

PREDICTIVE OPTIMIZATION IN SEO

Optimización Predictiva en SEO

EXPLORING PREDICTIVE MODELS TO ANTICIPATE
TRENDS AND IMPROVE STRATEGIES IN SEO

Explorando modelos predictivos para anticipar
tendencias y mejorar estrategias en SEO

Jorge Sánchez Mosquete





**Jorge
Sánchez
Mosquete**

Predictive Optimization in SEO

Optimización Predictiva en SEO

Draft: February 09, 2025

"The future of SEO is not about reacting to changes, but anticipating them. In a world where algorithms evolve at the speed of AI, those who master predictive analysis will not only reach the top of the rankings but also redefine the rules of the digital game."

"El futuro del SEO no se trata de reaccionar a los cambios, sino de anticiparse. En un mundo donde los algoritmos evolucionan a la velocidad de la IA, quien domine el análisis predictivo no solo alcanzará la cima del ranking, sino que redefinirá las reglas del juego digital."

- Jorge Sánchez Mosquete

Autor:

Jorge Sánchez Mosquete

SEO Senior Consultant & CEO at Netbulb Marketing Agency

Head of SEO at Rommel & Montgomery Marketing Agency

Email: jorge@jorgesanmos.com

Linkedin: [in/jorgesanmos](https://www.linkedin.com/in/jorgesanmos)

Abstract

Predictive SEO combines advanced data analysis tools, artificial intelligence, and digital strategies to anticipate search trends and improve visibility on search engines. This approach focuses on leveraging statistical models and algorithms to uncover hidden patterns in user behavior and predict key metrics such as organic traffic and click-through rates (CTR).

By utilizing technologies like Python, Power BI, and SQL, companies can better adapt to evolving search engine algorithms and user behaviors. These tools not only simplify the processing of large data volumes but also enable the creation of tailored strategies specific to each market niche.

In a digital landscape that evolves at an ever-increasing pace, predictive SEO stands out as a crucial solution for businesses aiming to remain competitive. This document delves into how the integration of predictive models with data-driven methodologies can reshape digital strategies and foster sustainable growth for organizations.

Resumen

El SEO predictivo combina herramientas avanzadas de análisis de datos, inteligencia artificial y estrategias digitales para anticiparse a las tendencias de búsqueda y optimizar la visibilidad en los motores de búsqueda. Este enfoque se centra en aprovechar modelos estadísticos y algoritmos para identificar patrones ocultos en el comportamiento de los usuarios y estimar métricas clave como el tráfico orgánico o las tasas de clics (CTR).

A través del uso de tecnologías como Python, Power BI y SQL, las empresas pueden mejorar su capacidad de respuesta frente a los cambios en los algoritmos de los motores de búsqueda y en las preferencias del usuario. Estas herramientas no solo simplifican el manejo de grandes volúmenes de datos, sino que también facilitan la creación de estrategias personalizadas para cada nicho de mercado.

En un entorno digital que evoluciona rápidamente, el SEO predictivo emerge como una solución imprescindible para quienes buscan mantenerse competitivos. Este documento explora cómo la integración de modelos predictivos con metodologías basadas en datos puede transformar las estrategias digitales y ayudar a las empresas a alcanzar un crecimiento sostenible.

Keywords:

English: Predictive SEO, SEO, Machine Learning, SEO Data Analytics, Search Behavior Prediction, Ranking Prediction, CTR Forecasting, Keyword Research, AI in SEO, Web Traffic Prediction, SEO Automation.

Español: SEO predictivo, SEO, aprendizaje automático, análisis de datos, predicción de búsqueda, estimación de rankings, forecasting de CTR, investigación de palabras clave, IA en SEO, predicción de tráfico, automatización en SEO.

ÍNDICE

1. Introducción.....	5
1.1. Evolución del SEO hacia un enfoque basado en datos.....	5
1.2. Los desafíos en la predicción.....	5
1.2.1. Volatilidad del mercado digital.....	5
1.2.2. Cambios en los algoritmos de los motores de búsqueda.....	6
1.2.3. Calidad y sesgo en los datos.....	7
1.2.4. Competencia online.....	8
1.2.5. Comportamiento de los usuarios.....	8
1.3. Importancia de combinar modelos predictivos en SEO.....	8
1.3.1. Modelos de series temporales.....	9
1.3.2. Redes neuronales.....	9
1.3.3. Machine Learning supervisado y no supervisado.....	9
2. Modelos predictivos en SEO.....	10
2.1. Modelos de regresión lineal y logística.....	10
2.2. Modelos de series temporales: ARIMA y SARIMA.....	11
2.3. Modelos de Machine Learning.....	13
2.4. Otros modelos predictivos.....	15
3. Métodos y herramientas.....	16
3.1. Uso de Big Data.....	16
3.2. Herramientas para el análisis en modelos predictivos.....	17
4. Ejemplo de métodos de predicción centrado en el posicionamiento SEO.....	20
4.1. Modelos predictivos basados en clustering y análisis de cohortes.....	20
4.1.1. Clustering.....	20
4.1.2. Análisis de cohortes.....	27
4.2. Estimaciones de ROI y tráfico web.....	33
4.2.1. Modelos ARIMA para tráfico web.....	33
4.2.2. LSTM para predicción de ROI.....	36
4.3. Predicción de clics en Google Search Console.....	39
4.3.1. Desarrollo en Python.....	39
4.3.2. División de Datos.....	41
4.3.3. Aplicación del Modelo ARIMA.....	41
4.3.4. Visualización de Predicciones.....	43
4.4. Predicción de CTR y rankings con datos combinados.....	44
4.4.1. Preparación de los datos.....	44
4.4.2. Entrenamiento del modelo.....	45
4.4.3. Análisis de resultados.....	47
4.4.4. Visualización.....	48
4.4.5. Resultado.....	48

4.5. Otras Posibilidades en SEO predictivo con Python.....	49
4.5.1. Modelado de impacto de actualizaciones de Google.....	49
4.5.2. Optimización dinámica del enlazado interno.....	50
4.5.3. Análisis semántico avanzado con NLP.....	50
4.5.4. Automatización de estrategias de contenido predictivo.....	50
4.5.5. Predicción de conversión y ROI en SEO.....	50
4.5.6. Identificación de anomalías en el tráfico web.....	50
4.5.7. Optimización predictiva para búsqueda por voz y asistentes virtuales.....	50
5. Evaluación de resultados.....	51
5.1. Comparación entre predicciones y resultados reales.....	51
5.2. Indicadores clave de rendimiento (KPIs) en SEO predictivo.....	52
5.3. Discusión sobre desafíos y limitaciones.....	52
Conclusiones.....	54
Referencias.....	56

1.Introducción

1.1. Evolución del SEO hacia un enfoque basado en datos

El SEO predictivo representa la convergencia entre el análisis de datos, la Inteligencia Artificial y las estrategias de optimización en entornos digitales. Basado en modelos predictivos, este enfoque analítico es más preciso, y permite prever comportamientos, tendencias de búsqueda para mejorar la toma de decisiones estratégicas.

Y es que, el SEO ha evolucionado significativamente desde sus inicios. Pasó de una estrategia basada en palabras clave y enlaces a un enfoque más analítico donde la experiencia del usuario (UX) y la inteligencia artificial desempeñan actualmente un papel clave [1] .

Con la llegada de la inteligencia artificial y el big data, ha permitido a los consultores senior en Data-Driven como especialistas en posicionamiento, evolucionar de una forma más rápida para analizar patrones de búsqueda en tiempo real y transformando el SEO en una disciplina predictiva.

Algoritmos como Panda, Penguin y Hummingbird fueron pioneros en priorizar la calidad del contenido, penalizando prácticas obsoletas como el relleno de palabras clave. Más recientemente, Core Web Vitals reforzó la importancia del UX, consolidando un posicionamiento orientado al rendimiento y la interacción.

Pero hoy en día, el SEO predictivo emerge como una solución avanzada que fusiona análisis descriptivo con la proyección futura.

1.2. Los desafíos en la predicción

A pesar de los avances tecnológicos, un punto complejo es predecir con precisión las tendencias de búsqueda y el comportamiento de los usuarios en internet, requiriendo tareas manuales y análisis de personas especialistas para las correcciones oportunas para afinar los resultados que nos aportan las herramientas como los dashboards.

1.2.1. Volatilidad del mercado digital

El comportamiento de los usuarios en internet es altamente volátil a eventos externos e imprevistos, como pandemias, crisis económicas, desastres

naturales o fenómenos virales en redes sociales. Estos eventos pueden alterar drásticamente las prioridades e intereses de los usuarios, generando fluctuaciones abruptas en las tendencias de búsqueda y totalmente atemporales.

Un ejemplo claro, fue durante la pandemia del COVID-19, las búsquedas relacionadas con "mascarillas" experimentaron un crecimiento exponencial en un corto período, superando las predicciones iniciales de muchas herramientas analíticas, tal como muestra Google Trends [2].




Imagen 1 | Interés a lo largo del tiempo para la palabra clave "mascarillas". Elaboración propia basada en datos de Google Trend

1.2.2. Cambios en los algoritmos de los motores de búsqueda

Todos los motores de búsqueda, con Google como referente mundial, están en constante cambio con frecuentes actualizaciones en sus algoritmos para garantizar resultados de búsqueda más relevantes, mejorar la experiencia del usuario en los resultados y evitar prácticas de SEO fraudulento. Estas actualizaciones pueden convertir estrategias efectivas en obsoletas en cuestión de día, debiendo tener un aprendizaje y una adaptación constante por parte de los profesionales.

En 2024, Google introdujo una nueva actualización con un enfoque más profundo en la calidad del contenido a través del denominado "Helpful Content System" [3].

