



TLATEMOANI
Revista Académica de Investigación
Editada por Eumed.net
Año 14, no. 44 – Diciembre 2023.
España
ISSN: 1989-9300
revista.tlatemoani@uaslp.mx

IMPACTO DE LOS MODELOS GENERATIVOS DE LENGUAJE DE INTELIGENCIA ARTIFICIAL EN LA EDUCACIÓN SUPERIOR

IMPACT OF ARTIFICIAL INTELLIGENCE GENERATIVE LANGUAGE MODELS ON HIGHER EDUCATION

AUTORES:

RICARDO LARA-COLÓN

Departamento de Ciencias Básicas, Tecnológico Nacional de México Campus Pabellón de Arteaga, Aguascalientes, México
ricardo.lc@pabellon.tecnm.mx

LILIANA CASTAÑÓN-AYALA

Departamento de Ciencias Básicas, Tecnológico Nacional de México Campus Pabellón de Arteaga, Aguascalientes, México
liliana.ca@pabellon.tecnm.mx

PAMELA ROMO-RODRÍGUEZ*

Departamento de Ciencias Básicas, Tecnológico Nacional de México Campus Pabellón de Arteaga, