

Aplicación del método few shot learning al modelo GPT3.5 para la personalización del contenido de las redes sociales

Brigitte Melody MÉNDEZ PASTOR
Universidad Peruana de Ciencias Aplicadas
Lima, Perú

Carolina Milagros VILLEGAS CELIS
Universidad Peruana de Ciencias Aplicadas
Lima, Perú

Alfredo BARRIENTOS PADILLA
Universidad Peruana de Ciencias Aplicadas
Lima, Perú

RESUMEN: Este paper presenta un enfoque KDD (Knowledge Discovery in Databases) para desarrollar una aplicación web que utiliza la técnica "few shot learning" con el modelo GPT-3.5 para generar contenido personalizado y de alta calidad para redes sociales de negocios. Los datos se recopilan mediante una interfaz de registro y archivos Excel con copias existentes y métricas de interacción. Se aplican técnicas de preprocesamiento y transformación de datos para mejorar la capacidad de generalización del modelo. La evaluación se realiza usando métricas de similitud, gramaticalidad y relevancia del contenido generado. Los resultados muestran altos puntajes de precisión (0.7177) y recall (0.6890), lo que indica una similitud significativa entre los copias generados y los existentes, además de un puntaje gramatical casi perfecto. La validación humana revela que los usuarios están mayormente satisfechos con el contenido, según encuestas realizadas. Estos resultados destacan la efectividad de la propuesta en la generación automatizada de contenido para redes sociales de negocios, ahorrando tiempo y esfuerzo a los especialistas en marketing y mejorando la calidad y coherencia del contenido generado.

Palabras Claves: aprendizaje de pocos ejemplos, copywriting, gpt, negocios, openai, personalización.

Applying few shot learning to GPT3.5 model for social media content personalization

ABSTRACT: This paper presents an approach based on KDD (Knowledge Discovery in Databases) for the development of a web application using the knowledge transfer technique "few shot learning" to the GPT3.5 model. The objective is to generate personalized and high-quality content for business social networks. Data is collected through a logging interface and Excel files containing existing copies and social network interaction metrics. Data preprocessing and transformation techniques are applied to improve the generalizability of the model. The evaluation is performed using metrics of similarity, grammaticality, and relevance of the generated content. The results show high scores for precision (0.7177) and recall (0.6890), indicating a substantial similarity between the generated copies and the existing ones. In addition, a grammatical score close to perfection is achieved. Regarding

human validation, the results show that users are mostly satisfied with the generated content, which is validated through a survey after the use of the application. These results demonstrate the effectiveness of the proposal in the automated generation of personalized content for business social networks, which can save time and effort for marketers, while improving the quality and consistency of the generated content.

Keywords: *businesses, copywriting, few shot learning, gpt, openai, personalization.*

1. INTRODUCCIÓN

El uso de modelos de inteligencia artificial para la creación de contenido en redes sociales se ha vuelto una necesidad dentro de las empresas, ya que muchos especialistas que se enfocan en el marketing digital buscan formas de agilizar estos procesos de creación de contenido publicitario. Debido a ello, muchas empresas optan por utilizar servicios que ofrecen acceso a modelos como GPT3.5 [6], aunque esto puede ser útil para la generación automatizada de contenido para las redes sociales, no siempre es una solución completa para todas las necesidades debido a la falta de personalización, lo cual vuelve necesaria la intervención humana para garantizar que el contenido sea relevante, coherente y se ajuste a los objetivos de la propuesta de marketing de la empresa [6].

En base al problema presentado, el objetivo de este paper es proporcionar una aplicación web que permita a los negocios crear contenido personalizado para sus redes sociales, esto se logrará aplicando una técnica de transferencia de conocimiento al modelo GPT3.5, se contará con las restricciones de no requerir grandes cantidades de datos y que el tiempo de entrenamiento sea corto.

La dificultad de este problema radica en que es complicado entrenar o personalizar un modelo como GPT para generar publicaciones en redes sociales debido a la falta de datos, ya que esto afecta la precisión de sus resultados. Los autores en el artículo [7] mencionan que "una de las razones por las cuales es difícil lograr una alta precisión en la clasificación de riesgos en publicaciones de redes sociales se debe al tamaño pequeño del conjunto de datos".

