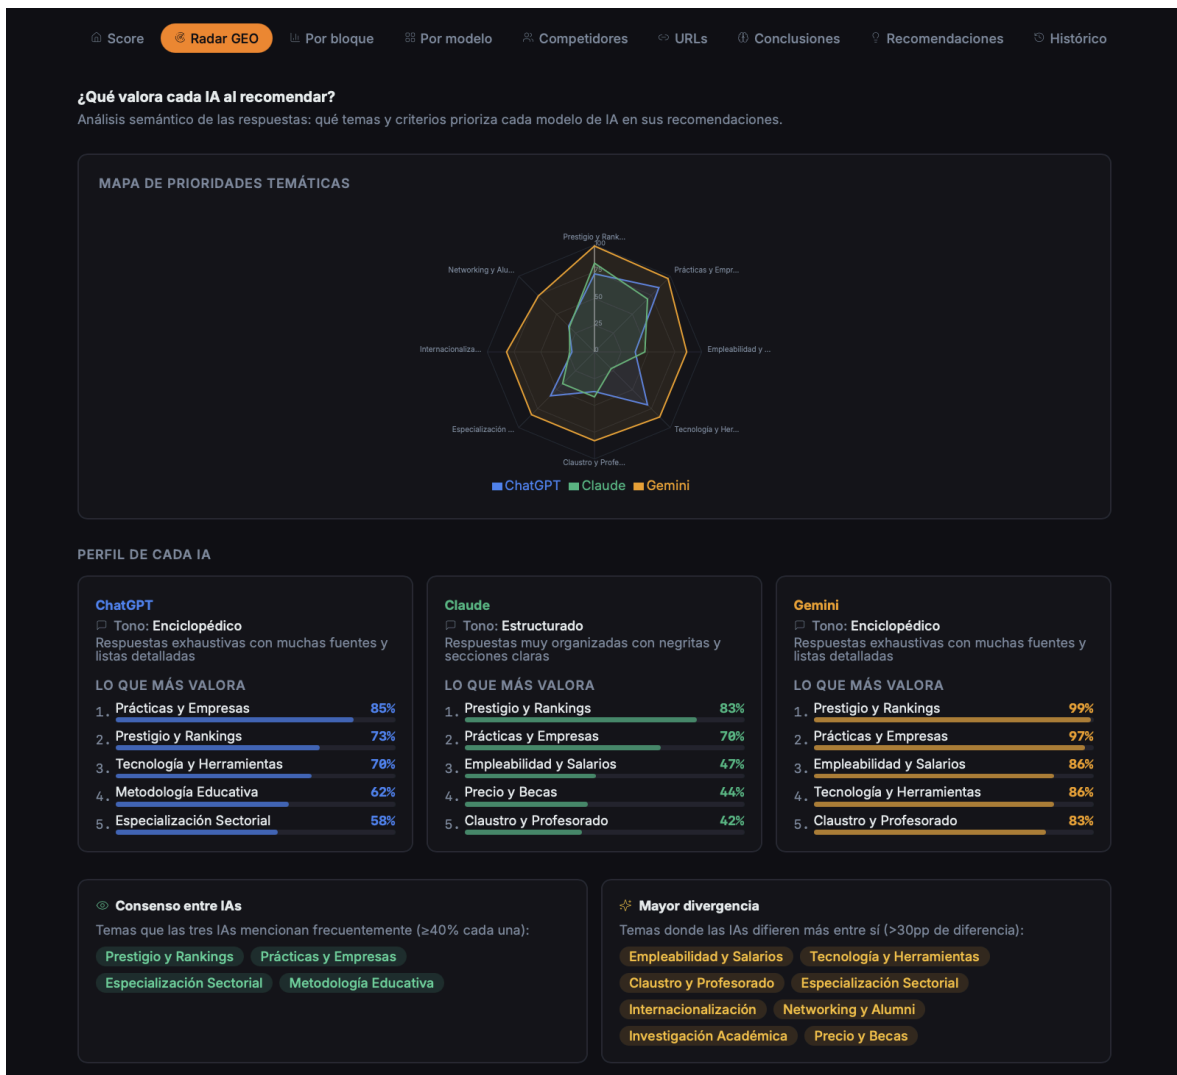


Figura 11. Vista "Radar GEO": análisis semántico de las dimensiones de atribución por LLM




Figura 12. Detalle del Radar GEO de ICAI: dimensiones fuertes y brechas frente a competidores

El Radar GEO es una visualización en forma de gráfico radar (araña) que muestra la distribución de razones por las que los LLMs mencionan a ICAI. Utiliza 12 dimensiones de atribución que emergen del análisis de contenido de respuestas:

Prestige y Ranking • Prácticas y Empresas • Empleabilidad y Salarios • Tecnología y Herramientas

Claustro y Profesorado • Especialización Sectorial • Internacionalización • Networking y Alumni

Investigación Académica • Metodología Educativa • Precio y Becas • Plan de Estudios

Cada una de estas dimensiones es puntualizada con un valor 0-100% que representa la frecuencia con que cada LLM menciona ese aspecto al hablar de ICAI. Por ejemplo, si Gemini menciona "Prestige y Ranking" en el 70% de sus respuestas sobre ICAI, esa dimensión suma 70 puntos.

El Radar permite identificar fortalezas (dimensiones altas, donde la visibilidad es fuerte) y brechas (dimensiones bajas, donde el programa no destaca). En el caso de ICAI, las dimensiones fuertes son "Prestige y Ranking" (gracias a citas de El Mundo) y

"Networking y Empresas", mientras que dimensiones como "Internacionalización" y "Plan de Estudios" tienen presencia baja, sugiriendo oportunidades de mejora en contenido.

8.3.4 ANÁLISIS POR CONTEXTO DE CONSULTA

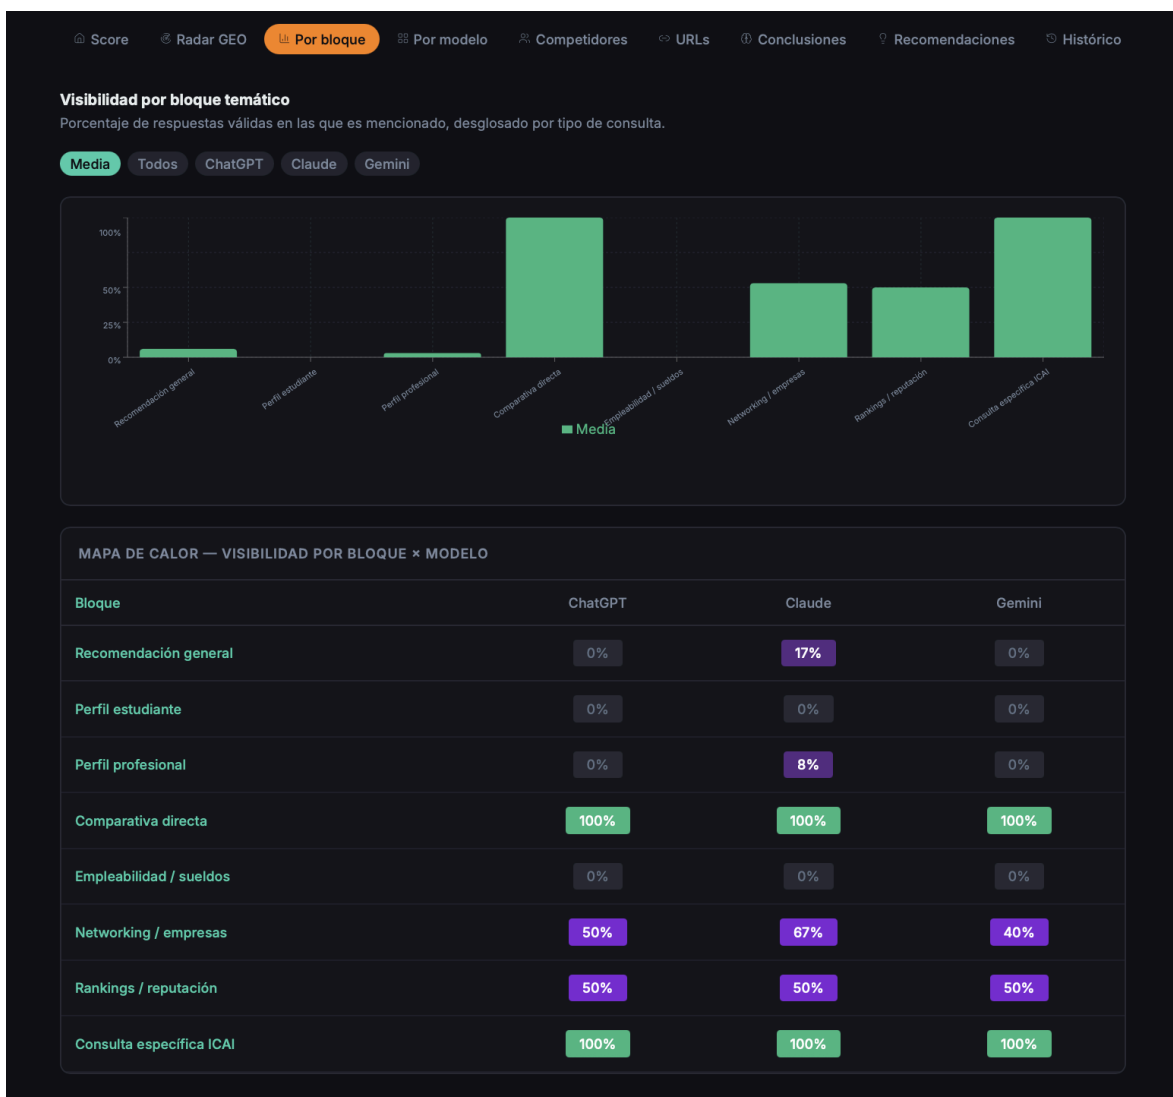


Figura 13. Vista "Por bloque": tasa de mención de ICAI por bloque temático y modelo

Esta vista desagrega la visibilidad de ICAI según el tipo de consulta (bloque temático). Incluye:

- Gráfico de barras horizontales mostrando % de mención de ICAI en cada bloque (recomendacion_general, perfil_estudiante, etc.)
- Heatmap que cruza bloques vs modelos, mostrando tasa de mención con escala de colores
- Tabla detallada con recuento de menciones, posición media, y frecuencia promedio por bloque

Los hallazgos clave en esta vista son:

- Visibilidad Orgánica Baja: En bloques no reactivos (recomendacion_general, perfil_estudiante), la mención de ICAI es casi 0%, comparado con 35-40% para competidores como UC3M y UPM.
- Visibilidad Reactiva Alta: En bloques donde se pregunta directamente por ICAI (especifico_icaei, comparativa), la mención alcanza 90-100%, demostrando que el problema es de descubrimiento, no de calidad de respuesta.
- Variabilidad por Contexto: En bloques de networking (convenio con empresas), ICAI logra 40-67% según el modelo, más alto que en recomendación general, sugiriendo que este es un vector de diferenciación actual.

