

## Anexo I. Registro del Título del Trabajo Fin de Grado (TFG)

NOMBRE DEL ALUMNO: Claudia García García

PROGRAMA: 5ºE6-Analytics GRUPO: 5ºE6-Analytics

FECHA: 24/10/2025

Director Asignado: Tena Blázquez, Antonio  
Apellidos Nombre

### Título provisional del TFG:

Modelado de respuesta y optimización presupuestaria en campañas de Social Media Ads con un enfoque data-driven

**ADJUNTAR PROPUESTA (máximo 4 páginas: Índice provisional, objetivos, metodología y bibliografía)**

Firma del estudiante:



Fecha: 24/10/2025

## **Índice de contenidos**

1. Resumen/Abstract
2. Introducción
  1. Relevancia del tema
  2. Objetivos del estudio
  3. Metodología y estructura del trabajo
3. Marco teórico y revisión bibliográfica
  1. Evolución de la inversión en medios digitales y social ads
  2. Fundamentos de marketing mix y elasticidades publicitarias
  3. Dinámicas de respuesta publicitaria: persistencia, saturación y efectos cruzados
  4. Optimización de presupuesto y técnicas robustas
4. Descripción y preparación de los datos
  1. Descripción del dataset
  2. Limpieza y creación de variables
  3. Análisis exploratorio
5. Metodología analítica
  1. Modelos de respuesta publicitaria
  2. Formulación y resolución del modelo de optimización
6. Evaluación y sensibilidad
  1. Validación del modelo
  2. Análisis de sensibilidad y escenarios
  3. Comparación de resultados
7. Dashboard PowerBI
8. Recomendaciones y limitaciones del estudio
9. Conclusiones
10. Referencias bibliográficas
11. Anexos

## **Breve descripción del tema seleccionado**

El presente Trabajo de Fin de Grado se centra en el desarrollo de un marco data-driven para la optimización del presupuesto en campañas de Social Media Ads, mediante un enfoque analítico y basado en datos (data-driven). La relevancia del tema radica en la transformación digital que ha experimentado el ecosistema publicitario global, obligando a las empresas a fundamentar sus decisiones de inversiones en métricas objetivas que reflejen la eficacia y el retorno de cada canal. Este estudio busca aportar un método cuantitativo que permita asignar de forma óptima el presupuesto de forma eficiente y basado en evidencias.

Para ello, se hace uso de un dataset público que recoge información de campañas de anuncios en redes sociales durante el año 2022, con aproximadamente 300.000 registros y 16 variables relacionadas con el rendimiento de las acciones publicitarias. A partir de estos datos brutos, se construyen indicadores clave de desempeño (Key Performance Indicators), entre los que destacan, CTR (Click Through Rate), CPC (Cost Per Click), CPA (Cost Per Acquisition) y ratios de retorno como ROI y ROAS (Return on Investment / Return on Ad Spend). Estos indicadores permiten evaluar de manera objetiva la eficacia de cada campaña publicitaria y constituyen la base para crear un modelo de asignación óptima del presupuesto. Además, para asegurar la solidez del modelo se someterá a un proceso de validación temporal a lo largo del mismo periodo analizado, con el fin de contrastar el desempeño predictivo del modelo cuando cambian las condiciones de las campañas. Finalmente, el resultado será plasmado en un dashboard interactivo en PowerBI que permita explorar asignaciones óptimas bajo diferentes escenarios.

## **Objetivo general**

Diseñar un método analítico para la asignación óptima del presupuesto en campañas de Social Ads mediante modelos de respuesta y elasticidades, complementando con un dashboard ejecutivo en una herramienta de visualización de datos para integrar resultados analíticos con decisiones operativas de inversión.

## **Objetivos específicos**

- Construir, limpiar y validar métricas clave de desempeño (KPIs) y segmentarlas según ciertas características como canal, audiencia o geografía.
- Estimar curvas de respuesta y elasticidades incluyendo posibles interacciones de canales.

- Diseño y comparación de modelos de optimización presupuestario considerando incertidumbre en los parámetros o coeficientes fijos.
- Validar y evaluar el rendimiento del modelo con análisis de sensibilidad.
- Desarrollar un dashboard interactivo con PowerBI que permita la visualización de KPIs y como cambian las asignaciones óptimas bajo distintos escenarios.
- Documentar el proceso analítico completos, incluyendo scripts y fórmulas, así como exploraciones futuras.