Existen algunas soluciones similares a la que proponemos, por

ejemplo, en el artículo [5], los autores se enfocan en contenido para la optimización de motores de búsqueda (SEO), pero no toman en cuenta la identidad de la marca, en vez de ello utilizan palabras clave relevantes. En cambio, nuestro enfoque va en generar contenido para redes sociales y priorizar los datos de negocio como identidad de marca, publico objetivo entre otros para la personalización del contenido.

El componente clave de nuestra investigación es aplicar una técnica de transferencia de conocimiento el modelo GPT3.5 para generar contenido personalizado y de alta calidad para las redes sociales de los negocios.

Nuestra contribución es implementar una aplicación web para generar contenido personalizado para redes sociales de negocios mediante la aplicación de transferencia de conocimiento al modelo GPT3.5.

2. TRABAJOS RELACIONADOS

El artículo [5], los autores proponen que a través de la identificación de palabras clave relevantes, la creación de plantillas de contenido y la generación automática de contenido específico para cada palabra clave se logre la creación de contenido para la optimización de motores de búsqueda (SEO), esto lo logran a través de un método de generación de contenido semiautomático para desarrollar contenido SEO mediante la combinación del ajuste fino al modelo GPT-2 y un editor humano para refinar el contenido.

El artículo [6] Los autores proponen utilizar el modelo GPT para generar texto empresarial artificial. El objetivo es mejorar la eficiencia y calidad del proceso de escritura de textos empresariales. Los investigadores entrenaron el modelo en una gran cantidad de datos 355 millones de parámetros y entrenado durante tres meses en dispositivos con GPU y 2.300 millones de tokens de texto, lo ajustaron para que genere contenido relevante y coherente en función del contexto empresarial. La propuesta se basa en la idea de que los modelos LLM pueden ser una herramienta útil para mejorar la productividad y eficiencia en el ámbito empresarial.

En el artículo [8] los autores proponen un sistema de inteligencia artificial para generar tweets populares, el sistema utiliza una combinación de técnicas estadísticas avanzadas, análisis econométrico y procesamiento del lenguaje natural para analizar los datos existentes sobre tweets populares y generar nuevos tweets que tengan una alta probabilidad de ser populares.

En el artículo [9] Los autores proponen el modelo Variational Latent-State GPT (VLS-GPT) para mejorar la capacidad de los sistemas de diálogo orientados a tareas (TOD) semi-supervisados. Este modelo combina técnicas de ajuste fino y entrenamiento variacional para mejorar la comprensión y respuesta del sistema TOD a las solicitudes y preguntas de los usuarios. El modelo VLS-GPT puede ayudar al usuario a generar contenido relevante y sugerencias para una tarea específica, como, por ejemplo, si el usuario necesita ayuda para escribir un artículo o una presentación como parte de una tarea más amplia.

En el artículo [10] Los autores proponen un sistema llamado CTGAN que genera contenido de texto diverso y variable en longitud con etiquetas emocionales personalizables. Se enfoca en generar contenido creativo mediante una estrategia

automatizada de reemplazo a nivel de palabra para garantizar la calidad y diversidad del texto generado.

3. APLICACIÓN WEB PARA LA GENERACIÓN DE CONTENIDO

En esta sección, se presentan los conceptos principales utilizados en nuestro trabajo y se describen en detalle nuestras contribuciones

Conceptos preliminares

En esta sección, presentamos los conceptos clave que se utilizan en nuestro trabajo.

Definición 1 (Large language model) [4] Los modelos de lenguaje grande (LLM) se refieren a modelos de lenguaje de Transformer que contienen cientos de miles de millones (o más) de parámetros, que se entrenan en datos de texto masivos, como GPT3.5, PaLM Galactica, y LLaMA. Los LLM exhiben fuertes capacidades para comprender el lenguaje natural y resolver tareas complejas (a través de la generación de texto). Para comprender rápidamente cómo funcionan los LLM, esta parte presenta los antecedentes básicos de los LLM, incluidas las leyes de escala, las habilidades emergentes y las técnicas clave.