8.3.5 ANÁLISIS COMPARATIVO ENTRE LLMs

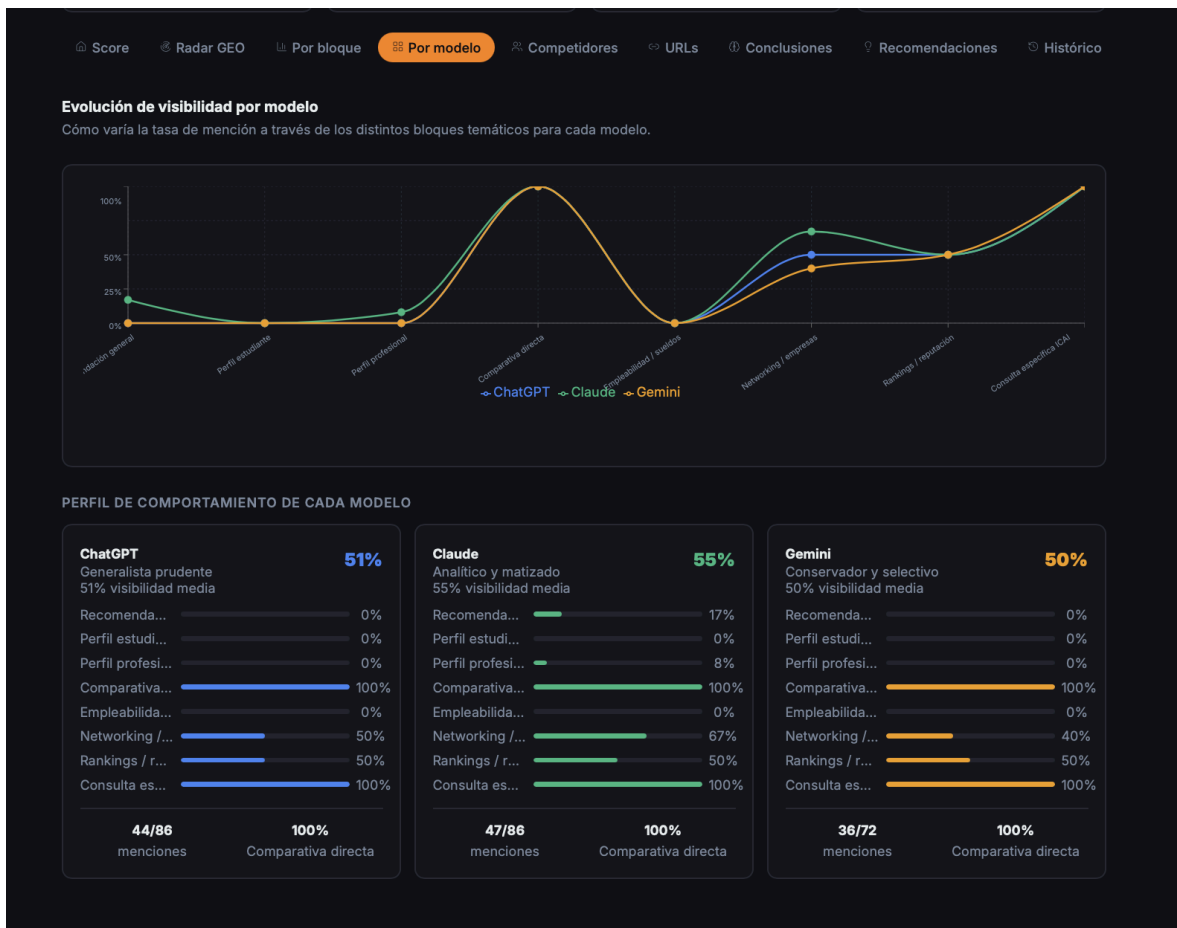


Figura 14. Vista "Por modelo": perfil comparativo de ChatGPT, Claude y Gemini

Esta vista compara el comportamiento diferencial de los tres LLMs analizados. Incluye:

- Gráfico de evolución que muestra % de mención de ICAI a lo largo de todos los bloques para cada modelo
- Panel de perfiles de comportamiento que sintetiza la estrategia de cada modelo
- Tabla de desagregación: tasa de mención, tasa de evasividad, tasa de negatividad por modelo

Los perfiles diferenciados son:

- ChatGPT (51%): Comportamiento polarizado: 100% mención en bloques reactivos, 0% en bloques orgánicos. No recupera ICAI de forma espontánea. Nivel de evasividad bajo (tiende a afirmar incluso con incertidumbre).
- Claude (55%): Comportamiento matizado: único modelo con mención orgánica (16% en recomendacion_general). Evasividad altísima (100% en especifico_icai), probablemente por cautela epistemológica. Mejor calidad factual cuando responde.
- Gemini (50%): Comportamiento afirmativo: baja evasividad, responde siempre. Mejor tasa de calidad factual (10% correcto vs 0% en otros). Pero en bloques orgánicos también falla (0% en perfil_estudiante).

Esta vista es crucial para ajustar la estrategia GEO por modelo: no existe una solución única. Para mejorar visibilidad en Claude, requiere más datos estructurados sobre ICAI en fuentes autorizadas. Para ChatGPT y Gemini, requiere presencia en rankings y contenido ampliamente indexado.

8.3.6 ANÁLISIS COMPETITIVO




Figura 15. Vista "Competidores": análisis competitivo agregado por LLM

Esta vista posiciona a ICAI en el *competitive landscape* GEO mediante un gráfico de barras agrupadas que compara la tasa de mención de cada competidor en los tres LLMs analizados (eje vertical: % de respuestas válidas en las que el competidor aparece, escala 0-60%; eje horizontal: competidores ordenados por visibilidad media; colores: azul = ChatGPT, verde = Claude, naranja = Gemini), una tabla con el detalle desagregado y un análisis cualitativo de las razones de mención (ranking, perfil técnico, perfil de negocio,

empleabilidad, reputación). La línea naranja punteada marca la visibilidad media de ICAI ($\approx 52\%$) como referencia visual.

Cómo leer este gráfico: cada grupo de tres barras representa un competidor; la altura de cada barra mide el porcentaje de respuestas en las que ese modelo concreto lo menciona. Una distribución equilibrada entre las tres barras (los tres LLMs lo mencionan por igual) indica un programa con visibilidad transversal; una distribución muy desigual indica un programa con presencia sesgada hacia un modelo concreto.

Toda barra por debajo de la línea naranja indica que ese LLM menciona menos a ese competidor que a ICAI. En el caso de ICAI prácticamente todos los competidores quedan por debajo, ya que ICAI concentra su visibilidad en los bloques reactivos."

Los principales hallazgos competitivos son:

- **IE Business School (37% de media):** competidor con mayor visibilidad agregada en LLMs, especialmente fuerte en Gemini (46%) y Claude (40%). Sus menciones son multimodales —negocios, empleabilidad, reputación empresarial— lo que lo posiciona como referente transversal en el descubrimiento de programas de Big Data orientados a perfil de gestión.
- **UC3M (36% de media):** principal competidor técnico. Muy presente en Gemini (51%) y consistente en ChatGPT y Claude (28-30%). Su vector dominante es el ranking (especialmente el de El Mundo) y un posicionamiento técnico claro.
- **UPM (33%) y UPC (31%):** politécnicos con visibilidad media similar pero perfiles diferenciados entre modelos. UPM destaca en ChatGPT (41%) y UPC en Claude (34%), reflejando representaciones internas distintas en cada LLM. Ambos son referentes en bloques técnicos e ingeniería.
- **ESADE (20%) y UAM (18%):** visibilidad media. UAM presenta el perfil más desigual del conjunto: Claude la menciona en el 35% de sus respuestas mientras ChatGPT solo en el 5%, lo que sugiere mayor densidad de información sobre UAM en el corpus de entrenamiento de Anthropic.

- **UOC, EAE, UNIR, UCM, KSchool (6-11%)**: cola larga del ranking competitivo, con visibilidad baja y dispersa.

La lectura estratégica clave es que la visibilidad media de ICAI ($\approx 52\%$) es **superior en términos absolutos** a la de todos los competidores analizados, pero su distribución a lo largo del *funnel* de descubrimiento es muy desigual: concentra prácticamente toda su presencia en bloques reactivos (comparativa y específico_ICAI), mientras que IE, UC3M, UPM y UPC mantienen visibilidad sostenida en bloques orgánicos. Es decir, ICAI gana las comparaciones cuando ya es nombrado, pero rara vez es nombrado primero. La recomendación es trabajar la diferenciación mediante una especialización clara en un vector concreto —por ejemplo, "Big Data aplicado a transformación digital industrial" o un eje vinculado al ecosistema empresarial de Comillas— que active la recuperación espontánea de ICAI en consultas abiertas, en lugar de competir genéricamente con UC3M en reputación técnica general o con IE en visibilidad de negocio, terrenos en los que estos programas ya tienen ventaja estructural por su presencia consolidada en rankings y datos públicos indexados.