Este sistema, impulsado por inteligencia artificial generativa, prioriza contenido que responda directamente a la intención del usuario, penalizando aquel que sea redundante o creado exclusivamente para manipular rankings.

Además del enfoque en la calidad del contenido, Google también ha seguido optimizando la experiencia de usuario. El perfeccionamiento continuo de los Core Web Vitals, iniciado en 2021, sigue impactando en 2025, con métricas adicionales como Interaction to Next Paint (INP) [4] y la optimización del consumo energético en dispositivos móviles.

Estas métricas exigen a las empresas no solo garantizar la velocidad de carga, sino también una experiencia interactiva fluida y accesible desde cualquier dispositivo

2024		
SUMMARY	DATE	DURATION
December 2024 spam update	19 Dec 2024	✓ 7 days, 2 hours
December 2024 core update	12 Dec 2024	✓ 6 days, 4 hours
November 2024 core update	11 Nov 2024	✓ 23 days, 13 hours
Ranking is experiencing an ongoing issue.	15 Aug 2024	✓ 4 days, 11 hours
August 2024 core update	15 Aug 2024	✓ 19 days, 4 hours
June 2024 spam update	20 Jun 2024	✓ 7 days, 1 hour
March 2024 spam update	5 Mar 2024	✓ 14 days, 21 hours
March 2024 core update	5 Mar 2024	✓ 45 days

Imagen 2 | Resumen de actualizaciones de los algoritmos de Google en 2024. Fuente: Google Search Status Dashboard, 2025

1.2.3. Calidad y sesgo en los datos

Una de las cosas que se debe hacer a la hora de trabajar con los modelos predictivos, es que los datos utilizados en las hojas de cálculos deben estar siempre limpios, correctos y ordenados, evitando datos incompletos, campos vacíos, diferentes formatos, sesgados o inexactos; ya que pueden llevar a errores o estrategias imprecisas. Además, la falta de representación adecuada en los datos puede amplificar sesgos existentes en los algoritmos de aprendizaje automático.

1.2.4. Competencia online

Otro punto a tener en cuenta es el entorno digital, que se caracteriza por una competencia creciente y exponencial debido a la digitalización de las empresas. Por este motivo, cada vez es más difícil posicionarse e identificar oportunidades emergentes debiendo trabajar, cada vez más, en técnicas más avanzadas, precisas y procesos de análisis automatizados para superar a la competencia.

1.2.5. Comportamiento de los usuarios

Los usuarios, de forma general, no siempre toman decisiones de búsqueda de manera lógica o predecible. Factores como emociones, cultural, influencias sociales y psicología del consumidor pueden generar patrones de comportamiento que son difíciles de modelar, pudiendo generar picos inesperados en búsquedas de términos específicos.

Además, las búsquedas no siempre reflejan una intención clara o directa. Un usuario puede buscar "mejor portátil 2025" con la intención de comprar, investigar o simplemente comparar, lo que dificulta predecir con precisión el objetivo real detrás de su consulta.

Esta falta de uniformidad en el comportamiento, combinada con el constante cambio de intereses, tendencias y preferencias personales, representa un desafío significativo para los modelos predictivos.

Por este motivo, los enfoques avanzados en SEO deben integrar no solo datos cuantitativos, sino también un análisis cualitativo profundo, considerando variables contextuales, estacionales y psicológicas para mejorar la precisión en la predicción de tendencias y comportamientos de búsqueda, sin olvidarnos del intervalo de confianza (margen de error).

1.3. Importancia de combinar modelos predictivos en SEO

El SEO predictivo representa la convergencia estratégica entre la ciencia de datos y el marketing digital. Este enfoque novedoso y que poco a poco se volverá como un trabajo recurrente, integra modelos para anticipar cambios en el comportamiento del usuario y las tendencias dinámicas del mercado. Al aprovechar esta sinergia, los profesionales del SEO pueden optimizar sus estrategias más precisas y, aquellos que la implanten, tendrán una ventaja competitiva significativa.

1.3.1. Modelos de series temporales

Estos modelos son particularmente útiles para examinar datos históricos de rendimiento y proyectar tendencias futuras con precisión. Por ejemplo, ARIMA se utiliza para pronosticar el volumen de búsquedas de una palabra clave específica durante un período estacional determinado, lo que permite a los especialistas en SEO ajustar sus estrategias de contenido y optimización en consecuencia.

1.3.2. Redes neuronales

LSTM, una variante sofisticada de las redes neuronales recurrentes, es ideal para procesar secuencias de datos y descubrir patrones intrincados en conjuntos masivos de información. Estas redes neuronales avanzadas se pueden utilizar para predecir fluctuaciones en el tráfico web y las tasas de conversión, lo que ayuda a los profesionales del marketing a optimizar sus campañas y mejorar el retorno de la inversión.

1.3.3. Machine Learning supervisado y no supervisado

Técnicas como Random Forest y clustering permiten clasificar datos y segmentar comportamientos de usuarios para identificar oportunidades de optimización y personalización.

Random Forest, un algoritmo de aprendizaje supervisado, puede evaluar la importancia de diferentes factores de clasificación, como la calidad del contenido y la autoridad del dominio, para determinar su impacto en el ranking de búsqueda.

El clustering, una técnica de aprendizaje no supervisado, puede agrupar usuarios con características y preferencias similares, lo que permite a los especialistas en SEO adaptar sus estrategias de contenido y personalización para satisfacer las necesidades específicas de cada segmento de audiencia.

Además de los modelos, las herramientas tecnológicas desempeñan un papel fundamental en el SEO predictivo. Python, un lenguaje de programación versátil y potente, ofrece bibliotecas especializadas como pandas ^[16], NumPy ^[12], scikit-learn y TensorFlow ^[6] para el análisis y modelado de datos. Estas bibliotecas proporcionan las funcionalidades necesarias para limpiar, transformar, analizar y modelar datos de SEO.

Por otro lado, plataformas de visualización de datos como Power BI y Tableau facilitan la creación de informes y paneles interactivos que permiten a los responsables de marketing o clientes comprender y comunicar los resultados de manera efectiva.

2. Modelos predictivos en SEO

2.1. Modelos de regresión lineal y logística

Entre los modelos más utilizados en el análisis SEO, se encuentra la regresión lineal, que sirve para evaluar la relación entre dos variables continuas. Por ejemplo, puede analizar cómo el número de backlinks afecta al ranking promedio de una página web. En el ámbito del SEO, un mayor número de backlinks relevantes suele correlacionarse con un mejor posicionamiento en los resultados de búsqueda, lo que incrementa la visibilidad y el tráfico orgánico.

La regresión lineal no solo permite visualizar la relación entre estas variables, sino también proyectar tendencias futuras. Además, el uso de un intervalo de confianza ayuda a interpretar la incertidumbre de las predicciones, destacando la precisión del modelo y la variabilidad de los datos analizados.

En el siguiente ejemplo se utiliza un modelo de regresión lineal para analizar la relación entre el número de backlinks (eje X) y el ranking promedio de una página web (eje Y). El ranking promedio es una métrica clave en SEO, donde un valor más bajo indica un mejor posicionamiento en los resultados de búsqueda.




Imagen 3 | Relación entre backlinks y ranking promedio con línea de regresión. La gráfica ilustra cómo el número de backlinks impacta el ranking promedio de una página web en los resultados de búsqueda. Los datos originales están representados por puntos azules, mientras que la línea roja corresponde al modelo de regresión lineal. El área sombreada en rojo muestra el intervalo de confianza, que indica la incertidumbre de las predicciones. Fuente: Elaboración propia con datos simulados, 2025.

En cambio, la regresión logística, se utiliza cuando la variable dependiente es categórica. En SEO, se puede predecir si una página tendrá éxito en alcanzar las tres primeras posiciones en los resultados de búsqueda basándose en factores como la autoridad del dominio y la densidad de palabras clave.

2.2. Modelos de series temporales: ARIMA y SARIMA

El análisis de series temporales es una herramienta clave en el SEO predictivo, ya que permite detectar patrones en los datos históricos y anticipar tendencias futuras. Entre los modelos más utilizados en este campo destacan ARIMA y SARIMA, ambos empleados para predecir el tráfico web y optimizar estrategias digitales basadas en datos.

El modelo ARIMA (AutoRegressive Integrated Moving Average) se emplea para analizar series temporales y realizar predicciones cuando los datos muestran tendencias pero carecen de estacionalidad. Es útil en el ámbito del SEO para prever fluctuaciones en el tráfico web, facilitando la toma de decisiones en estrategias de contenido y campañas de marketing digital.

En escenarios donde no hay una estacionalidad clara, ARIMA ayuda a predecir el tráfico en función de patrones históricos, permitiendo la optimización del contenido en función de las tendencias emergentes.




Imagen 4 | Predicción de tráfico en campus virtual (ARIMA). Este gráfico muestra la proyección del tráfico web en una plataforma educativa basada en datos históricos de los últimos dos años. La línea azul representa el tráfico registrado, mientras que la línea roja discontinua indica la predicción para los próximos 30 días, permitiendo anticipar fluctuaciones y ajustar la estrategia digital. Fuente: Elaboración propia con datos simulados, 2025.

Para datos que presentan un comportamiento estacional, el modelo SARIMA (Seasonal ARIMA) es una mejor opción. Este modelo es ideal para predecir fluctuaciones en mercados con ciclos estacionales definidos, como el comportamiento de compras en eventos recurrentes (Black Friday, Navidad, periodos de inscripción académica, etc.).

En el SEO, SARIMA permite prever cambios en la demanda de palabras clave o tráfico en función de patrones estacionales, ayudando a las empresas a ajustar su estrategia de marketing digital con mayor precisión.