## **Metodología**

La metodología de este trabajo se fundamenta en un enfoque multidisciplinario que combina una primera parte de investigación de la literatura académica y profesional, un análisis de tendencias recientes del mercado digital y social media, y el desarrollo de una propuesta analítica específica basada en los resultados obtenidos. El objetivo principal es desarrollar un marco conceptual y empírico robusto que sirva de base para entender como varia el rendimiento de la inversión publicitaria y diseñar un sistema que optimice la asignación de presupuesto en campañas de Social Media Ads.

El dataset empleado recoge campañas publicitarias durante el año 2022, por lo que ese año marca el punto de referencia del análisis empírico. Por lo tanto, es coherente hacer una revisión del estado del mercado en los años posteriores (2023-2025), ya que contextualizan el análisis dentro de la evolución más reciente y proyectada el entorno digital. Esta revisión abarca informes de referencia como Global Ad Spend Outlook de WARC, en el que se proyecta el gasto global en publicidad con una cifra de casi el billón de dólares en 2024, con un crecimiento estimado del 10.7%. Asimismo, el informe AdEx Benchmark de IAB Europe es útil para mostrar como Europa no es ajena a las tendencias globales u otros como los estudios de GroupM. Con estos datos se permite tener un contexto empírico que justifica la relevancia del estudio.

Posteriormente, se desarrolla un bloque teórico centrado en Marketing Mix Modeling, (MMM) utilizada para cuantificar el impacto de las variables de marketing sobre un resultado de negocio. Este constituye la base metodológica para cuantificar la relación ente inversión y resultados en marketing, estimando parámetros como la elasticidad publicitaria y rendimientos decrecientes del gasto. Asimismo, será necesario el desarrollo de distintas aproximaciones de optimización, como la optimización lineal en caso de que la relación entre inversión y

resultados sea proporcional. Sin embargo, el objetivo no es solo maximizar los resultados esperados, sino garantizar soluciones estables ante posibles variaciones en los datos en el entorno de mercado.

La revisión bibliográfica también incluirá el análisis de estudios recientes y casos aplicados de optimización en marketing digital que describen la evolución de herramientas de inteligencia artificial para planificación de medios y prácticas emergentes de optimización en tiempo real. Como por ejemplo el proyecto Robyn, un proyecto oficial de Meta, que representa la aplicación práctica más actual del MMM en entornos digitales.

Basándose en los conocimientos adquiridos a través de la revisión bibliográfica y del estudio de casos, el trabajo desarrolla una propuesta analítica que comienza con la construcción y depuración de un dataset público obtenido de la página web con múltiples dataset de libre acceso conocida como Kaggle. Continúa con la generación de métricas, modelado de respuesta y finaliza con la visualización de resultados en dashboard interactivo.

### **Bibliografía**

jsonk11. (2024). *Social Media Advertising Dataset Dataset* Kaggle. <https://www.kaggle.com/datasets/jsonk11/social-media-advertising-dataset>

Sedlářová Nehézová, L., Bureš, V., & Otčenášek, J. (2025). *A robust optimization approach to budget optimization in online marketing campaigns*. *Central European Journal of Operations Research*. Springer. <https://doi.org/10.1007/s10100-025-00984-x>

Yahia, M. B., Aoun, D., & Cheikhrouhou, N. (2025). *A stochastic nonlinear programming model for budget mix optimization of digital marketing campaigns under uncertainty*. *Future Business Journal*, 11(1), Article 6. <https://doi.org/10.1186/s43093-025-00664-x>

Luzón, M. D. (2022). *Dynamic budget allocation for social media advertising*. *European Journal of Operational Research*, 304(2), 834–847. <https://doi.org/10.1016/j.ejor.2021.07.012>

Gong, Y., Wang, H., Lin, Y., & Zhang, R. (2024). *CausalMMM: Learning causal structure for marketing mix modeling*. *arXiv preprint*. <https://arxiv.org/abs/2406.16728>

Srinivasan, V., Pauwels, K., & Hanssens, D. M. (2022). *Using marketing mix elasticities to demonstrate consumer and marketing-mix interactions. International Journal of Research in Marketing*, 39(4), 818–832.  
<https://doi.org/10.1016/j.ijresmar.2022.07.004>