8.3.7 URLs

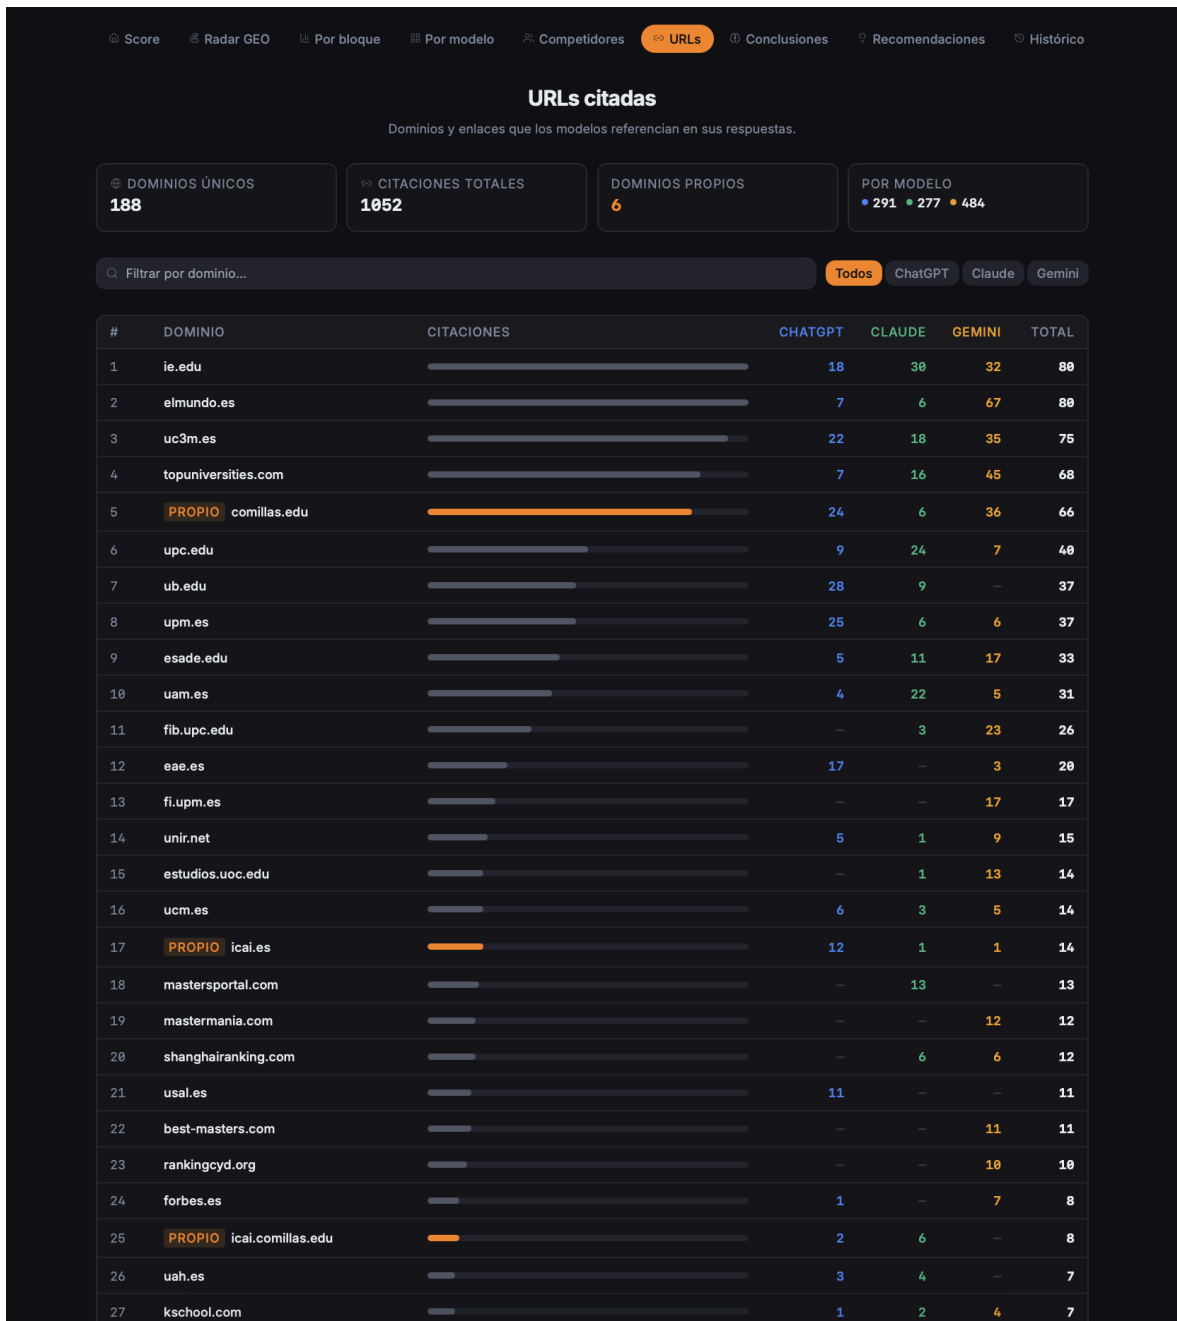


Figura 16. Vista "Urls"

Esta vista responde a una pregunta que las demás no abordan: ni qué recomienda el modelo, sino sobre qué fuentes apoya esta recomendación. La vista combina tres

elementos: un ranking de los dominios más citados (barras horizontales ordenadas por número de citas), un selector que permite alternar entre la vista agregada y el desglose por modelo (ChatGPT, Claude, Gemini), y una clasificación de cada dominio por tipo de fuente (web oficial de universidad o escuela, prensa y rankings, agregador de posgrados, bootcamp/centro privado, otros).

Cómo leer esta vista: cada barra es un dominio raíz; su longitud mide cuántas veces ese dominio aparece citado a lo largo de las consultas. El código de color indica el tipo de fuente, lo que permite ver de un vistazo si un modelo se apoya en fuentes oficiales o en portales comerciales. Al desagregar por modelo, una distribución concentrada en pocas barras indica un modelo que recurre siempre a las mismas fuentes; una distribución más plana indica un modelo que diversifica. El indicador superior resume el volumen total de URLs y los dominios únicos por modelo, métrica que distingue verbosidad (muchas citas) de diversidad (muchas fuentes distintas).

8.3.8 GENERACIÓN DE INSIGHTS

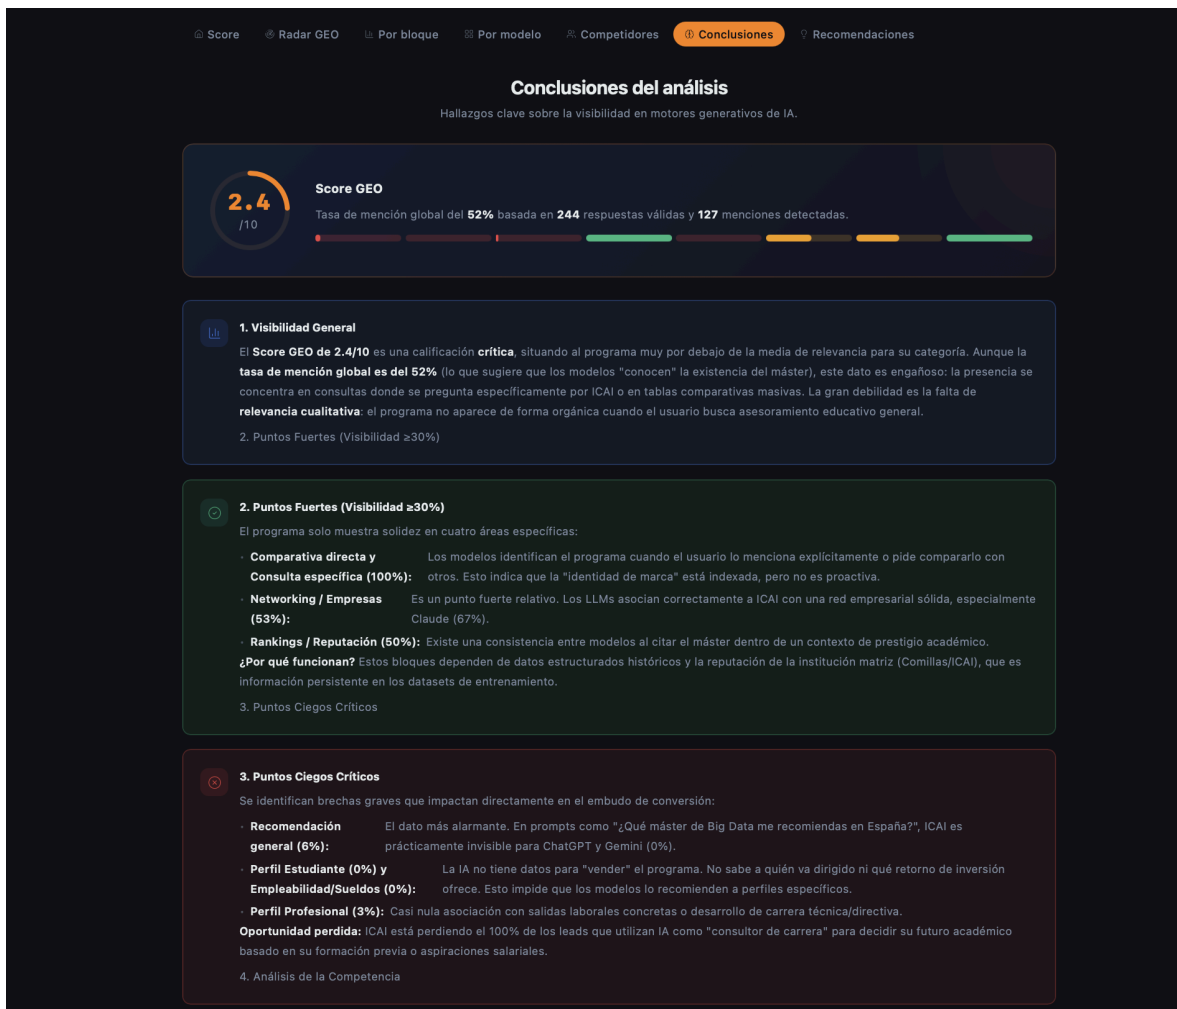


Figura 17. Vista "Conclusiones": insights generados automáticamente con IA (Gemini)



Figura 18. Vista "Recomendaciones": plan de acción priorizado por horizonte temporal (quick wins, medio plazo, largo plazo)

El sistema integra un módulo de generación automática de insights basado en modelos generativos, que permite transformar los resultados cuantitativos en interpretaciones cualitativas.