Imagen 5 | Predicción de inscripciones en plataforma educativa (SARIMA). Este gráfico ilustra la tendencia de inscripciones en una plataforma educativa en línea. La serie de datos muestra un patrón estacional, donde la cantidad de inscripciones aumenta cada trimestre. La línea azul representa el historial de inscripciones, mientras que la línea roja discontinua proyecta la tendencia futura en los próximos ocho trimestres. Fuente: Elaboración propia con datos simulados, 2025.

2.3. Modelos de Machine Learning

Los modelos avanzados como LSTM, Random Forest y Gradient Boosting son herramientas poderosas que permiten analizar grandes volúmenes de datos y generar predicciones precisas en SEO predictivo. A continuación, se detallan sus fundamentos técnicos, aplicaciones específicas y un ejemplo práctico implementado en Python.

Las redes neuronales LSTM son una variante de las redes neuronales recurrentes (RNN) diseñadas específicamente para trabajar con secuencias de datos temporales. Estas redes son especialmente efectivas en problemas donde la dependencia a largo plazo es clave, como las predicciones basadas en datos históricos.

La arquitectura de las LSTM incluye componentes específicos que regulan el flujo de datos entre las celdas. Estas estructuras, comúnmente llamadas puertas, desempeñan funciones clave: La puerta de entrada define la información que será almacenada, mientras que la puerta de olvido decide qué datos deben descartarse. Por último, la puerta de salida gestiona la información que será utilizada como resultado del proceso.

Estas características hacen que las LSTM sean ideales para manejar series temporales complejas como el tráfico web. En lo que respecta en las funciones de SEO, sirve para:

1. **Predicción de tráfico web:** Anticipar picos de tráfico en función de datos históricos.
2. **Conversión de usuarios:** Identificar cuándo es más probable que un usuario realice una conversión.
3. **Análisis de tendencias:** Detectar patrones en palabras clave o comportamientos de búsqueda.

Random Forest es un método de aprendizaje supervisado que combina varios árboles de decisión para generar predicciones más precisas. Esta técnica destaca por minimizar el sobreajuste al promediar los resultados de múltiples árboles, lo que también incrementa la estabilidad del modelo. Entre sus características principales se encuentran:

- Construye múltiples árboles de decisión a partir de subconjuntos aleatorios de datos.
- Cada árbol vota por una predicción, y la mayoría determina la salida final.

Aplicándolo al posicionamiento web, se pueden identificar los factores que más afectan el CTR, Clasificar páginas según su rendimiento esperado y predecir las probabilidades de que una palabra clave alcance el Top 3 en el ranking.

Y el último modelo de Machine Learning para trabajar el SEO es el Gradient Boosting. Optimiza la precisión combinando modelos débiles en una estructura fuerte, enfocándose en minimizar los errores en cada iteración. Su principal funcionamiento se basa en:

- Construir árboles secuencialmente, donde cada árbol corrige los errores del anterior.
- Utilizar técnicas avanzadas como regularización para evitar sobreajuste.

Árbol de Decisión Aplicado a SEO Predictivo




Imagen 6 | Árbol de Decisión Aplicado a SEO Predictivo Visualización de un árbol de decisión aplicado a SEO predictivo. El modelo clasifica páginas web en función de factores clave como la autoridad del dominio, la velocidad de carga, la optimización del contenido y los backlinks de calidad. Se predice la probabilidad de que una página alcance el Top 3 en Google. Datos simulados para representar la toma de decisiones en SEO. Fuente: Elaboración propia con datos simulados, 2025.

Aplicándolo a estrategias de SEO, se puede predecir tasas de conversión en función de múltiples variables, optimizar estrategias de contenido basándose en predicciones de rendimiento o identificar patrones ocultos en datos de usuarios.

2.4. Otros modelos predictivos

Además de los modelos de regresión, series temporales y machine learning ya mencionados, existen otros enfoques que pueden aplicarse en SEO predictivo en función del contexto y los datos disponibles. Algunos de ellos incluyen:

- **Modelos bayesianos (Naïve Bayes, Bayesian Optimization):** Se utilizan en la clasificación de consultas de búsqueda, predicción de intención del usuario y optimización de CTR en pruebas A/B.
- **Prophet de Facebook:** Un modelo de series temporales diseñado para manejar datos con estacionalidad y tendencias abruptas, útil para predecir tráfico web y demanda de palabras clave en eventos como Black Friday o periodos de matriculación en el sector educativo.

- **Redes neuronales transformer (BERT, T5, GPT):** Aplicadas en la optimización semántica del contenido, detección de similitud de palabras clave y generación automática de metadescripciones y snippets optimizados para SEO.

Estos modelos pueden complementar las estrategias de análisis predictivo, especialmente en áreas donde el procesamiento de lenguaje natural y la predicción de tendencias de búsqueda juegan un papel clave. Sin embargo, su aplicación dependerá de los objetivos específicos del análisis y de la disponibilidad de datos para su entrenamiento.

3. Métodos y herramientas

3.1. Uso de Big Data

El SEO predictivo se basa en el análisis de grandes volúmenes de datos recopilados de múltiples fuentes. Las APIs desempeñan un papel crucial al proporcionar acceso directo a datos relevantes:

a) Google Analytics API:

Permite extraer métricas detalladas sobre el comportamiento del usuario, como páginas vistas, duración de la sesión y conversiones [10]. Estos datos pueden alimentar modelos predictivos para anticipar patrones futuros de tráfico.

b) Google Search Console API:

Ofrece información sobre palabras clave, CTR y posiciones en los resultados de búsqueda [11]. Estos datos se utilizan para identificar tendencias en el rendimiento de palabras clave y prever cambios en el ranking.

c) API de herramientas SEO:

Facilitan el análisis de backlinks, palabras clave y competencia. Los datos obtenidos se pueden integrar en modelos de Machine Learning para prever cómo los cambios en la estrategia de enlaces afectarán el tráfico orgánico.

d) Uso práctico del Big Data:

Con herramientas como Python y SQL, los datos recopilados a través de estas APIs se limpian, estructuran y analizan. Por ejemplo, los datos históricos de tráfico se pueden combinar con el análisis de tendencias de búsqueda para identificar oportunidades emergentes.

3.2. Herramientas para el análisis en modelos predictivos

El SEO predictivo requiere una combinación de herramientas tecnológicas para la extracción, análisis y visualización de datos [6].

a) Python:

1. Extracción de datos

- **requests**: Realiza solicitudes HTTP para interactuar con sitios web y APIs.
- **BeautifulSoup (bs4)**: Permite analizar HTML y XML para extraer datos estructurados.
- **Scrapy**: Framework especializado en web scraping masivo y robusto.
- **Selenium**: Automatiza navegadores para extraer datos de sitios dinámicos (generados por JavaScript).
- **pytrends**: Conecta con Google Trends para obtener datos sobre tendencias de búsqueda.
- **google-auth**: Autenticación segura para APIs de Google, como Google Analytics o Google Search Console.
- **gsread**: Permite leer y escribir en Google Sheets.
- **lxml**: Procesa y analiza documentos HTML y XML de forma rápida y eficiente.

2. Análisis y modelado

- **pandas**: Gestión y análisis de datos en formato tabular.
- **NumPy**: Soporte para cálculos matemáticos y operaciones con matrices.
- **scikit-learn**: Proporciona algoritmos de machine learning como regresión, clustering, árboles de decisión, etc.
- **statsmodels**: Modelos estadísticos avanzados como regresiones y análisis de series temporales.
- **Prophet**: Herramienta de Meta para análisis y predicción de datos con tendencias y estacionalidad.
- **NLTK**: Procesamiento de lenguaje natural, útil para analizar contenido y keywords.
- **spaCy**: Procesamiento avanzado de texto, ideal para análisis semántico en SEO.
- **Gensim**: Para análisis de temas y semántica latente en textos (LDA, Word2Vec).

- **XGBoost** y **LightGBM**: Algoritmos de boosting para mejorar predicciones en SEO.
- **TensorFlow** y **PyTorch**: Frameworks para implementar modelos de deep learning avanzados.

3. Visualización

- **matplotlib**: Librería base para crear gráficos.
- **seaborn**: Extensión de **matplotlib** para visualizaciones estadísticas más avanzadas.
- **Plotly**: Genera gráficos interactivos y dinámicos.
- **Dash**: Plataforma para construir dashboards interactivos basados en Python.
- **Altair**: Librería declarativa para gráficos rápidos y personalizables.

4. Automatización y SEO técnico

- **robotparser**: Analiza archivos robots.txt.
- **openpyxl**: Manipula archivos Excel, ideal para reportes SEO.
- **xml.etree.ElementTree**: Procesa y analiza archivos XML, como sitemaps.
- **whois**: Proporciona información sobre dominios.
- **APScheduler**: Automatiza tareas programadas en SEO.

b) Power BI:

1. Integración de datos

Power BI permite conectar múltiples fuentes de datos para centralizar la información clave de SEO, como:

- **Google Analytics y Google Search Console**: A través de conectores nativos o APIs, facilita la integración de métricas como tráfico orgánico, CTR, impresiones y rankings.
- **Bases de datos**: Conexión a MySQL, PostgreSQL o bases de datos en la nube (Azure, AWS) para importar datos históricos de tráfico, conversiones y palabras clave.
- **APIs de terceros**: Herramientas como Ahrefs, SEMrush o Moz pueden conectarse mediante APIs personalizadas para importar métricas avanzadas como backlinks, autoridad de dominio y dificultad de palabras clave.

- **Fuentes adicionales:** Excel, Google Sheets, sitemaps XML o archivos CSV para agregar datos externos manualmente.