Definición 2 (Transfer learning) [3] Transferir el aprendizaje a un modelo de lenguaje grande preentrenado implica utilizar el conocimiento adquirido por un modelo preexistente, como GPT3.5, para mejorar el rendimiento de un nuevo modelo para una tarea o dominio diferente. En lugar de entrenar un nuevo modelo desde cero, el aprendizaje por transferencia implica tomar un modelo preexistente que ha sido entrenado en un gran conjunto de datos y ajustarlo para una tarea o dominio específico utilizando un conjunto de datos más pequeño. Al aprovechar el conocimiento y las representaciones aprendidas por el modelo preexistente, el aprendizaje por transferencia puede reducir significativamente la cantidad de datos etiquetados y los recursos computacionales necesarios para entrenar un nuevo modelo. Este enfoque ha tenido mucho éxito en tareas de procesamiento de lenguaje natural, como la traducción de idiomas, la clasificación de textos y la generación de textos.

Definición 3 (GPT3.5) [2] Es un modelo de lenguaje autorregresivo que presenta alrededor de 175 mil millones de parámetros entrenables, es capaz de generar respuestas no deterministas cada vez que se ejecuta, lo que introduce flexibilidad en la generación de texto y su transformación.

Definición 4 (Copy) [11] Se refiere a la redacción o contenido escrito utilizado en publicidad y marketing para promocionar productos, servicios o marcas, con el objetivo de persuadir al público objetivo.

Método

La principal contribución de esta investigación es el desarrollo de una aplicación web que utiliza la técnica de transferencia de conocimiento al modelo GPT3.5 para generar contenido personalizado y de calidad para las redes sociales de negocios, basándose en publicaciones previas de esos negocios.

Para guiar y estructurar el proceso de desarrollo de la aplicación, utilizamos la metodología KDD (Knowledge Discovery in Databases). Esta metodología consta de varias fases que nos ayudan a extraer información valiosa a partir de los datos disponibles.

Selección de datos: Se identifican los datos relevantes necesarios para la generación de contenido personalizado, los cuales incluyen la siguiente información sobre el negocio: nombre del negocio, público objetivo, servicios ofrecidos, ubicación, número de teléfono, sitio web, correo electrónico y el contenido textual de las publicaciones y de los flyers existentes en las redes sociales [11].

Preprocesamiento de datos: El proceso de recolección de datos se lleva a cabo de la siguiente manera: Los datos del negocio se recopilan a través de una interfaz de registro del negocio en la aplicación web y el contenido de las publicaciones en redes sociales se obtiene a través de un archivo de Excel cargado por el especialista en marketing. El archivo de Excel contiene las siguientes columnas:

- Nombre del negocio: Este campo almacena el nombre del negocio para el cual se generó la copia.
- Copy: Aquí se registra el contenido generado por los especialistas en marketing para las publicaciones en redes sociales de cada negocio, y se compone exclusivamente de texto.
- Cantidad de "Me gusta": Esta columna registra el número de veces que cada publicación ha recibido "Me gusta" en las redes sociales, lo que da una medida del nivel de aceptación y respuesta de los seguidores del negocio.
- Cantidad de veces compartidas: En esta columna se registra la cantidad de veces que los seguidores han compartido cada publicación en las redes sociales, lo cual nos ayuda a evaluar la viabilidad y alcance del contenido generado.

Todos los datos recopilados se almacenan en la base de datos de la aplicación web.

Transformación de datos: La técnica de transferencia de conocimiento que se usa es el aprendizaje de pocos ejemplos (few shot learning), debido a su capacidad para lograr resultados satisfactorios con una cantidad reducida de datos de entrenamiento y demostrar mejores puntuaciones de F1 y precisión respecto a otras técnicas [10].

Para aplicar tal técnica los datos de los copys se transforman en un conjunto de pares de contexto y tarea (FIGURA 1). Esta transformación permite que el modelo aprenda y generalice a partir de un número reducido de ejemplos, mejorando su capacidad para generar contenido personalizado para los negocios.