Este componente aporta:

- Escalabilidad (no depende de analistas humanos)
- Consistencia en el análisis
- Capacidad de generar recomendaciones estructuradas

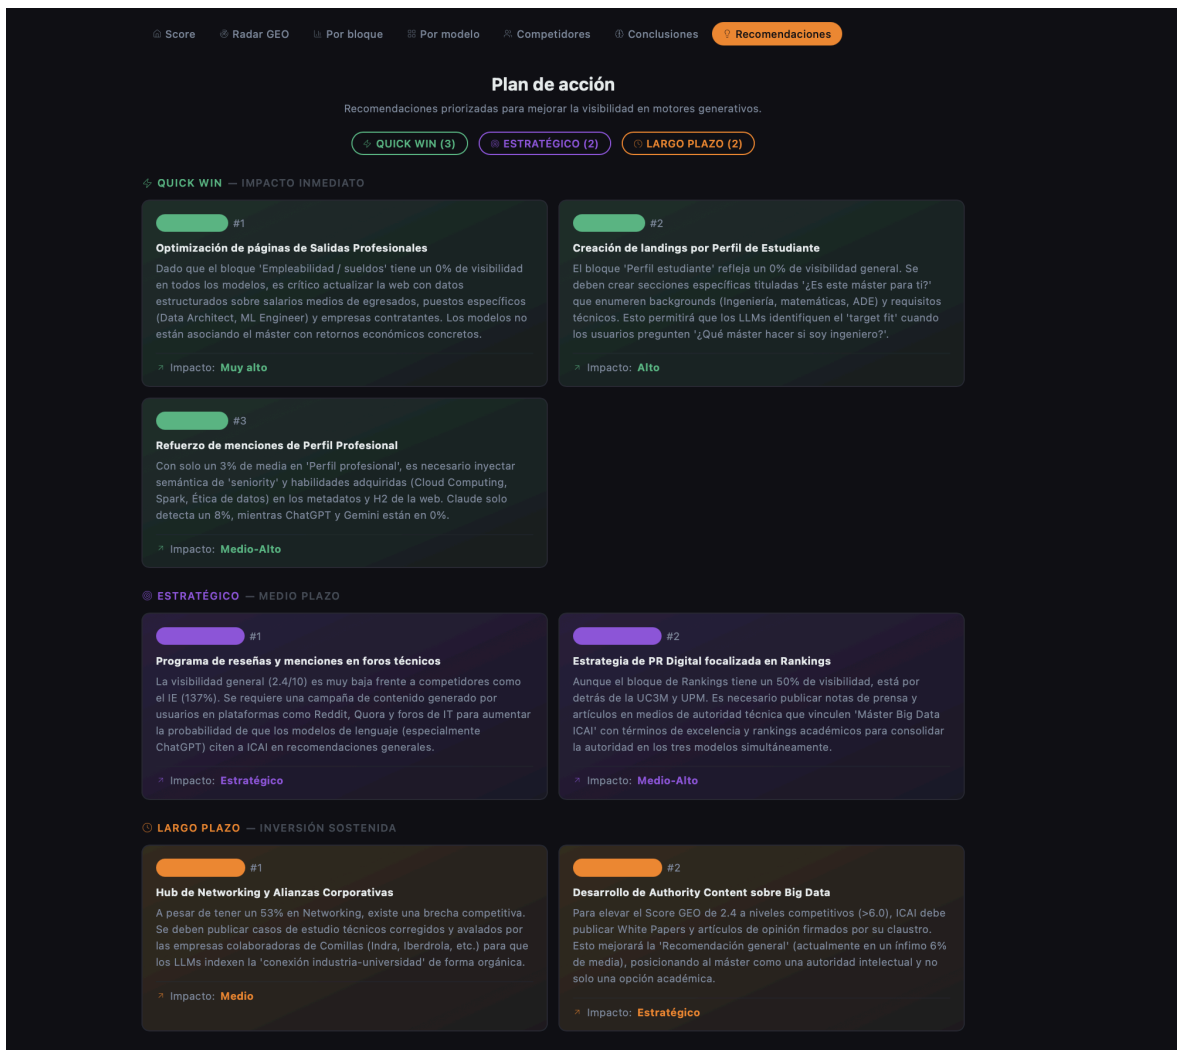


Figura 19. Detalle del plan de acción: quick wins y métricas de impacto esperado

Las últimas vistas del dashboard sintetizan los hallazgos principales y proponen acciones concretas, categorizadas por horizonte temporal.

8.3.7.1 Quick Wins (Impacto Inmediato)

Optimización de Páginas de Salidas Profesionales: Dado que empleabilidad aparece en un gran porcentaje de respuestas de Claude, crear página dedicada con datos concretos de salarios, empresas contratantes, tasa de inserción laboral. Impacto esperado: +15% en mención en bloque empleabilidad_sueldos.

- Creación de Landings por Perfil de Estudiante: Los bloques perfil_estudiante y perfil_profesional muestran 0% de mención. Crear landing pages dirigidas a "Ingeniero de software que quiere entrar en datos" o "Profesional que busca reciclarse en Big Data". Impacto: +20% en mención orgánica en estos contextos.

8.3.7.2 Estratégico (Mediano Plazo)

- Programa de Reseñas en Mentores en Foros Técnicos: Dado que Claude muestra % de mención en portal_empleo (4 vs 9 de ChatGPT), publicar testimonios de alumni en portales como StackOverflow, GitHub, y Medium. Esto aumentaría la relevancia de ICAI en embeddings de estos LLMs.

- Estrategia de Presencia en Ranking El Mundo: El dominio elmundo.es aparece en 72 citas totales. Asegurar que ICAI está correctamente perfilado y posicionado en el ranking anual de El Mundo (tanto en términos de factual como de visibilidad SEO tradicional).

- Desarrollo de Authority Content sobre Big Data: Publicar white papers, estudios de caso, e investigación sobre tendencias en Big Data que cite comillas.edu como fuente. Esto aumentaría la probabilidad de que los LLMs citen al ICAI como autoridad en el dominio.

8.3.7.3 Largo Plazo (Sostenible)

- Hub de Networking y Alianzas Corporativas: Crear página web dedicada a convenios con empresas, con nombres, logos, y testimonios de recruiters. Esto atacaría directamente la dimensión "Networking" del radar, donde ICAI tiene debilidad.

- Ciclo Trimestral de Análisis GEO: Continuar ejecutando el análisis con el sistema GEO Analyzer cada 3 meses, rastreando evolución de Score GEO y comparando pre/post intervenciones.

8.3.7.4 Conclusión Estratégica

El Score GEO de 2.4/10 refleja un posicionamiento débil en visibilidad orgánica pero presencia que aparece cuando se pregunta directamente. La solución no es "optimizar para LLMs" en sentido manipulatorio, sino crear contenido estructurado, ubicuo y verificable que los modelos pueden confiar que citan. Esto requiere enfoque coordinado en: (1) SEO

clásico (para que los LLMs encuentren el contenido), (2) Especialización temática clara (para que ICAI sea reconocido como autoridad en Big Data), y (3) Embeddedness en redes de profesionales (para que testimonios de alumni amplifiquen la señal).

8.3.9 HISTÓRICO

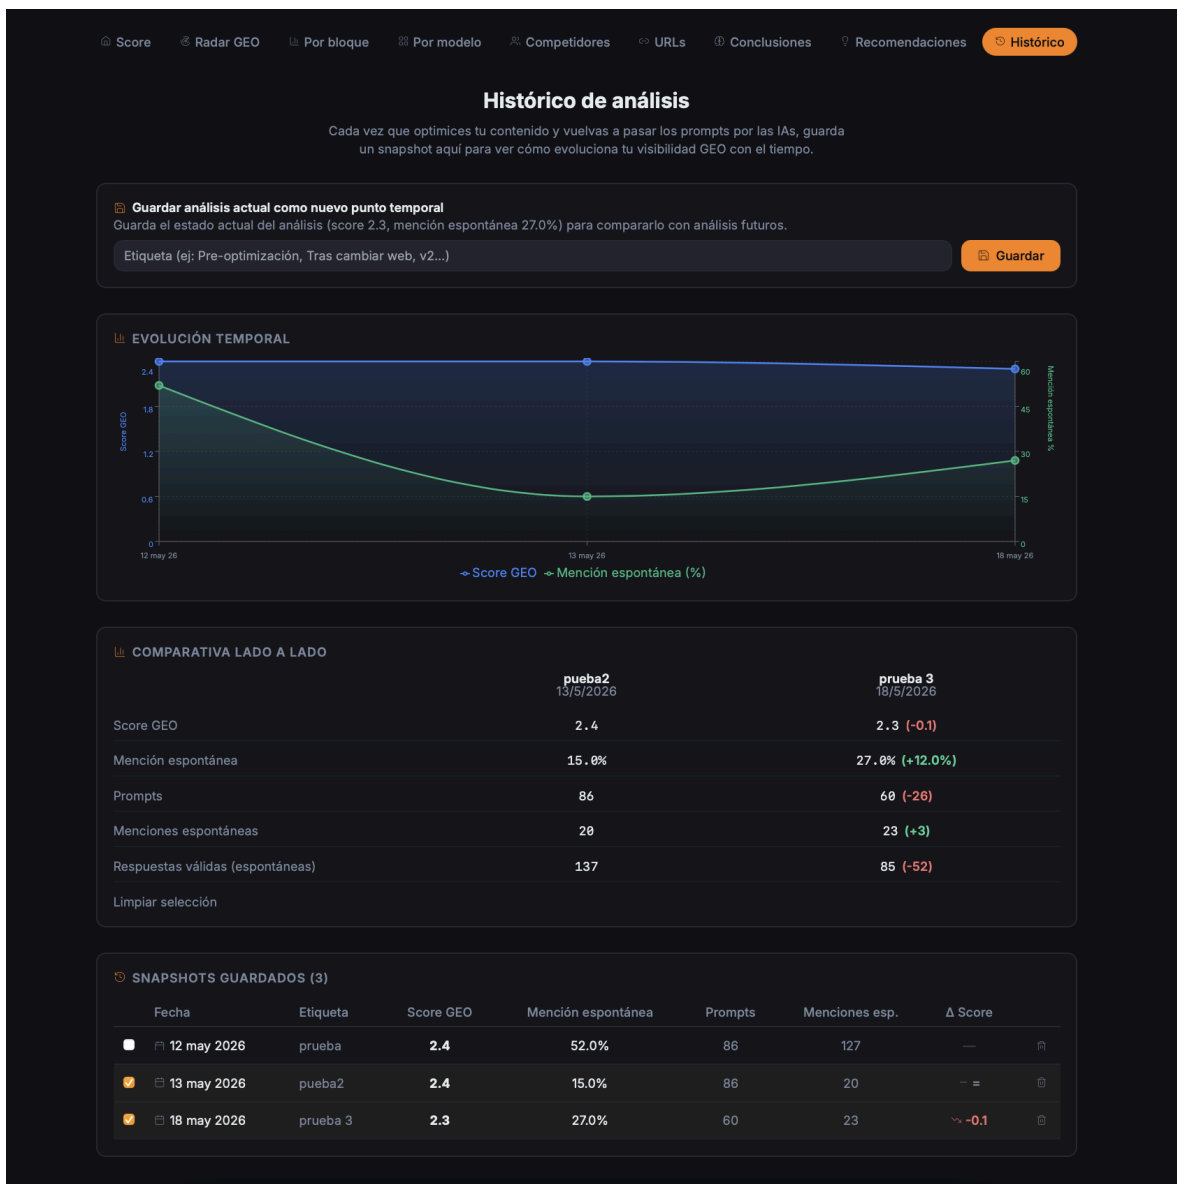


Figura 20. Vista "Histórico": evolución temporal del Score GEO y la tasa de mención mediante snapshots

El módulo de análisis histórico constituye una extensión clave del sistema GEO Analyzer, permitiendo no solo evaluar la visibilidad en un momento puntual, sino analizar su evolución temporal. Este enfoque transforma el sistema de una herramienta descriptiva a una herramienta analítica con capacidad de monitorización continua y soporte a la toma de decisiones.

El objetivo principal de esta funcionalidad es evaluar el impacto de acciones externas —como cambios en la web institucional, campañas de comunicación o mejoras en contenido— sobre la visibilidad del programa en motores generativos.

8.3.9.1 Funcionamiento del sistema

El módulo histórico se basa en el concepto de *snapshot*, definido como una captura completa del estado de visibilidad en un instante determinado. Cada snapshot almacena tanto métricas agregadas como el dataset original, permitiendo reproducibilidad y análisis comparativos.

El flujo de funcionamiento es el siguiente:

1. **Generación del análisis GEO** a partir de un conjunto de prompts y respuestas de LLMs
2. **Persistencia del snapshot**, incluyendo métricas clave y datos brutos
3. **Visualización temporal**, mostrando la evolución de las métricas
4. **Comparación entre snapshots**, permitiendo identificar mejoras o degradaciones

8.3.9.2 Arquitectura Técnica y Persistencia de Datos

Para dotar al sistema de memoria histórica, se ha implementado una arquitectura de persistencia basada en Supabase Cloud, utilizando una base de datos relacional PostgreSQL. La estructura de datos se articula en torno a dos tablas principales que garantizan la integridad y la trazabilidad de cada medición:

- Tabla `geo_analyses`: Actúa como el repositorio maestro de cada "snapshot" o captura temporal. En ella se almacena la información contextual (nombre de la entidad y programa), las métricas agregadas (Score GEO, tasa de mención global, volumen de prompts y respuestas válidas) y una etiqueta descriptiva que permite al usuario identificar el hito temporal (ej. "Post-optimización SEO trimestral"). Un elemento técnico diferencial es el almacenamiento del JSON original mediante el tipo de dato `jsonb`, lo que asegura la reproducibilidad total del experimento y permite futuros re-procesamientos bajo métricas actualizadas.
- **Tabla `geo_analysis_details`**: Esta tabla gestiona el desglose granular por bloque temático y modelo de IA. Almacena la relación de éxito de cada segmento (menciones detectadas frente a respuestas válidas), permitiendo que el dashboard reconstruya visualmente el estado de visibilidad en un punto específico del pasado sin necesidad de volver a ejecutar las llamadas a las APIs.

8.3.9.3 Métricas Almacenadas

Cada snapshot incluye las siguientes variables:

- Score GEO global (escala 0–10)
- Tasa de mención global (%)
- Número total de prompts analizados
- Número de menciones detectadas
- Número de respuestas válidas
- Desglose por bloque temático y modelo
- Dataset original en formato JSON

Este diseño permite tanto análisis agregados como re-procesamiento futuro bajo nuevas métricas.

8.3.9.4 Visualización Temporal

La interfaz del dashboard traduce esta estructura técnica en un gráfico de evolución temporal (AreaChart) de doble eje. El eje izquierdo monitoriza el Score GEO (escala 0-10) como indicador de salud global, mientras que el eje derecho rastrea la tasa de mención porcentual. Esta superposición visual facilita la identificación de correlaciones: por ejemplo, un aumento en el Score GEO acompañado de una tasa de mención estable indicaría que, aunque el programa no aparece en más respuestas, la calidad y veracidad de la información proporcionada por los LLMs ha mejorado.

Adicionalmente, el sistema implementa un panel de análisis comparativo lado a lado. Esta funcionalidad permite al usuario seleccionar dos snapshots cronológicos para calcular automáticamente los "deltas" o variaciones absolutas en las métricas clave. El sistema resalta mediante indicadores visuales (iconografía de tendencia ↑/↓) si las estrategias de contenido aplicadas entre ambos hitos han logrado traspasar el umbral de activación orgánica de los modelos.

8.3.9.5 Valor Estratégico y Proyección Futura

Desde una perspectiva analítica, este módulo transforma el TFM en un estudio longitudinal. Permite demostrar de forma cuantificable el Retorno de la Inversión (ROI) de las estrategias GEO propuestas en este trabajo. Al observar cómo las métricas reaccionan tras la implementación de "Quick Wins" —como la creación de landing pages optimizadas por perfil de estudiante—, la institución puede validar qué vectores de comunicación (empleabilidad, prestigio o networking) son más efectivos para "educar" a los modelos generativos.

Como línea de trabajo futuro, la robustez de los datos almacenados en Supabase abre la puerta a la integración de módulos de simulación. En futuras versiones, el sistema podría utilizar las tendencias históricas para predecir el impacto de futuros cambios en la web institucional antes de su publicación, consolidando a GEO Analyzer como una herramienta de inteligencia estratégica esencial en el nuevo paradigma de la búsqueda generativa.

CAPÍTULO 9. CONCLUSIONES Y TRABAJOS FUTUROS

9.1 CONCLUSIONES

Este trabajo partía de una pregunta que, hasta hace muy poco, ninguna institución educativa había necesitado formularse: cuando un futuro estudiante deja de teclear en Google y empieza a preguntar directamente a ChatGPT, Claude o Gemini por dónde estudiar un máster en Big Data, ¿aparece el programa de ICAI en esa respuesta? La hipótesis de la que se partía era que la presencia de un programa en un motor generativo no es ni aleatoria ni inescrutable, sino que puede medirse, descomponerse en factores explicativos y, sobre esa base, intervenir. El desarrollo y la aplicación de GEO Analyzer confirman esa hipótesis en sus tres niveles.

En el plano de la medición, el sistema operacionaliza la visibilidad GEO en un cuadro de métricas reproducibles —Tasa de Presencia Orgánica, Posición de Primera Mención, Frecuencia de Mención, calidad factual y análisis de fuentes— agregadas en un Score GEO compuesto. Aplicado al Máster en Big Data de ICAI, el sistema arroja un Score GEO de 2,4 sobre 10 y una tasa de presencia orgánica del 2,2 %, frente a tasas notablemente superiores de competidores como UC3M, UPM o UPC, que emergen de forma espontánea en la mayoría de respuestas a consultas abiertas. La aportación no es solo el número, sino el hecho de que un fenómeno que se percibía como una caja negra queda, por primera vez para este programa, cuantificado y comparado.

En el plano de la explicación, el hallazgo más relevante es la disociación entre visibilidad orgánica y reactiva. Cuando el prompt nombra explícitamente a ICAI, los tres modelos lo reconocen al 100 %, con un tono predominantemente positivo o neutro y una calidad de representación comparable a la de sus competidores directos. El problema, por tanto, no es

de reputación ni de desconocimiento: es de activación. ICAI existe en los pesos de los modelos, pero no se recupera de forma espontánea ante una consulta genérica. El análisis de sesgos refina este diagnóstico: la convergencia del sesgo geográfico Madrid–Cataluña en tres modelos entrenados de forma independiente, y el resultado contraintuitivo de que el modelo con conocimiento más reciente no mejora la visibilidad orgánica de ICAI, apuntan a que la causa raíz es el posicionamiento semántico del programa dentro del espacio de representación de los modelos, no la antigüedad ni el volumen de la información publicada.

En el plano de la prescripción, el análisis de fuentes citadas convierte el diagnóstico en una hoja de ruta. Saber que los modelos se apoyan de forma dominante en agregadores comerciales y rankings periodísticos —y solo de forma marginal en fuentes institucionales primarias— indica con precisión sobre qué palancas puede actuar el equipo de comunicación: estructurar la información extraíble del propio dominio, ganar presencia en los rankings que los modelos efectivamente citan y construir contenido de autoridad que cierre la brecha de activación orgánica. El dashboard traduce todo ello en un plan de acción priorizado por horizonte temporal y, gracias al módulo de snapshots, permite además monitorizar si esas intervenciones mueven realmente la aguja, transformando el TFM en la base de un estudio longitudinal y no en una fotografía aislada.

En conjunto, el trabajo demuestra que el GEO no es una etiqueta de marketing, sino una evolución necesaria del SEO para un ecosistema en el que el LLM sustituye progresivamente al buscador como punto de descubrimiento. La contribución central es metodológica y reutilizable: GEO Analyzer no resuelve únicamente el caso de ICAI, sino que proporciona un instrumento aplicable a cualquier programa o institución que necesite responder a las tres preguntas que antes no tenían respuesta —dónde está, por qué está ahí y qué puede hacer al respecto—. El caso de ICAI valida el sistema y entrega, como subproducto, un diagnóstico accionable para un programa real.

9.1.1 IMPACTO DE LOS LLMs EN LA TOMA DE DECISIONES

Más allá del caso concreto, los resultados invitan a una reflexión sobre el papel de los modelos generativos como intermediarios en la decisión del usuario. A diferencia del buscador clásico, donde el usuario recibe una lista de enlaces y ejerce su propio criterio de selección, el LLM entrega una respuesta ya sintetizada que incorpora una jerarquización implícita: decide qué programas merecen ser mencionados, en qué orden y con qué matices. Esa síntesis, percibida por el usuario como neutral, es en realidad el resultado de sesgos estructurales del corpus de entrenamiento y de la formulación de la consulta, como evidencia este trabajo.

La consecuencia para una institución educativa es directa: una parte creciente de la decisión de matrícula se juega en un espacio que la institución no controla y que, hasta ahora, ni siquiera podía observar. No se trata de un problema de imagen —el tono de las menciones de ICAI es positivo— sino de presencia: si el programa no se activa en la respuesta, simplemente no entra en el conjunto de opciones que el candidato considera. Comprender y optimizar esa activación deja de ser una cuestión técnica para convertirse en un objetivo estratégico de captación, y ese es precisamente el vacío que GEO Analyzer permite empezar a cubrir de forma sistemática.

9.2 LIMITACIONES DEL TRABAJO

Los resultados deben interpretarse a la luz de varias limitaciones, que se exponen de forma transparente porque acotan el alcance de las conclusiones y, al mismo tiempo, definen el espacio de mejora.

- Alcance de modelos y temporalidad. El análisis se restringe a tres modelos (GPT-4o, Claude Sonnet 3.5 y Gemini 2.0 Flash) en un instante temporal concreto. Los LLMs son sistemas dinámicos cuyo comportamiento varía con cada nueva versión, por lo que las cifras absolutas tienen fecha de caducidad; lo que el trabajo reivindica como estable no es el valor del Score GEO sino la metodología que permite recalcularlo.

- Validez ecológica del corpus de prompts. Los 86 prompts se diseñaron a priori sobre hipótesis razonables del comportamiento de búsqueda de un candidato típico, pero no están validados empíricamente con consultas reales de usuarios. Construir el corpus a partir de fuentes externas —keywords reales de Google Trends y Keyword Planner para el sector, preguntas recogidas por el equipo de admisiones, o extractos filtrados de datasets públicos de conversaciones como WildChat o ShareGPT— elevaría sustancialmente la representatividad de los resultados.
- Simplificación métrica. Las métricas propuestas cuantifican la visibilidad de forma operativa, pero comprimen un fenómeno con matices semánticos y contextuales que un índice agregado no captura por completo.
- Madurez del sistema. GEO Analyzer es un prototipo funcional, no un producto en producción: existen límites conocidos de escalabilidad, automatización y robustez ante grandes volúmenes, y la segunda ronda experimental de análisis de fuentes hubo de limitarse a 60 prompts por restricciones de presupuesto de API.
- Ausencia de validación externa. No se ha contrastado el impacto práctico de las recomendaciones con usuarios reales ni con expertos del sector, por lo que su efecto sobre resultados tangibles —visibilidad o captación— queda pendiente de comprobación empírica.

9.3 LÍNEAS DE TRABAJO FUTURO

Las limitaciones anteriores trazan, casi en espejo, la agenda de continuación del trabajo.

- Corpus basado en la demanda real. Línea prioritaria: sustituir el corpus diseñado a priori por uno construido con consultas reales de usuarios, mejorando la validez ecológica del experimento y permitiendo ponderar los bloques por frecuencia de uso observada.
- Extensión a más modelos y validación longitudinal. Incorporar nuevas familias y versiones (incluidos sistemas con búsqueda en tiempo real como Perplexity) y, sobre todo,

explotar el módulo de snapshots para validar de forma longitudinal si las intervenciones de contenido modifican efectivamente la visibilidad, cerrando el ciclo medir–intervenir–medir.

- Métricas semánticas avanzadas. Desarrollar indicadores que integren relevancia percibida y matices de contexto más allá del recuento de menciones, aproximándose a una medida de calidad de la representación y no solo de presencia.
- Módulo de auditoría de contenido por URL. Complementar el análisis a nivel de programa con un análisis a nivel de URL: para cada página institucional citada como fuente, medir cuántas veces se cita, con qué precisión se reproducen sus datos y si su mención correlaciona con descripciones positivas o evasivas, identificando qué páginas posicionan bien y cuáles generan confusión, mediante un crawler que cruce las URLs citadas con elementos estructurales que los modelos valoran (datos cuantitativos, citas verificables, encabezados claros).
- Capacidad predictiva. Aprovechar la serie histórica almacenada para incorporar simulación: estimar el impacto esperado de un cambio en la web institucional antes de su publicación, consolidando GEO Analyzer como herramienta de inteligencia estratégica y no solo de diagnóstico.
- Validación en entorno real. Pilotar el sistema junto a un equipo de marketing o admisiones para medir el efecto de las estrategias GEO en métricas de negocio, dotando al trabajo de la validación externa de la que hoy carece.

CAPÍTULO 10. BIBLIOGRAFÍA

AboutChromebooks / StatCounter. (2025). Google Search Market Share Statistics 2025.

<https://www.aboutchromebooks.com/google-search-market-share/>

Aggarwal, P., Murahari, V., Rajpurohit, T., Kalyan, A., Narasimhan, K., & Deshpande, A. (2024). *GEO: Generative Engine Optimization. En KDD 2024 — Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (pp. 5-16). Association for Computing Machinery.* <https://doi.org/10.1145/3637528.3671900>

AutoGEO. (2025, noviembre). *Generative Engine Optimization (GEO): The Mechanics, Strategy, and Economic Impact of the Post-Search Era. ResearchGate.*

<https://www.researchgate.net/publication/398120277>

Bellan, R., & Forristal, L. (2025, October 6). *Sam Altman says ChatGPT has hit 800M weekly active users.* TechCrunch. Retrieved April 9, 2026, from

<https://techcrunch.com/2025/10/06/sam-altman-says-chatgpt-has-hit-800m-weekly-active-users/>

Columbia University & MIT. (2025, November 25). *E-GEO: A Testbed for Generative Engine Optimization in E-Commerce.* Retrieved April 9, 2026, from <https://arxiv.org/pdf/2511.20867>

Gartner Predicts Search Engine Volume Will Drop 25% by 2026, Due to AI Chatbots and Other Virtual Agents. (2024, February 19). Gartner. Retrieved April 9, 2026, from

<https://www.gartner.com/en/newsroom/press-releases/2024-02-19-gartner-predicts-search-engine-volume-will-drop-25-percent-by-2026-due-to-ai-chatbots-and-other-virtual-agents>

Gemini Developer API pricing | Gemini API. (2026, April 7). Google AI for Developers. Retrieved April 9, 2026, from <https://ai.google.dev/gemini-api/docs/pricing>

- GPT-4o Model | OpenAI API.* (n.d.). OpenAI Developers. Retrieved May 19, 2026, from <https://platform.openai.com/docs/models/gpt-4o>
- Ho, A. (2025, December 19). *The changing drivers of LLM adoption.* Epoch AI | Substack. Retrieved April 9, 2026, from <https://epochai.substack.com/p/the-changing-drivers-of-llm-adoption>
- Introducing Claude 3.5 Sonnet.* (2024, June 21). Anthropic. Retrieved May 19, 2026, from <https://www.anthropic.com/news/claude-3-5-sonnet>
- Kumar, A., & Lakkaraju, H. (2024). *Manipulating large language models to increase product visibility.* *arXiv.* <https://arxiv.org/abs/2404.07981>
- Models | Gemini API.* (2026, May 7). Google AI for Developers. Retrieved May 19, 2026, from <https://ai.google.dev/gemini-api/docs/models>
- Musk, E., & Fraser, M. (2025, August 11). *2025 AI Tools Usage Statistics: ChatGPT, Claude, Grok, Perplexity, DeepSeek & Gemini.* Views4You. Retrieved April 9, 2026, from <https://views4you.com/ai-tools-usage-statistics-report-2025/>
- OpenAI API Pricing.* (n.d.). OpenAI. Retrieved April 9, 2026, from <https://openai.com/api/pricing/>
- Pricing - Claude API Docs.* (n.d.). Claude Console. Retrieved April 9, 2026, from <https://platform.claude.com/docs/en/about-claude/pricing>
- Search Engine Land.* (2025). Google's search market share drops below 90% for first time since 2015. <https://searchengineland.com/google-search-market-share-drops-2024-450497>
- Search Engine Market Share Worldwide | Statcounter Global Stats.* (n.d.). StatCounter Global Stats. Retrieved April 9, 2026, from <https://gs.statcounter.com/search-engine-market-share>
- Singh, S. (2026, March 25). *ChatGPT Statistics (2026) – Active Users & Growth Data.* DemandSage. Retrieved April 9, 2026, from <https://www.demandsage.com/chatgpt-statistics/>

ANEXO I: GLOSARIO DE TÉRMINOS, SIGLAS Y ANGLICISMOS

En este anexo se recogen los principales términos técnicos, siglas y anglicismos utilizados a lo largo del documento, con el objetivo de facilitar su comprensión y asegurar la precisión conceptual.

A

API (Application Programming Interface) : Interfaz de programación que permite la comunicación entre diferentes sistemas software mediante un conjunto definido de reglas y protocolos.

B

Backend : Parte del sistema encargada de la lógica de negocio, procesamiento de datos y comunicación con bases de datos, no visible para el usuario final.

BaaS : Backend as a Service

C

CSV (Comma-Separated Values): Formato de archivo de texto utilizado para almacenar datos tabulares, donde los valores están separados por comas.

CTR: Click-Through Rate

D

Dashboard: Interfaz visual que presenta de forma estructurada métricas, gráficos y datos relevantes para facilitar su análisis e interpretación.

Dataset: Conjunto estructurado de datos utilizados para análisis, entrenamiento de modelos o evaluación de resultados.

F

Frontend: Parte del sistema con la que interactúa el usuario, encargada de la presentación visual y la experiencia de usuario.

FM: Frecuencia de Mención

G

GEO (Generative Engine Optimization): Conjunto de técnicas y métricas orientadas a mejorar la visibilidad de una entidad en motores generativos basados en modelos de lenguaje.

H

HTML (HyperText Markup Language): Lenguaje estándar de marcado utilizado para la creación de páginas web.

I

JSON (JavaScript Object Notation): Formato ligero de intercambio de datos basado en texto, ampliamente utilizado para representar estructuras de datos en aplicaciones web.

J

JWT: JSON Web Token

K

KPI: Key Performance Indicator

L

LLM (Large Language Model): Modelo de lenguaje de gran tamaño basado en redes neuronales, entrenado con grandes volúmenes de datos para generar texto en lenguaje natural.

M

Métrica: Medida cuantitativa utilizada para evaluar el rendimiento, comportamiento o características de un sistema.

Modelo: Representación matemática o computacional que permite simular o predecir comportamientos a partir de datos.

MOOC: Massive Open Online Course

N

NLP: Natural Language Processing – Procesamiento de Lenguaje Natural

NER: Named Entity Recognition – Reconocimiento de Entidades Nombradas

P

Prompt: Entrada de texto proporcionada a un modelo de lenguaje para generar una respuesta.

PostgreSQL: Sistema de gestión de bases de datos relacional de código abierto utilizado para almacenar y consultar datos estructurados.

PPM: Posición de Primera Mención

R

Response (Respuesta): Salida generada por un modelo de lenguaje a partir de un prompt dado.

ROI: Return on Investment

S

Score: Valor numérico que representa el resultado de una evaluación cuantitativa.

Score GEO: Métrica agregada que cuantifica la visibilidad de una entidad en motores generativos, normalmente en una escala normalizada.

Snapshot: Captura del estado de un sistema en un momento determinado, incluyendo datos y métricas asociadas.

SupaBase: Plataforma backend como servicio basada en PostgreSQL que proporciona almacenamiento, autenticación y APIs en tiempo real.

SEO: Search Engine Optimization

SERP: Search Engine Results Page

T

Tasa de mención: Proporción de respuestas en las que una entidad es mencionada respecto al total de respuestas analizadas.

Timestamp: Marca temporal que indica el momento exacto en el que se genera o almacena un dato.

TFM: Trabajo Fin de Máster

TPO: Tasa de Presencia Orgánica

U

UI (User Interface): Interfaz de usuario que permite la interacción entre el usuario y el sistema.

UX (User Experience): Experiencia global del usuario al interactuar con un sistema, incluyendo usabilidad y diseño.

V

Visualización de datos: Representación gráfica de información con el objetivo de facilitar su comprensión e interpretación.

ANEXO II: PROMPTS

```
[  
  {  
    "bloque": "recomendacion_general",  
    "prompt": "¿Cuál es el mejor máster en Big Data o Ciencia de Datos en España?"  
  },  
  {  
    "bloque": "recomendacion_general",  
    "prompt": "¿Qué máster en Big Data o Ciencia de Datos me recomiendas cursar en España?"  
  },  
  {  
    "bloque": "recomendacion_general",  
    "prompt": "¿Cuáles son los máster en Big Data o Ciencia de Datos más valorados en España?"  
  },  
  {  
    "bloque": "recomendacion_general",  
    "prompt": "¿Cuál es el máster en Big Data o Ciencia de Datos más reconocido por las empresas en España?"  
  },  
  {
```


"bloque": "recomendacion_general",

"prompt": "Dame un ranking de los mejores máster en Big Data o Ciencia de Datos en España"

},

{

"bloque": "recomendacion_general",

"prompt": "¿Qué máster en Big Data o Ciencia de Datos tienen mejor salida laboral en España?"

},

{

"bloque": "perfil_estudiante",

"prompt": "Soy un recién graduado en ingeniería de telecomunicaciones y quiero hacer un máster en Big Data o Ciencia de Datos. ¿Cuál me recomiendas en España?",

"perfil": "un recién graduado en ingeniería de telecomunicaciones"

},

{

"bloque": "perfil_estudiante",

"prompt": "Soy un graduado en ingeniería informática y quiero hacer un máster en Big Data o Ciencia de Datos. ¿Cuál me recomiendas en España?",

"perfil": "un graduado en ingeniería informática"

},

{

"bloque": "perfil_estudiante",

"prompt": "Soy un estudiante de matemáticas o estadística recién graduado y quiero hacer un máster en Big Data o Ciencia de Datos. ¿Cuál me recomiendas en España?",

"perfil": "un estudiante de matemáticas o estadística recién graduado"

},

{

"bloque": "perfil_estudiante",

"prompt": "Soy alguien con grado en ingeniería que quiere especializarse en datos y quiero hacer un máster en Big Data o Ciencia de Datos. ¿Cuál me recomiendas en España?",

"perfil": "alguien con grado en ingeniería que quiere especializarse en datos"

},

{

"bloque": "perfil_estudiante",

"prompt": "Tengo el perfil de un recién graduado en ingeniería de telecomunicaciones y me interesa el máster en Big Data o Ciencia de Datos. ¿Qué programa español me conviene más?",

"perfil": "un recién graduado en ingeniería de telecomunicaciones"

},

{

"bloque": "perfil_estudiante",

"prompt": "Tengo el perfil de un graduado en ingeniería informática y me interesa el máster en Big Data o Ciencia de Datos. ¿Qué programa español me conviene más?",

"perfil": "un graduado en ingeniería informática"

},

{

"bloque": "perfil_estudiante",

"prompt": "Tengo el perfil de un estudiante de matemáticas o estadística recién graduado y me interesa el máster en Big Data o Ciencia de Datos. ¿Qué programa español me conviene más?",

"perfil": "un estudiante de matemáticas o estadística recién graduado"

},

{

"bloque": "perfil_estudiante",

"prompt": "Tengo el perfil de alguien con grado en ingeniería que quiere especializarse en datos y me interesa el máster en Big Data o Ciencia de Datos. ¿Qué programa español me conviene más?",

"perfil": "alguien con grado en ingeniería que quiere especializarse en datos"

},

{

"bloque": "perfil_estudiante",

"prompt": "Como un recién graduado en ingeniería de telecomunicaciones, ¿qué máster en Big Data o Ciencia de Datos en España se adapta mejor a mi perfil?",

"perfil": "un recién graduado en ingeniería de telecomunicaciones"

},

{

"bloque": "perfil_estudiante",

"prompt": "Como un graduado en ingeniería informática, ¿qué máster en Big Data o Ciencia de Datos en España se adapta mejor a mi perfil?",

"perfil": "un graduado en ingeniería informática"

},

{

"bloque": "perfil_estudiante",

"prompt": "Como un estudiante de matemáticas o estadística recién graduado, ¿qué máster en Big Data o Ciencia de Datos en España se adapta mejor a mi perfil?",

"perfil": "un estudiante de matemáticas o estadística recién graduado"

},

```
{  
  "bloque": "perfil_estudiante",  
  "prompt": "Como alguien con grado en ingeniería que quiere especializarse en datos,  
  ¿qué máster en Big Data o Ciencia de Datos en España se adapta mejor a mi perfil?",  
  "perfil": "alguien con grado en ingeniería que quiere especializarse en datos"  
},  
{  
  "bloque": "perfil_profesional",  
  "prompt": "Soy un ingeniero de software con experiencia que quiere pasarse a datos y  
  quiero hacer un máster en Big Data o Ciencia de Datos. ¿Cuál me recomiendas en  
  España?",  
  "perfil": "un ingeniero de software con experiencia que quiere pasarse a datos"  
},  
{  
  "bloque": "perfil_profesional",  
  "prompt": "Soy un profesional del sector tecnológico que quiere reorientarse hacia Big  
  Data y quiero hacer un máster en Big Data o Ciencia de Datos. ¿Cuál me recomiendas en  
  España?",  
  "perfil": "un profesional del sector tecnológico que quiere reorientarse hacia Big Data"  
},  
{  
  "bloque": "perfil_profesional",  
  "prompt": "Soy un analista de datos junior que quiere formarse mejor y quiero hacer un  
  máster en Big Data o Ciencia de Datos. ¿Cuál me recomiendas en España?",  
  "perfil": "un analista de datos junior que quiere formarse mejor"  
},
```

```
{  
  "bloque": "perfil_profesional",  
  "prompt": "Soy un ingeniero de telecomunicaciones trabajando que busca reciclarse y  
quiero hacer un máster en Big Data o Ciencia de Datos. ¿Cuál me recomiendas en  
España?",  
  "perfil": "un ingeniero de telecomunicaciones trabajando que busca reciclarse"  
},  
{  
  "bloque": "perfil_profesional",  
  "prompt": "Trabajo como un ingeniero de software con experiencia que quiere pasarse a  
datos y quiero especializarme con un máster en Big Data o Ciencia de Datos. ¿Qué  
opciones hay en España?",  
  "perfil": "un ingeniero de software con experiencia que quiere pasarse a datos"  
},  
{  
  "bloque": "perfil_profesional",  
  "prompt": "Trabajo como un profesional del sector tecnológico que quiere reorientarse  
hacia Big Data y quiero especializarme con un máster en Big Data o Ciencia de Datos.  
¿Qué opciones hay en España?",  
  "perfil": "un profesional del sector tecnológico que quiere reorientarse hacia Big Data"  
},  
{  
  "bloque": "perfil_profesional",  
  "prompt": "Trabajo como un analista de datos junior que quiere formarse mejor y quiero  
especializarme con un máster en Big Data o Ciencia de Datos. ¿Qué opciones hay en  
España?",  
  "perfil": "un analista de datos junior que quiere formarse mejor"
```