2. Dashboards interactivos

Power BI permite crear dashboards dinámicos y visualmente atractivos que facilitan el análisis y la toma de decisiones. Algunos ejemplos específicos para SEO incluyen:

- **Análisis de tráfico orgánico:** Visualizaciones del crecimiento del tráfico, comparación por segmentos (móvil vs. desktop), y análisis por países o regiones.
- **Rendimiento de palabras clave:** Dashboards que muestran CTR, posición promedio y volumen de búsqueda, segmentados por intención de búsqueda (informativa, navegacional, transaccional).
- **Tendencias y estacionalidades:** Análisis de tendencias de búsqueda para identificar oportunidades basadas en estacionalidades (Black Friday, verano, campañas locales).
- **Mapas de calor:** Visualización de clics y comportamiento del usuario en diferentes secciones del sitio web.

3. Análisis avanzado y en tiempo real

- **Datos en tiempo real:** Conexión con fuentes que ofrecen datos actualizados al instante, como Google Analytics 4, para monitorear el tráfico en vivo y tomar decisiones rápidas ante caídas de tráfico inesperadas.
- **Modelos predictivos:** Al integrar Power BI con Python o R, es posible desarrollar modelos de predicción para anticipar cambios en el tráfico, el rendimiento de palabras clave o el impacto de nuevas estrategias SEO.
- **Segmentación y filtros personalizados:** Power BI permite aplicar filtros avanzados para analizar datos específicos, como tráfico orgánico en dispositivos móviles o el rendimiento de URLs concretas.

4. Automatización de reportes

- **Actualización automática:** Power BI permite programar actualizaciones automáticas de los datos para mantener los dashboards actualizados sin intervención manual.

- **Exportación y compartición:** Los reportes pueden compartirse fácilmente con equipos internos o clientes, manteniendo una comunicación clara y profesional.

c) SQL:

- **Gestión de datos:** SQL es esencial para estructurar y consultar grandes volúmenes de datos.
- **Optimización:** Con SQL, se pueden realizar análisis complejos, como segmentación por palabras clave y detección de tendencias.
- **Conexión con herramientas:** Bases de datos en SQL se integran fácilmente con Python y Power BI, creando un flujo de trabajo continuo.

4. Ejemplo de métodos de predicción centrado en el posicionamiento SEO

El SEO predictivo no solo se basa en modelos teóricos y análisis matemáticos, sino que su verdadero impacto se demuestra a través de aplicaciones prácticas. A continuación, se presentan casos prácticos detallados que ilustran cómo las técnicas predictivas pueden transformar estrategias de SEO, aumentar el tráfico web y optimizar recursos.

4.1. Modelos predictivos basados en clustering y análisis de cohortes

Los métodos de clustering y análisis de cohortes permiten segmentar datos para comprender mejor los patrones de comportamiento del usuario en entornos digitales. En SEO, estas técnicas ayudan a identificar tendencias y optimizar estrategias de contenido y conversión.

4.1.1. Clustering

El clustering, una técnica de aprendizaje no supervisado, se utiliza para agrupar datos con propiedades similares. En el ámbito del SEO, esta metodología permite:

1. **Agrupación de palabras clave por intención de búsqueda:**

- Un análisis de clustering puede separar keywords en grupos de informativas, navegacionales y transaccionales.
 - Esto ayuda a priorizar la creación de contenido específico para cada intención.
- 2. Segmentación de usuarios según patrones de comportamiento:**
- Se pueden identificar grupos de usuarios según su interacción con el sitio web (frecuencia de visitas, duración de la sesión, páginas vistas).
 - Esto permite personalizar estrategias de remarketing y mejorar la tasa de conversión.
- 3. Detección de anomalías en rankings y tráfico:**
- El clustering ayuda a identificar fluctuaciones atípicas en los rankings de búsqueda, permitiendo actuar de forma proactiva ante posibles penalizaciones o actualizaciones de algoritmos.

A continuación mostraremos un ejemplo utilizando K-Means Clustering para clasificar keywords en grupos similares basándonos en volumen de búsqueda, dificultad, CPC y CTR. Para ello será necesario:

1. Importar las librerías básicas (`pandas`, `numpy`, `sklearn`, `matplotlib`, `seaborn`).
2. Cargar los datos desde un CSV, Google Search Console o una API de SEO.
3. Revisar valores nulos y eliminar o completar datos faltantes.

```
import pandas as pd

# Cargar dataset (ejemplo con datos simulados)

df = pd.DataFrame({

    "Keyword": ["comprar zapatillas", "mejores zapatillas
running", "precio zapatillas nike",

                "zapatillas adidas rebajas", "zapatillas para
trail"],

    "Search Volume": [15000, 8000, 12000, 6000, 7000],

    "Keyword Difficulty": [80, 65, 75, 50, 55],
```

```
"CPC": [1.2, 0.8, 1.5, 0.9, 1.0],  
"CTR": [0.12, 0.15, 0.10, 0.18, 0.14]  
})  
  
df.head()
```

Luego, deberás evitar que una variable domine sobre otras en el clustering, seleccionar las métricas numéricas y usar `StandardScaler()` para normalizar los valores.

```
from sklearn.preprocessing import StandardScaler  
  
# Selección de métricas clave  
X = df[["Search Volume", "Keyword Difficulty", "CPC", "CTR"]]  
  
# Normalizar los datos  
scaler = StandardScaler()  
  
X_scaled = scaler.fit_transform(X)
```

Lo siguiente es determinar cuántos grupos (**k**) usar en el clustering y por ejemplo:

1. Probar diferentes valores de **k** (de 1 a 10).
2. Medir la "inercia" o WCSS (Within-Cluster Sum of Squares).
3. Identificar el **punto de inflexión** en la gráfica del "codo".

```
import matplotlib.pyplot as plt  
  
from sklearn.cluster import KMeans  
  
# Verificar que hay suficientes datos para K-Means
```

```
if len(X_scaled) < 2:

    raise ValueError("No hay suficientes datos para aplicar
    K-Means. Se necesitan al menos 2 muestras.")

# Determinar el rango adecuado de k

max_clusters = min(6, len(X_scaled)) # Máximo de clusters
permitidos

wcss = []

# Aplicar K-Means para diferentes valores de k

for i in range(1, max_clusters + 1):

    kmeans = KMeans(n_clusters=i, init="k-means++",
    random_state=42, n_init=10)

    kmeans.fit(X_scaled)

    wcss.append(kmeans.inertia_)


# Graficar el método del codo

plt.figure(figsize=(8, 5))

plt.plot(range(1, max_clusters + 1), wcss, marker="o",
linestyle="--")

plt.xlabel("Número de clusters (k)")

plt.ylabel("WCSS (Within-Cluster Sum of Squares)")

plt.title("Método del Codo para encontrar k óptimo")

plt.grid(True)

plt.show()
```

Seguidamente agruparemos las palabras clave en segmentos optimizados y aquí se deberá aplicar `KMeans(n_clusters=3)` y añadir la etiqueta de cluster a cada palabra clave.

```
# Aplicar K-Means con k=3

kmeans = KMeans(n_clusters=3, init="k-means++",
random_state=42)

df["Cluster"] = kmeans.fit_predict(X_scaled)

# Ver los clusters asignados

df[["Keyword", "Cluster"]]
```

Y el último paso será representar gráficamente los grupos de palabras clave, aplicar **PCA** para reducir dimensiones (porque tenemos 4 variables) y crear un **scatterplot** con los clusters.

```
import seaborn as sns

from sklearn.decomposition import PCA

# Reducir dimensiones con PCA

pca = PCA(n_components=2)

X_pca = pca.fit_transform(X_scaled)

# Crear DataFrame con las componentes principales

df_pca = pd.DataFrame(X_pca, columns=["PCA1", "PCA2"])

df_pca["Cluster"] = df["Cluster"]

# Graficar clusters

plt.figure(figsize=(8, 5))
```

```
sns.scatterplot(x="PCA1", y="PCA2", hue="Cluster",  
data=df_pca, palette="Set1", s=100)  
  
plt.title("Clusters de Palabras Clave")  
  
plt.xlabel("PCA1")  
  
plt.ylabel("PCA2")  
  
plt.show()
```




Imagen 7 | Clusters de palabras clave en SEO para residencias universitarias. Representación visual de la segmentación de palabras clave utilizando K-Means Clustering y reducción de dimensiones con PCA. Los clusters se basan en métricas de volumen de búsqueda, dificultad SEO, CPC y competencia en Ads. Fuente: Elaboración propia, 2025.

● **Cluster 0:** Palabras clave con alta competencia y CPC elevado, difíciles de posicionar pero con alto potencial de conversión.

● **Cluster 1:** Keywords equilibradas, con buen volumen y dificultad moderada, recomendadas para estrategias de contenido SEO.

● **Cluster 2:** Keywords de baja competencia y CPC bajo, ideales para posicionamiento rápido con menor esfuerzo SEO.

Y si reducimos la lista de keywords a 5 palabras por cluster para simplificar el resultado serían:

Palabra clave	Dificultad	Vol. de búsqueda	CPC (€)	Competencia	Cluster
universitarios en madrid	47	90	0.00	0.00	0
residencia de estudiantes madrid	50	2900	0.30	0.31	0
residencias estudiantes madrid	35	1500	0.29	0.52	0
residencias madrid estudiantes	37	2400	0.29	0.52	0
residencias de estudiantes	34	3600	0.28	0.13	0
residencia barata	28	880	0.32	0.35	1
residencia universitaria barata	33	720	0.28	0.25	1
residencia económica	22	390	0.25	0.20	1
residencia de estudiantes barata	30	1300	0.31	0.18	1
residencia para universitarios económica	25	500	0.27	0.22	1
alojamiento para estudiantes en madrid	55	2500	0.40	0.50	2
alquiler habitaciones estudiantes madrid	60	3100	0.45	0.55	2
alquiler piso estudiantes	48	2000	0.38	0.48	2
habitaciones para estudiantes en madrid	53	2700	0.41	0.52	2
piso compartido estudiantes	51	3500	0.42	0.49	2

Tabla 1 | Segmentación de palabras clave en SEO mediante Clustering con datos reales centrado en residencias universitarias. Fuente: Elaboración propia, 2025.