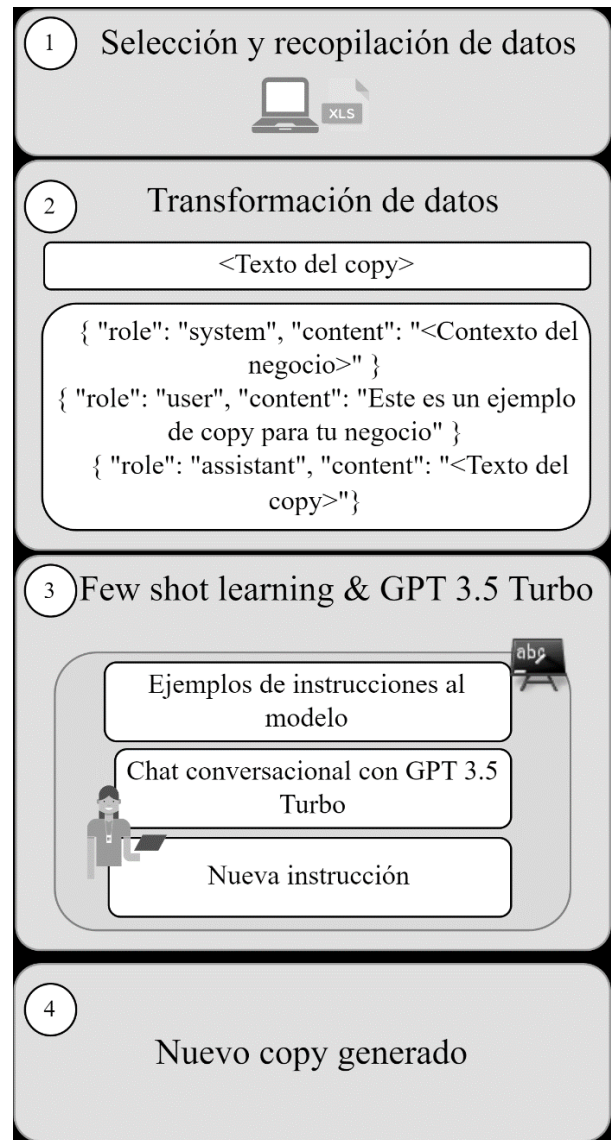


FIGURA 1

Minería de datos: Esta fase del proceso no fue aplicada.

Evaluación de patrones: Se aplica la técnica de few-shot learning al modelo GPT3.5 utilizando los datos existentes del negocio para generar nuevos copys. Para cada post, se recopila información relevante como la ocasión, el lenguaje, las palabras clave y la creatividad (parámetro temperatura para

GPT3.5 [12]), a través de una plantilla definida en la aplicación web. Se considera que, con un contexto bien definido, GPT3.5 es capaz de generar nuevos copias. Nuestra solución incluye una conversación multiturno para lograr una interacción fluida con el especialista de marketing. Esto se logra a través del uso de la variante del modelo GPT3.5, el cual es GPT3.5 turbo que es el modelo especializado en conversaciones.

Para evaluar la calidad de los copias generados, utilizamos métricas de similitud como F1, recall y precisión [10]. Además, verificamos la gramática y ortografía para asegurar su efectividad. También evaluamos la satisfacción del especialista en marketing a través de una encuesta que presenta variadas preguntas respecto a la calidad del copy que son evaluados a través de la escala de Likert.

A continuación, un detalle de cada una de las métricas y los resultados en cada una de ellas al hacer pruebas de concepto:

Precisión: Se refiere a la proporción de palabras del texto candidato (generado por el modelo) que están presentes en el texto de referencia. En este caso, realizando pruebas de concepto, se alcanzó un valor de 0.7177.

Recall: Mide la proporción de palabras del texto de referencia que están presentes en el texto candidato. En este caso, se obtuvo un valor de 0.6890.

F1 Score: Es una medida que combina la precisión y el recall en un solo indicador de la calidad del texto. En este caso, se obtuvo un valor de 0.7030.

Puntaje gramatical: Indica un alto nivel de gramaticalidad en el texto generado, en este caso se obtuvo un puntaje de 0.99.

Estas métricas nos permiten evaluar la calidad y la adecuación de los copias generados en base a los criterios establecidos.