},

{

"bloque": "perfil_profesional",

"prompt": "Trabajo como un ingeniero de telecomunicaciones trabajando que busca reciclarse y quiero especializarme con un máster en Big Data o Ciencia de Datos. ¿Qué opciones hay en España?",

"perfil": "un ingeniero de telecomunicaciones trabajando que busca reciclarse"

},

{

"bloque": "perfil_profesional",

"prompt": "Como un ingeniero de software con experiencia que quiere pasarse a datos, ¿qué máster en Big Data o Ciencia de Datos español me ayudaría más a avanzar profesionalmente?",

"perfil": "un ingeniero de software con experiencia que quiere pasarse a datos"

},

{

"bloque": "perfil_profesional",

"prompt": "Como un profesional del sector tecnológico que quiere reorientarse hacia Big Data, ¿qué máster en Big Data o Ciencia de Datos español me ayudaría más a avanzar profesionalmente?",

"perfil": "un profesional del sector tecnológico que quiere reorientarse hacia Big Data"

},

{

"bloque": "perfil_profesional",

"prompt": "Como un analista de datos junior que quiere formarse mejor, ¿qué máster en Big Data o Ciencia de Datos español me ayudaría más a avanzar profesionalmente?",

"perfil": "un analista de datos junior que quiere formarse mejor"

},

{

"bloque": "perfil_profesional",

"prompt": "Como un ingeniero de telecomunicaciones trabajando que busca reciclarse, ¿qué máster en Big Data o Ciencia de Datos español me ayudaría más a avanzar profesionalmente?",

"perfil": "un ingeniero de telecomunicaciones trabajando que busca reciclarse"

},

{

"bloque": "comparativa",

"prompt": "Compara el Máster en Big Data de ICAI con el Máster en Data Science de KSchool en términos de calidad y salidas laborales",

"par": [

"Máster en Big Data de ICAI",

"Máster en Data Science de KSchool"

]

},

{

"bloque": "comparativa",

"prompt": "¿Cuál es mejor, el Máster en Big Data de ICAI o el Máster en Data Science de KSchool?",

"par": [

"Máster en Big Data de ICAI",

"Máster en Data Science de KSchool"

]

},

```
{  
  "bloque": "comparativa",  
  "prompt": "¿En qué se diferencian el Máster en Big Data de ICAI y el Máster en Data  
Science de KSchool?",  
  "par": [  
    "Máster en Big Data de ICAI",  
    "Máster en Data Science de KSchool"  
  ]  
},  
{  
  "bloque": "comparativa",  
  "prompt": "Si tuviera que elegir entre el Máster en Big Data de ICAI y el Máster en Data  
Science de KSchool, ¿cuál me recomiendas?",  
  "par": [  
    "Máster en Big Data de ICAI",  
    "Máster en Data Science de KSchool"  
  ]  
},  
{  
  "bloque": "comparativa",  
  "prompt": "Compara el Máster en Big Data de ICAI con el Máster en Big Data y Data  
Science de la UAM en términos de calidad y salidas laborales",  
  "par": [  
    "Máster en Big Data de ICAI",  
    "Máster en Big Data y Data Science de la UAM"
```


]

},

{

"bloque": "comparativa",

"prompt": "¿Cuál es mejor, el Máster en Big Data de ICAI o el Máster en Big Data y Data Science de la UAM?",

"par": [

"Máster en Big Data de ICAI",

"Máster en Big Data y Data Science de la UAM"

]

},

{

"bloque": "comparativa",

"prompt": "¿En qué se diferencian el Máster en Big Data de ICAI y el Máster en Big Data y Data Science de la UAM?",

"par": [

"Máster en Big Data de ICAI",

"Máster en Big Data y Data Science de la UAM"

]

},

{

"bloque": "comparativa",

"prompt": "Si tuviera que elegir entre el Máster en Big Data de ICAI y el Máster en Big Data y Data Science de la UAM, ¿cuál me recomiendas?",

"par": [

"Máster en Big Data de ICAI",

"Máster en Big Data y Data Science de la UAM"

]

},

{

"bloque": "comparativa",

"prompt": "Compara el Máster en Big Data de ICAI con el Máster en Big Data de la UPM en términos de calidad y salidas laborales",

"par": [

"Máster en Big Data de ICAI",

"Máster en Big Data de la UPM"

]

},

{

"bloque": "comparativa",

"prompt": "¿Cuál es mejor, el Máster en Big Data de ICAI o el Máster en Big Data de la UPM?",

"par": [

"Máster en Big Data de ICAI",

"Máster en Big Data de la UPM"

]

},

{

"bloque": "comparativa",

"prompt": "¿En qué se diferencian el Máster en Big Data de ICAI y el Máster en Big Data de la UPM?",

"par": [
 "Máster en Big Data de ICAI",
 "Máster en Big Data de la UPM"
],
{

 "bloque": "comparativa",

"prompt": "Si tuviera que elegir entre el Máster en Big Data de ICAI y el Máster en Big Data de la UPM, ¿cuál me recomiendas?",

"par": [
 "Máster en Big Data de ICAI",
 "Máster en Big Data de la UPM"
],
},
{

 "bloque": "comparativa",

"prompt": "Compara el Máster en Big Data de ICAI con el Máster en Data Science de la UOC en términos de calidad y salidas laborales",

"par": [
 "Máster en Big Data de ICAI",
 "Máster en Data Science de la UOC"
],
},

```
{  
  "bloque": "comparativa",  
  "prompt": "¿Cuál es mejor, el Máster en Big Data de ICAI o el Máster en Data Science de la UOC?",  
  "par": [  
    "Máster en Big Data de ICAI",  
    "Máster en Data Science de la UOC"  
  ]  
},  
{  
  "bloque": "comparativa",  
  "prompt": "¿En qué se diferencian el Máster en Big Data de ICAI y el Máster en Data Science de la UOC?",  
  "par": [  
    "Máster en Big Data de ICAI",  
    "Máster en Data Science de la UOC"  
  ]  
},  
{  
  "bloque": "comparativa",  
  "prompt": "Si tuviera que elegir entre el Máster en Big Data de ICAI y el Máster en Data Science de la UOC, ¿cuál me recomiendas?",  
  "par": [  
    "Máster en Big Data de ICAI",  
    "Máster en Data Science de la UOC"
```

]

},

{

"bloque": "comparativa",

"prompt": "Compara el Máster en Big Data de ICAI con el Máster en Big Data y Data Science de UNIR en términos de calidad y salidas laborales",

"par": [

"Máster en Big Data de ICAI",

"Máster en Big Data y Data Science de UNIR"

]

},

{

"bloque": "comparativa",

"prompt": "¿Cuál es mejor, el Máster en Big Data de ICAI o el Máster en Big Data y Data Science de UNIR?",

"par": [

"Máster en Big Data de ICAI",

"Máster en Big Data y Data Science de UNIR"

]

},

{

"bloque": "comparativa",

"prompt": "¿En qué se diferencian el Máster en Big Data de ICAI y el Máster en Big Data y Data Science de UNIR?",

"par": [

"Máster en Big Data de ICAI",

"Máster en Big Data y Data Science de UNIR"

]

},

{

"bloque": "comparativa",

"prompt": "Si tuviera que elegir entre el Máster en Big Data de ICAI y el Máster en Big Data y Data Science de UNIR, ¿cuál me recomiendas?",

"par": [

"Máster en Big Data de ICAI",

"Máster en Big Data y Data Science de UNIR"

]

},

{

"bloque": "especifico_icaei",

"prompt": "¿Qué temario tiene el Máster en Big Data de ICAI (Universidad Pontificia Comillas)?"

},

{

"bloque": "especifico_icaei",

"prompt": "¿Cuáles son las salidas profesionales del Máster en Big Data de ICAI (Universidad Pontificia Comillas)?"

},

{

"bloque": "especifico_icaei",

"prompt": "¿Cuánto cuesta el Máster en Big Data de ICAI (Universidad Pontificia Comillas)?"

},

{

"bloque": "especifico_icaei",

"prompt": "¿Qué requisitos de acceso tiene el Máster en Big Data de ICAI (Universidad Pontificia Comillas)?"

},

{

"bloque": "especifico_icaei",

"prompt": "¿Está bien valorado el Máster en Big Data de ICAI (Universidad Pontificia Comillas) por las empresas?"

},

{

"bloque": "especifico_icaei",

"prompt": "¿Qué empresas contratan a los egresados del Máster en Big Data de ICAI (Universidad Pontificia Comillas)?"

},

{

"bloque": "especifico_icaei",

"prompt": "¿Es presencial u online el Máster en Big Data de ICAI (Universidad Pontificia Comillas)?"

},

{

"bloque": "especifico_icaei",

"prompt": "¿Qué diferencia al Máster en Big Data de ICAI (Universidad Pontificia Comillas) de otros másteres similares?"

},

{

"bloque": "especifico_icaei",

"prompt": "¿Tiene el Máster en Big Data de ICAI (Universidad Pontificia Comillas) convenios con empresas o prácticas?"

},

{

"bloque": "especifico_icaei",

"prompt": "¿Qué opinan los alumnos del Máster en Big Data de ICAI (Universidad Pontificia Comillas)?"

}

]