4.1.2. Análisis de cohortes

El análisis de cohortes es una técnica analítica utilizada para segmentar a los usuarios en grupos según su fecha de primera interacción y estudiar su comportamiento en el tiempo. En SEO, se emplea para evaluar la retención de usuarios, la eficacia de distintos canales de adquisición y la conversión de tráfico orgánico en leads o ventas al estudiar cómo los usuarios que llegan a una página específica regresan o interactúan con otras secciones de la web en un período determinado. De esta forma podremos:

1. Medir la fidelización de usuarios

- Si los visitantes regresan en las semanas siguientes, significa que el contenido genera valor y engagement.
- Una baja tasa de retorno indica que el contenido no logra captar el interés de los usuarios.

2. Evaluar la eficacia del contenido

- Comparar la retención de diferentes páginas permite identificar cuáles generan mayor interacción a largo plazo.
- Se pueden realizar ajustes en la estructura del contenido o mejorar la experiencia de usuario para aumentar la recurrencia.

3. Optimización de estrategias de retención

- Implementar llamadas a la acción, enlaces internos estratégicos y estrategias de email marketing para atraer a los usuarios recurrentes.

A continuación, se presenta un ejemplo utilizando un análisis de cohortes para medir la retención de usuarios a lo largo del tiempo. Para ello, será necesario:

1. Importar las librerías necesarias (**pandas**, **numpy**, **seaborn**, **matplotlib**).
2. Cargar los datos desde Google Analytics o un archivo con información sobre sesiones de usuarios.
3. Procesar los datos para construir la matriz de cohortes.

```
import pandas as pd
```

```
import numpy as np
```

```
# Simulación de datos de cohortes en SEO
```

```
cohort_data = {  
    "Cohorte": ["Enero", "Febrero", "Marzo", "Abril",  
    "Mayo"],  
    "Mes 0": [1000, 1200, 1100, 1300, 1250],  
    "Mes 1": [800, 900, 850, 950, 920],  
    "Mes 2": [600, 700, 680, 750, 730],  
    "Mes 3": [400, 500, 490, 550, 530],  
    "Mes 4": [250, 350, 340, 400, 380],  
}  
  
df_cohorte = pd.DataFrame(cohort_data)  
  
df_cohorte.head()
```

Luego, se calculará la tasa de retención de usuarios dividiendo el número de usuarios que regresan cada mes entre el número total de usuarios iniciales en el Mes 0.

```
# Calcular tasas de retención (%)  
  
df_cohorte_retencion = df_cohorte.copy()  
  
for col in df_cohorte.columns[1:]:  
    df_cohorte_retencion[col] = df_cohorte[col] /  
    df_cohorte["Mes 0"] * 100
```

Para representar visualmente los resultados, se generará una matriz de cohortes mediante un mapa de calor, lo que permitirá identificar tendencias en la retención de usuarios.

```
import seaborn as sns
```

```
import matplotlib.pyplot as plt

# Crear un mapa de calor con la retención de cohortes

plt.figure(figsize=(10, 6))

sns.heatmap(df_cohorte_retencion.set_index("Cohorte").iloc[:, 1:], annot=True, fmt=".1f", cmap="Blues")

plt.title("Matriz de Cohortes: Retención de Usuarios en SEO (%)")

plt.xlabel("Meses desde la primera visita")

plt.ylabel("Cohorte de Adquisición")

plt.show()
```

Posteriormente se realizará una comparativa del rendimiento de los usuarios según el canal por el cual llegaron a la web, como tráfico orgánico (SEO), redes sociales, tráfico de pago o tráfico directo para:

1. Evaluar el rendimiento de tráfico orgánico en comparación con otros canales

- Permite identificar si los usuarios provenientes de Google tienen mayor retención que aquellos que llegan desde redes sociales o campañas pagadas.
- Si el tráfico orgánico tiene menor retención, es necesario optimizar la experiencia de usuario en las páginas de destino.

2. Medición de la calidad del tráfico SEO

- Un alto porcentaje de retención en usuarios de tráfico orgánico indica que las páginas están alineadas con la intención de búsqueda.
- Si los usuarios de SEO abandonan rápidamente el sitio, puede ser necesario mejorar la calidad del contenido o la navegación.

A continuación, se presenta el ejemplo de análisis de cohortes por canal de adquisición, donde se estudia la retención de usuarios en los primeros tres meses después de su llegada al sitio.

```
# Simulación de retención por canal de adquisición

data_canal = {

    "Canal": ["SEO", "Redes Sociales", "Tráfico
Directo"],

    "Mes 0": [5000, 3000, 4000],

    "Mes 1": [4000, 1800, 2500],

    "Mes 2": [3000, 1200, 1800],

    "Mes 3": [2000, 800, 1200],

}

df_canal = pd.DataFrame(data_canal)

# Calcular tasas de retención por canal

for col in df_canal.columns[1:]:

    df_canal[col] = df_canal[col] / df_canal["Mes 0"] *
100

# Crear mapa de calor para visualizar la retención por
canal

plt.figure(figsize=(8, 5))

sns.heatmap(df_canal.set_index("Canal").iloc[:, 1:],
annot=True, fmt=".1f", cmap="Greens")

plt.title("Retención de Usuarios por Canal de Adquisición
(%)")

plt.xlabel("Meses desde la primera visita")

plt.ylabel("Canal de Adquisición")

plt.show()
```

También, el análisis de cohortes permite evaluar cómo los usuarios que entraron en un sitio web a través de una consulta de búsqueda específica terminan convirtiéndose en clientes en un período determinado para:

1. Optimización de estrategias de conversión

- Permite identificar qué tipos de consultas llevan a una conversión más rápida.
- Ayuda a ajustar el contenido y la arquitectura del sitio para maximizar la conversión.

2. Asignación eficiente de recursos SEO

- Al detectar qué cohortes generan más conversiones, es posible priorizar esfuerzos en mejorar el posicionamiento de esas palabras clave.

A continuación, se presenta un ejemplo de análisis de cohortes de conversión, donde se evalúa el porcentaje de usuarios que completaron una conversión en los meses posteriores a su primera visita.

```
# Simulación de conversión de cohortes SEO

data_conversion = {

    "Cohorte": ["Enero", "Febrero", "Marzo", "Abril",
               "Mayo"],

    "Mes 0": [500, 600, 550, 650, 700],

    "Mes 1": [100, 120, 110, 130, 140],

    "Mes 2": [80, 90, 85, 100, 105],

    "Mes 3": [60, 70, 65, 75, 80],

}

df_conversion = pd.DataFrame(data_conversion)

# Calcular tasas de conversión

for col in df_conversion.columns[1:]:
```

```

df_conversion[col] = df_conversion[col] /
df_conversion["Mes 0"] * 100

# Crear mapa de calor para visualizar la conversión de
cohortes

plt.figure(figsize=(8, 5))

sns.heatmap(df_conversion.set_index("Cohorte").iloc[:,
1:], annot=True, fmt=".1f", cmap="Oranges")

plt.title("Conversión de Usuarios por Cohorte (%)")

plt.xlabel("Meses desde la primera visita")

plt.ylabel("Cohorte de Adquisición")

plt.show()

```

Este análisis permite comprender cómo evoluciona la conversión a lo largo del tiempo y ayuda a tomar decisiones informadas en la optimización de estrategias SEO y de contenido.




Imagen | 8 Matriz de cohortes de retención de usuarios en SEO durante 2024. La gráfica representa el porcentaje de usuarios que regresan en los meses posteriores a su primera visita, agrupados según el mes de adquisición. Se observa una disminución progresiva en la retención después del primer mes, aunque con una leve mejora en las cohortes de la segunda mitad del año. Este patrón podría reflejar optimizaciones recientes en la experiencia de usuario y estrategias de contenido orientadas a aumentar el engagement y la fidelización. (Fuente: Elaboración propia, 2024).

4.2. Estimaciones de ROI y tráfico web

El retorno de inversión (ROI) y el tráfico web son métricas fundamentales en SEO. Los modelos de series temporales como **ARIMA** y las redes neuronales recurrentes como **LSTM** se utilizan para estimar estas métricas con alta precisión, permitiendo una planificación más estratégica.

4.2.1. Modelos ARIMA para tráfico web

El modelo **ARIMA (AutoRegressive Integrated Moving Average)** es una técnica estadística utilizada para analizar y predecir datos de series temporales [18]. Es especialmente útil para predecir volúmenes de tráfico web a partir de datos históricos. Por ejemplo se puede utilizar para:

1. Anticipación de picos de tráfico

- Un modelo ARIMA puede identificar patrones estacionales en el tráfico web, como aumentos durante campañas promocionales o eventos importantes.
- Esto permite ajustar la infraestructura del sitio para manejar el tráfico esperado, evitando caídas en el rendimiento.

2. Optimización de campañas de marketing

- Prever picos de tráfico ayuda a planificar campañas de marketing digital en momentos clave para maximizar el impacto.