Interpretación y análisis: Se analizan los resultados obtenidos en la generación de copias personalizados utilizando la técnica de few-shot learning con el modelo GPT3.5 y se realiza una evaluación exhaustiva de su calidad y adecuación. Para ello, se emplean diversas métricas y se tiene en cuenta la satisfacción del especialista en marketing.

En primer lugar, se evalúa la similitud entre los textos generados por el modelo y los textos de referencia mediante métricas como precisión, recall y F1 Score. En términos de precisión, se obtuvo un puntaje de 0.717, lo que indica que aproximadamente el 72% de las palabras en el texto candidato coinciden con las del texto de referencia. En cuanto al recall, se logró un puntaje de 0.6890, lo que significa que aproximadamente el 69% de las palabras en el texto de referencia están presentes en el texto candidato. Un valor alto de recall indica que el modelo ha capturado de manera adecuada las palabras clave y la información relevante del texto de referencia. Por otro lado, el F1 Score obtuvo un valor de 0.7030, lo que señala una buena similitud general entre el texto candidato y el texto de referencia.

Además de las métricas de similitud, se realiza una verificación

de la gramática y ortografía del texto generado para garantizar su efectividad y legibilidad. Se asigna un puntaje gramatical en una escala del 0 al 1, y en este caso, se obtuvo un puntaje de 0.99, lo cual indica un nivel muy alto de gramaticalidad en el texto.

Con relación a la validación realizada con cinco especialistas en marketing, se muestran los resultados en la siguiente tabla:

- 1) ¿Estás satisfecho con la calidad de las copias generadas por Smart Content en función de tus necesidades específicas?
- 2) ¿Las copias generadas por Smart Content son altamente relevantes y personalizadas para las necesidades de tu negocio?
- 3) ¿Las copias generadas por Smart Content se ajusten al tono y estilo de tu marca?
- 4) ¿Las copias generadas por Smart Content son efectivas para atraer la atención de tu audiencia objetivo?
- 5) ¿La aplicación Smart Content demuestra una comprensión precisa de las instrucciones proporcionadas y genera copias que mantienen una alta coherencia con el contexto establecido?
- 6) ¿La aplicación genera copias de alta calidad de manera consistente, sin necesidad de correcciones significativas por parte del usuario?

TABLA 1. Tabla de preguntas y porcentajes obtenidos de la encuesta.

Nº	Totalmente en desacuerdo	En desacuerdo	Ni en acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
1	0%	0%	20%	0%	80%
2	0%	0%	0%	40%	60%
3	0%	0%	0%	40%	60%
4	0%	0%	20%	40%	40%
5	0%	0%	0%	20%	80%
6	0%	0%	20%	40%	40%

Presentación de resultados: El proyecto se enfocó en la generación de contenido personalizado utilizando la técnica de few-shot learning y el modelo GPT3.5. Se seleccionaron datos relevantes, se llevaron a cabo procesos de preprocesamiento y transformación de datos, y se aplicó la técnica para generar nuevos copias. Los resultados fueron evaluados mediante métricas de similitud, gramaticalidad y validación humana por parte de cinco especialistas que ocupan cargos relacionados al marketing dentro de las empresas donde laboran. Los resultados mostraron altos niveles de similitud entre los textos generados y los textos de referencia, una gramaticalidad destacada y en su mayoría una satisfacción resaltable por parte de los especialistas en marketing en cuanto a la calidad del copy.

4. CONCLUSIONES

En este estudio, se ha presentado un enfoque innovador basado en la metodología KDD (Knowledge Discovery in Databases) y la transferencia de conocimiento al modelo GPT3.5 para abordar el desafío de la generación automatizada de contenido personalizado en redes sociales de negocios. La aplicación web desarrollada ha demostrado su eficacia al generar contenido de alta calidad, optimizando tanto la eficiencia como la coherencia del contenido generado.

Al aplicar técnicas de preprocesamiento y transformación de datos, se ha mejorado la capacidad de generalización del modelo, lo que ha llevado a resultados sobresalientes en términos de similitud, gramaticalidad y relevancia del contenido generado. Estas métricas validan la efectividad de nuestra propuesta y su capacidad para generar copias que se asemejan sustancialmente a las existentes.