Pasos para implementar un modelo ARIMA en Python:

1. Importar las librerías necesarias para trabajar con datos de series temporales, como `pandas`, `statsmodels` y `matplotlib`.
2. Cargar y analizar los datos históricos de tráfico web.
3. Ajustar el modelo ARIMA seleccionando los parámetros (p, d, q) adecuados.
4. Generar predicciones y visualizar los resultados.

```
# Importar librerías necesarias

import pandas as pd

import matplotlib.pyplot as plt

from statsmodels.tsa.arima.model import ARIMA

from pmdarima import auto_arima # Para seleccionar
automáticamente los mejores parámetros

# Cargar datos históricos de tráfico web

data = {

    "Fecha": pd.date_range(start="2023-01-01", periods=12,
freq="M"),

    "Tráfico_web": [15000, 16000, 15500, 18000, 19000, 18500,
20000, 21000, 19500, 22000, 22500, 23000]

}

df = pd.DataFrame(data).set_index("Fecha") # Establecer la
fecha como índice

# Seleccionar automáticamente los mejores valores (p, d, q)

auto_model = auto_arima(df["Tráfico_web"], seasonal=False,
trace=True, suppress_warnings=True)

# Crear y ajustar el modelo ARIMA con los parámetros óptimos

model = ARIMA(df["Tráfico_web"], order=auto_model.order)

model_fit = model.fit()

# Generar predicciones para los próximos 6 meses

forecast_index = pd.date_range(start=df.index[-1], periods=7,
freq="M")[1:] # Fechas futuras

forecast = model_fit.forecast(steps=6)
```

```
# Visualizar predicciones
```

```
plt.figure(figsize=(10, 6))
```

```
plt.plot(df.index, df["Tráfico_web"], label="Tráfico  
histórico", marker='o')
```

```
plt.plot(forecast_index, forecast, label="Predicción",  
linestyle="dashed", marker='o')
```

```
plt.xlabel("Fecha")
```

```
plt.ylabel("Tráfico Web")
```

```
plt.title("Predicción de tráfico web con ARIMA")
```

```
plt.legend()
```

```
plt.show()
```




Imagen 9 | Predicción de tráfico web con ARIMA. Gráfica que muestra la predicción de tráfico web con un modelo ARIMA. La línea continua representa los datos históricos y la línea discontinua muestra las predicciones para los próximos seis meses. Fuente: Elaboración propia, 2025.

4.2.2. LSTM para predicción de ROI

Las redes neuronales **LSTM (Long Short-Term Memory)** son un tipo de red neuronal recurrente (RNN) diseñada para manejar secuencias de datos temporales. Son ideales para predecir ROI y analizar interacciones complejas entre múltiples canales de marketing [8]. Con ello se podrá realizar:

1. **Predicción de fluctuaciones en ROI**

- LSTM puede analizar datos de campañas anteriores y predecir cómo los cambios en el contenido o en las estrategias SEO impactarán en las conversiones.

2. **Análisis de interacciones entre canales de marketing**

- Permite evaluar cómo la combinación de SEO, campañas de pago y redes sociales contribuyen al ROI general.

Pasos para implementar un modelo LSTM en Python con Keras:

1. Importar las librerías necesarias, como `numpy`, `pandas`, y `tensorflow.keras`.
2. Preprocesar los datos, normalizándolos y dividiéndolos en secuencias para el entrenamiento.
3. Construir y entrenar un modelo LSTM para predecir ROI.
4. Evaluar el modelo y visualizar los resultados.

try:

```
import tensorflow as tf

from tensorflow.keras.models import Sequential

from tensorflow.keras.layers import LSTM, Dense, Dropout

from sklearn.preprocessing import MinMaxScaler

import numpy as np

import pandas as pd

    print("TensorFlow está instalado. El modelo LSTM puede
ejecutarse.")

except ImportError:
```

```
print("TensorFlow no está instalado. Por favor, instálalo  
usando 'pip install tensorflow'.")  
  
# Simulación de datos para ROI  
  
data = {  
    "Fecha": pd.date_range(start="2023-01-01", periods=24,  
freq="M"),  
    "ROI": [1.2, 1.3, 1.25, 1.5, 1.7, 1.65, 1.8, 1.85, 2.0,  
2.1, 2.2, 2.3,  
2.35, 2.4, 2.5, 2.6, 2.7, 2.8, 2.85, 2.9, 3.0,  
3.1, 3.2, 3.25]  
}  
  
df = pd.DataFrame(data).set_index("Fecha")  
  
# Escalar los datos  
  
scaler = MinMaxScaler()  
  
scaled_data = scaler.fit_transform(df)  
  
# Crear secuencias para LSTM  
  
sequence_length = 5  
  
X, y = [], []  
  
for i in range(len(scaled_data) - sequence_length):  
    X.append(scaled_data[i:i + sequence_length])  
    y.append(scaled_data[i + sequence_length])  
  
X, y = np.array(X), np.array(y)  
  
# Construcción del modelo LSTM  
  
model = Sequential([
```

```
LSTM(50, activation='relu', return_sequences=True,
input_shape=(X.shape[1], 1)),

Dropout(0.2),

LSTM(50, return_sequences=False),

Dense(25),

Dense(1)

])

# Compilación y entrenamiento

model.compile(optimizer='adam', loss='mean_squared_error')

model.fit(X, y, epochs=50, batch_size=8, verbose=1)

# Predicción

predicciones = model.predict(X[-5:])
```




Imagen 10 | Gráfica que compara los datos históricos de ROI con las predicciones generadas por un modelo LSTM. La línea azul representa los datos históricos, y la línea roja muestra las predicciones futuras. Fuente: Elaboración propia, 2025.

4.3. Predicción de clics en Google Search Console

Para este estudio, los datos provienen de **Google Search Console (GSC)**, una herramienta de Google que proporciona información detallada sobre el rendimiento de búsqueda de un sitio web.

Las métricas clave utilizadas son:

- **Clics:** Número de veces que los usuarios hicieron clic en un resultado de búsqueda.
- **Impresiones:** Número de veces que un enlace apareció en los resultados de búsqueda.
- **CTR (Click-Through Rate):** Relación entre clics e impresiones.
- **Posición media:** Ubicación promedio en los resultados de búsqueda.

Antes de aplicar cualquier modelo predictivo, es esencial limpiar y estructurar los datos. Seguimos estos pasos:

1. **Generar datos simulados:** Creamos una serie temporal con **365 días** de datos de clics e impresiones.
2. **Visualizar la serie temporal:** Observamos si existen tendencias o patrones estacionales.
3. **Dividir los datos:** Separar en **entrenamiento (80%)** y **prueba (20%)**.
4. **Verificar estacionariedad:** Si es necesario, aplicamos transformaciones como diferenciación para estabilizar la varianza.

Usaremos un **modelo ARIMA (AutoRegressive Integrated Moving Average)**, ampliamente utilizado en análisis de series temporales debido a su capacidad para modelar datos con patrones estacionales y tendencias.

El modelo se compone de tres parámetros:

- **p (AutoRegresión):** Número de observaciones pasadas utilizadas.
- **d (Diferenciación):** Veces que se diferencian los datos para hacer la serie estacionaria.
- **q (Media Móvil):** Tamaño de la ventana de suavizado.

4.3.1. Desarrollo en Python

Generación y visualización de datos

Generamos datos sintéticos para simular los clics en Search Console y analizamos su distribución.

```
import pandas as pd

import numpy as np

import matplotlib.pyplot as plt

import seaborn as sns

# Simulación de datos de Search Console

np.random.seed(42)

dates = pd.date_range(start="2024-01-01", periods=365,
freq="D")

clicks = np.abs(np.random.normal(loc=500, scale=100,
size=len(dates))).astype(int)

impressions = clicks * np.random.uniform(5, 10,
size=len(dates))

# Crear DataFrame

df = pd.DataFrame({"date": dates, "clicks": clicks,
"impressions": impressions})

df.set_index("date", inplace=True)

# Visualizar datos

plt.figure(figsize=(12,6))

plt.plot(df.index, df["clicks"], label="Clics diarios",
color="blue")

plt.xlabel("Fecha")

plt.ylabel("Clics")

plt.title("Evolución de los Clics en Google Search Console")

plt.legend()
```

```
plt.show()
```

4.3.2. División de Datos

Dividimos los datos en **conjunto de entrenamiento (80%)** y **conjunto de prueba (20%)** para evaluar el modelo.

```
# Dividir en datos de entrenamiento y prueba
train_size = int(len(df) * 0.8)

train, test = df[:train_size], df[train_size:]
```

4.3.3. Aplicación del Modelo ARIMA

Prueba de Estacionariedad

Para usar ARIMA, necesitamos comprobar si la serie es **estacionaria** (su media y varianza no cambian con el tiempo). Aplicamos la **prueba de Dickey-Fuller aumentada (ADF)**.

```
from statsmodels.tsa.stattools import adfuller

# Prueba de Dickey-Fuller

adf_test = adfuller(train["clicks"])

print(f"Estadístico ADF: {adf_test[0]}")

print(f"Valor p: {adf_test[1]}")
```

**Si $p < 0.05$, la serie es estacionaria. Si no, aplicamos diferenciación.*

Entrenamiento del Modelo ARIMA

Entrenamos el modelo ARIMA con parámetros óptimos.

```
from statsmodels.tsa.arima.model import ARIMA

# Entrenar modelo ARIMA

model_clicks = ARIMA(train["clicks"], order=(5,1,0)) # p=5,
d=1, q=0

model_fit_clicks = model_clicks.fit()
```

Predicción de Clics y Evaluación del Modelo

Realizamos predicciones y evaluamos su precisión con **error absoluto medio (MAE)** y **raíz del error cuadrático medio (RMSE)**.

```
from sklearn.metrics import mean_absolute_error,
mean_squared_error

# Hacer predicciones

predictions_clicks =
model_fit_clicks.forecast(steps=len(test))

# Evaluación del modelo

mae_clicks = mean_absolute_error(test["clicks"],
predictions_clicks)

rmse_clicks = mean_squared_error(test["clicks"],
predictions_clicks, squared=False)

# Mostrar métricas de error

print(f"MAE: {mae_clicks:.2f}, RMSE: {rmse_clicks:.2f}")
```

Resultados obtenidos:

- **MAE:** 65.37
- **RMSE:** 79.75
- El modelo predice los clics con un error de aproximadamente **65 clics diarios**, lo que es útil para la planificación estratégica.

4.3.4. Visualización de Predicciones

Graficamos los resultados para comparar las predicciones con los valores reales.

```
plt.figure(figsize=(12,6))

plt.plot(train.index, train["clicks"], label="Entrenamiento",
color="blue")

plt.plot(test.index, test["clicks"], label="Real",
color="green")

plt.plot(test.index, predictions_clicks, label="Predicción",
color="red", linestyle="dashed")

plt.xlabel("Fecha")

plt.ylabel("Clics")

plt.title("Predicción de Clics en Google Search Console con
ARIMA")

plt.legend()

plt.show()
```




Imagen 11 | Predicción de clics en Google Search Console hasta enero de 2025. Esta gráfica muestra la evolución de los clics diarios (línea azul) y las predicciones generadas por un modelo ARIMA (línea roja discontinua). Los datos reales en el periodo de prueba (línea verde) permiten evaluar la precisión del modelo, que se basa en tendencias históricas y fluctuaciones del tráfico orgánico. (Fuente: Elaboración propia con modelo ARIMA aplicado a datos simulados de Search Console).

4.4. Predicción de CTR y rankings con datos combinados

La integración de datos de múltiples fuentes, como **Google Search Console (GSC)** y **herramientas de SEO (SE Ranking, Semrush, Ahrefs, etc)**, puede mejorar significativamente las decisiones estratégicas en SEO. En este caso, utilizamos estas herramientas para identificar palabras clave con mayor potencial de crecimiento, basándonos en métricas como clics, impresiones, CTR, dificultad y volumen de búsqueda.

El objetivo es combinar estas métricas para crear un modelo que evalúe y priorice palabras clave según su capacidad de generar tráfico orgánico y mejorar posiciones en los rankings.

4.4.1. Preparación de los datos

Limpieza y combinación de métricas

Primero, fusionamos los datos de GSC y SE Ranking, seleccionando las columnas clave y eliminando las palabras clave relacionadas con "smart residences".

```
# Filtrar y combinar datos
```

```
combined_df = pd.merge(
    gsc_filtered,
    se_ranking_filtered,
    left_on="Consultas principales",
    right_on="Palabra clave",
    how="inner"
)

# Convertir métricas para el modelo

combined_df["CTR"] = combined_df["CTR"].str.replace("%",
    "").astype(float) / 100

combined_df["Dificultad"] =
combined_df["Dificultad"].astype(float)

combined_df["Competencia"] =
combined_df["Competencia"].astype(float)

combined_df["Vol. de búsqueda"] = combined_df["Vol. de
búsqueda"].astype(float)

combined_df["Impresiones"] =
combined_df["Impresiones"].astype(float)
```

4.4.2. Entrenamiento del modelo

Predicción del CTR

Usamos un modelo de **Random Forest** para predecir el CTR esperado de cada palabra clave, basándonos en métricas como impresiones, dificultad y competencia.

```
from sklearn.model_selection import train_test_split

from sklearn.ensemble import RandomForestRegressor

# Variables predictoras y objetivo

features_ctr = combined_df[["Impresiones", "Dificultad",
"Competencia", "Vol. de búsqueda"]]

target_ctr = combined_df["CTR"]

# Dividir los datos en entrenamiento y prueba

X_train_ctr, X_test_ctr, y_train_ctr, y_test_ctr =
train_test_split(features_ctr, target_ctr, test_size=0.2,
random_state=42)

# Entrenar el modelo

model_ctr = RandomForestRegressor(n_estimators=100,
random_state=42)

model_ctr.fit(X_train_ctr, y_train_ctr)

# Predecir el CTR

combined_df["CTR_predicho"] = model_ctr.predict(features_ctr)
```

Predicción de posición en el ranking

De manera similar, entrenamos otro modelo para predecir la posición futura en el ranking de cada palabra clave.

```
# Variables predictoras y objetivo

features_ranking = combined_df[["CTR", "Dificultad",
"Competencia", "Vol. de búsqueda"]]

target_ranking = combined_df["Posición"]

# Dividir los datos
```

```

X_train_rank, X_test_rank, y_train_rank, y_test_rank =
train_test_split(features_ranking, target_ranking,
test_size=0.2, random_state=42)

# Entrenar el modelo

model_rank = RandomForestRegressor(n_estimators=100,
random_state=42)

model_rank.fit(X_train_rank, y_train_rank)

# Predecir posiciones

combined_df["Posición_predicha"] =
model_rank.predict(features_ranking)

```

4.4.3. Análisis de resultados

Palabras clave con potencial de crecimiento

Identificamos palabras clave con:

- **CTR bajo actual, pero alto CTR predicho.**
- **Posición actual distante de los primeros puestos, pero con alta posición predicha.**

```

# Seleccionar palabras clave con potencial

potential_keywords = combined_df[

    (combined_df["CTR"] < 0.1) & (combined_df["CTR_predicho"]
> 0.3) &

    (combined_df["Posición"] > 5) &
(combined_df["Posición_predicha"] <= 3)

]

# Ordenar por posición predicha

```

```
potential_keywords =  
potential_keywords.sort_values(by="Posición_predicha")  
  
import ace_tools as tools  
  
tools.display_dataframe_to_user(name="Predicción de CTR y  
Posiciones Futuras", dataframe=potential_keywords)
```

4.4.4. Visualización

Gráfica de predicción de posiciones

Creamos un gráfico que muestre las palabras clave con el mayor potencial de ranking en los primeros puestos.

```
import matplotlib.pyplot as plt  
  
# Gráfico de posiciones predichas  
  
plt.figure(figsize=(12, 6))  
  
plt.barh(potential_keywords["Consultas principales"],  
potential_keywords["Posición_predicha"], color="skyblue")  
  
plt.xlabel("Posición Predicha")  
  
plt.ylabel("Palabra Clave")  
  
plt.title("Predicción de Posiciones Futuras en el Ranking")  
  
plt.gca().invert_yaxis()  
  
plt.show()
```

4.4.5. Resultado

El análisis, basado en miles de palabras clave extraídas de los documentos de **Google Search Console** y **SE Ranking**, ha sido simplificado en **5 términos clave** con el mayor **potencial de crecimiento en clics**.

Consultas principales	Clics	Impresiones	CTR	Dificultad	Competencia	Vol. de búsqueda	CTR predicho	Posición actual	Posición predicha	Potencial de clics
residencias universitarias pamplona	44	2971	0.014	4	0.46	10	0.0379	7.52	8.85	112.77
pisos compartidos estudiantes pamplona	16	1234	0.012	12	0.34	50	0.0421	6.45	5.73	51.96
alojamiento estudiantes barato pamplona	10	875	0.011	15	0.25	30	0.0407	8.22	6.91	35.60
alquiler habitaciones estudiantes pamplona	7	645	0.010	18	0.40	20	0.0365	9.01	7.24	23.53
residencia universitaria cerca de la UNAV	3	415	0.007	8	0.20	15	0.0332	10.20	9.03	13.77

Tabla 2 | Predicción de CTR y posiciones futuras en el ranking en el nicho educativo y de alojamientos para estudiantes. La tabla muestra los 5 términos clave con mayor potencial de clics, seleccionados a partir de un análisis predictivo basado en palabras clave extraídas de Google Search Console y herramientas SEO. Se presentan las métricas actuales de cada término junto con las predicciones de CTR y posición futura, destacando oportunidades de crecimiento en tráfico orgánico mediante optimización SEO en el sector educativo y de alojamientos para estudiantes. (Fuente: Elaboración propia con datos de Google Search Console y herramientas SEO, 2025).

4.5. Otras Posibilidades en SEO predictivo con Python

El SEO predictivo sigue evolucionando con el uso de modelos avanzados y nuevas metodologías. A continuación, se presentan algunas aplicaciones adicionales que pueden potenciar el análisis y la optimización del posicionamiento web:

4.5.1. Modelado de impacto de actualizaciones de Google

En lugar de reaccionar a los cambios de algoritmo, se pueden construir modelos de aprendizaje automático que analicen patrones históricos y anticipen fluctuaciones en rankings. Herramientas como **Prophet** y **Random**

Forest pueden predecir posibles afectaciones en función de cambios pasados en Google.

4.5.2. Optimización dinámica del enlazado interno

Mediante algoritmos de **grafos** y **aprendizaje reforzado**, es posible identificar la mejor estructura de enlaces internos basada en la navegación real de los usuarios y las tendencias de búsqueda. Esto optimiza el flujo de autoridad SEO dentro del sitio web.

4.5.3. Análisis semántico avanzado con NLP

Usando **BERT**, **spaCy** o **Gensim**, se pueden identificar nuevas oportunidades de contenido analizando relaciones semánticas entre keywords. Esto permite generar contenido más alineado con la intención de búsqueda real del usuario y mejorar la relevancia en los resultados de búsqueda.

4.5.4. Automatización de estrategias de contenido predictivo

Los modelos de **series temporales** pueden anticipar la demanda de ciertos temas en función de patrones estacionales. Esto permite programar la publicación de contenido en los momentos óptimos para captar más tráfico orgánico sin depender de tendencias ya consolidadas.

4.5.5. Predicción de conversión y ROI en SEO

Integrando datos de tráfico, CTR y conversiones históricas, se pueden construir modelos de predicción que estimen el impacto económico de mejorar ciertas posiciones en los rankings. Esto ayuda a priorizar esfuerzos en palabras clave con mayor potencial de rentabilidad.

4.5.6. Identificación de anomalías en el tráfico web

Usando algoritmos de **detección de anomalías**, como Isolation Forest o DBSCAN, se pueden identificar caídas atípicas en el tráfico que podrían indicar problemas técnicos, penalizaciones o cambios en la intención de búsqueda. Esto permite reaccionar rápidamente ante posibles afectaciones.

4.5.7. Optimización predictiva para búsqueda por voz y asistentes virtuales

Analizando datos de consultas por voz y procesamiento de lenguaje natural (NLP), se pueden detectar patrones en búsquedas conversacionales y

adaptar el contenido para mejorar el posicionamiento en asistentes como Google Assistant y Alexa.

Cada una de estas aplicaciones demuestra el potencial del SEO predictivo y cómo el uso de datos y modelos avanzados puede transformar la toma de decisiones estratégicas en marketing digital.

5. Evaluación de resultados

Dado que los motores de búsqueda operan bajo múltiples variables y algoritmos en constante evolución, es imprescindible contar con mecanismos que permitan evaluar la precisión de las predicciones y su aplicabilidad en la optimización de sitios web. La evaluación no solo debe centrarse en la comparación de valores estimados y reales, sino también en la interpretación de los indicadores clave de rendimiento (KPIs) y en la identificación de limitaciones que puedan afectar la efectividad de los modelos aplicados.

5.1. Comparación entre predicciones y resultados reales

Para determinar la fiabilidad de un modelo predictivo, es necesario contrastar las proyecciones con los datos observados, analizando la magnitud y la distribución de los errores. Este proceso permite ajustar los modelos y mejorar su capacidad de anticipar cambios en las métricas clave del SEO.

Entre las métricas más utilizadas para la evaluación del error se encuentran:

- **Error absoluto medio (Mean Absolute Error, MAE):** mide el promedio de las diferencias absolutas entre los valores predichos y los reales, proporcionando una visión general de la desviación en unidades comparables.
- **Raíz del error cuadrático medio (Root Mean Squared Error, RMSE):** enfatiza los errores más grandes al elevarlos al cuadrado, resultando útil en casos donde es crítico minimizar desviaciones atípicas.
- **Error porcentual medio absoluto (Mean Absolute Percentage Error, MAPE):** permite comparar errores en términos relativos, expresándose como un porcentaje del valor real, lo que facilita su interpretación en diferentes contextos.

El análisis de errores no debe limitarse a métricas numéricas, sino complementarse con representaciones gráficas que faciliten la detección de patrones y anomalías. Comparar la evolución temporal de los valores reales y predichos mediante gráficos de líneas o dispersión puede proporcionar información adicional sobre la estabilidad y precisión de los modelos utilizados.

5.2. Indicadores clave de rendimiento (KPIs) en SEO predictivo

La evaluación del desempeño de un modelo no se basa únicamente en su precisión matemática, sino en su impacto en la optimización y el tráfico orgánico. Por ello, es necesario analizar KPIs que reflejen mejoras en la visibilidad, el engagement del usuario y la conversión.

- **Evolución del tráfico orgánico:** el crecimiento en visitas provenientes de buscadores debe correlacionarse con las predicciones realizadas y verificarse en función de las palabras clave optimizadas.
- **Cambio en la posición de las palabras clave:** evaluar si las mejoras en contenido y estructura del sitio han generado un ascenso en el ranking de búsqueda.
- **Click through rate (CTR):** el incremento en la tasa de clics es un indicador de la efectividad de las optimizaciones en snippets, títulos y metadescripciones.
- **Tasa de conversión:** el SEO predictivo no solo debe centrarse en atraer tráfico, sino en convertir visitas en acciones concretas, como registros o compras.
- **Retención y engagement del usuario:** métricas como la tasa de rebote y el tiempo en página ayudan a evaluar si las predicciones han contribuido a mejorar la experiencia del usuario.

La combinación de estos indicadores proporciona una visión integral del impacto de los modelos predictivos y su aplicación en estrategias de optimización.

5.3. Discusión sobre desafíos y limitaciones

A pesar de su potencial, la aplicación de técnicas predictivas en SEO enfrenta varios desafíos que pueden influir en su efectividad.

- **Calidad y disponibilidad de datos:** la precisión de cualquier modelo depende de la integridad y representatividad de los datos utilizados. Información incompleta o sesgada puede generar predicciones poco fiables.
- **Evolución de los algoritmos de búsqueda:** los cambios constantes en los motores de búsqueda pueden alterar significativamente las reglas del posicionamiento, haciendo que modelos entrenados con datos históricos pierdan vigencia.
- **Requerimientos técnicos y computacionales:** la implementación de modelos avanzados, como redes neuronales o técnicas de series temporales, requiere conocimientos especializados y capacidad de procesamiento adecuada.
- **Necesidad de actualización continua:** los modelos predictivos deben ajustarse periódicamente para reflejar cambios en tendencias de búsqueda, comportamiento del usuario y nuevas prácticas de optimización.
- **Limitaciones en la interpretación de modelos complejos:** técnicas como deep learning pueden generar predicciones precisas, pero su interpretabilidad puede ser un reto, dificultando la toma de decisiones estratégicas basadas en estos resultados.

Conclusiones

Sin duda alguna, el SEO predictivo es una disciplina que ha venido para quedarse con una constante evolución que combina datos, modelos estadísticos y herramientas avanzadas que ayudan a predecir tendencias de búsqueda, anticipar el interés de los usuarios, predecir tráfico orgánico, como posiciones, entre otras disciplinas del posicionamiento en internet.

Este enfoque no solo mejora el rendimiento orgánico, sino que también permite a los expertos de SEO mantenerse competitivos en un entorno digital tan cambiante.

Sin embargo, su implementación requiere una combinación de conocimiento técnico, herramientas avanzadas y un compromiso ético para alcanzar el éxito.

A medida que la tecnología evolucione, las oportunidades para mejorar y escalar las estrategias de SEO predictivo seguirán creciendo, posicionando a las empresas en la vanguardia del marketing digital. Tecnologías como GPT-, Gemini, DeepSeek, Perplexity, Copilot, etc., basadas en modelos de inteligencia artificial avanzados, han cambiado la forma en que los algoritmos de búsqueda procesan y entienden el contenido [19].

Nota: Texto del documento mejorado con la asistencia de ChatGPT (OpenAI, 2025) [20]

Referencias

- [1] Sánchez Mosquete, J. (2025). *Análisis predictivo en SEO*. Blog. <https://agenciaseonetbulb.com/noticias/analisis-predictivo-seo/>
- [2] Google Trends. (n.d.). *Interés a lo largo del tiempo para la palabra clave "mascarillas"*. <https://trends.google.com>
- [3] Google Search Central. (2023, febrero 8). *Google Search's guidance about AI-generated content*. Google Developers. <https://developers.google.com/search/blog/2023/02/google-search-and-ai-content>
- [4] Google Search Central. (2023, mayo 10). *Introducing INP: A new metric for responsiveness*. <https://developers.google.com/search/blog/2023/05/introducing-inp>
- [5] Google Search Status Dashboard. (n.d.). *Resumen de actualizaciones de los algoritmos de Google en 2024*. <https://status.search.google.com>
- [6] Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... & Zheng, X. (2016). *TensorFlow: Large-scale machine learning on heterogeneous systems*. <https://www.tensorflow.org>
- [7] Brownlee, J. (2017). *Machine Learning Mastery with Python: Understand Your Data, Create Accurate Models, and Work Projects End-to-End*. Machine Learning Mastery. ISBN 979-8540446273
- [8] Chollet, F. (2015). *Keras: Deep Learning library for Theano and TensorFlow*. <https://keras.io>
- [9] SE Ranking. (n.d.). *API documentation*. Recuperado el 6 de febrero de 2025. <https://seranking.com/api.html>
- [10] Google Analytics API. (n.d.). *Métricas sobre el comportamiento del usuario en sitios web*. <https://developers.google.com/analytics>
- [11] Google Search Console API. (n.d.). *Datos de palabras clave, CTR y posiciones en los resultados de búsqueda*. <https://developers.google.com/webmaster-tools>

- [12] Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... & Oliphant, T. E. (2020). *Array programming with NumPy*. *Nature*, 585(7825), 357-362. <https://doi.org/10.1038/s41586-020-2649-2>
- [13] Hunter, J. D. (2007). *Matplotlib: A 2D graphics environment*. *Computing in Science & Engineering*, 9(3), 90-95. <https://doi.org/10.1109/MCSE.2007.55>
- [14] McKinney, W. (2010). *Data Structures for Statistical Computing in Python*. *Proceedings of the 9th Python in Science Conference*, 51-56. <https://proceedings.scipy.org/articles/Majora-92bf1922-00a>
- [15] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, E. (2011). *Scikit-learn: Machine learning in Python*. *Journal of Machine Learning Research*, 12, 2825-2830. <https://jmlr.org/papers/v12/pedregosa11a.html>
- [16] Python Software Foundation. (2025). *Python programming language*. <https://www.python.org>
- [17] Seabold, S., & Perktold, J. (2010). *Statsmodels: Econometric and statistical modeling with Python*. *Proceedings of the 9th Python in Science Conference*, 92-96. <https://proceedings.scipy.org/articles/Majora-92bf1922-011>
- [18] Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice (3.ª ed.)*. OTexts. <https://otexts.com/fpp3/>
- [19] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). *Attention is all you need*. *Advances in Neural Information Processing Systems*, 30. <https://arxiv.org/abs/1706.03762>
- [20] OpenAI. (2025). *ChatGPT (Versión 4.0)* [Modelo de lenguaje grande]. <https://chat.openai.com/chat>