Los resultados obtenidos en las pruebas de concepto han demostrado una precisión de 0.7177 y un recall de 0.6890, lo que respalda aún más la viabilidad y efectividad de nuestra solución propuesta. Asimismo, en la validación humana, la mayoría de respuestas a las preguntas se encuentran entre satisfechos y muy satisfechos. Estos resultados indican que nuestro enfoque puede ser utilizado de manera confiable por especialistas en marketing en la generación automatizada de contenido personalizado para redes sociales de negocios.

Este enfoque tiene un gran potencial para ahorrar tiempo y esfuerzo a los profesionales del marketing, permitiéndoles centrarse en otras tareas estratégicas mientras se genera contenido de calidad para las redes sociales. Además, la capacidad de personalización proporcionada por nuestra solución mejora la conexión entre las marcas y sus audiencias, lo que puede conducir a un mayor compromiso y satisfacción del cliente.

5. REFERENCIAS

- [1] Killalea, T. (2016). The Hidden Dividends of Microservices. *Queue*, 14(3). <https://doi.org/10.1145/2956641.2956643>
- [2] Saravanan, S., & Sudha, K. (2022). GPT3.5 Powered System for Content Generation and Transformation. *Proceedings - 2022 5th International Conference on Computational Intelligence and Communication Technologies, CCICT 2022*, 514–519. <https://doi.org/10.1109/CCICT56684.2022.00096>
- [3] Vrbaničič, G., & Podgorelec, V. (2020). Transfer learning with adaptive fine-tuning. *IEEE Access*, 8, 196197–196211. <https://doi.org/10.1109/ACCESS.2020.3034343>
- [4] Zhao, W. X., Zhou, K., Li, et. al. (2023). A Survey of Large Language Models. <https://arxiv.org/pdf/2303.18223.pdf>
- [5] Reisenbichler, M., Reutterer, T., Schweidel, D. A., & Dan, D. (2022). Frontiers: Supporting Content Marketing with Natural Language Generation. *Marketing Science*, 41(3), 441–452. <https://doi.org/10.1287/MKSC.2022.1354>
- [6] Khalil, F., & Pipa, G. (2022). Transforming the generative pretrained transformer into augmented business text writer. *Volume 9, Issue 1, Article Number 112*. <https://doi.org/10.1186/s40537-022-00663-7>
- [7] Howard, D., Maslej, M. M., Lee, J., Ritchie, J., Woollard, G., & French, L. (2020). Transfer Learning for Risk Classification of Social Media Posts: Model Evaluation Study. *Journal of Medical Internet Research*, 22(5), e15371. <https://doi.org/10.2196/15371>

- [8] Garvey, M. D., Samuel, J., & Pelaez, A. (2021). Would you please like my tweet?! An artificially intelligent, generative probabilistic, and econometric based system design for popularity-driven tweet content generation. *Decision Support Systems*, 144. <https://doi.org/10.1016/J.DSS.2021.113497>
- [9] H. Liu, Y. Cai, Z. Lin, Z. Ou, Y. Huang and J. Feng, "Variational Latent-State GPT for Semi-Supervised Task-Oriented Dialog Systems," in *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, vol. 31, pp. 970–984, 2023, doi: 10.1109/TASLP.2023.3240661.
- [10] GPT3.5: Brown, T. B., Mann, B., et. al. (2020). Language Models are Few-Shot Learners. *ArXiv:2005.14165 [Cs]*. <http://arxiv.org/abs/2005.14165>
- [11] Affonso, F. M., & Janiszewski, C. (2023). Marketing by Design: The Influence of Perceptual Structure on Brand Performance. *Journal of Marketing*, 002224292211422. <https://doi.org/10.1177/00222429221142281>
- [12] OpenAI (2023) Create completion: Request Body. <https://platform.openai.com/docs/api-reference/completions/create>
- [13] Fu, M., & Tantithamthavorn, C. (2023). GPT2SP: A Transformer-Based Agile Story Point Estimation Approach. *IEEE Transactions on Software Engineering*, 49(2), 611–625. <https://doi.org/10.1109/TSE.2022.3158252>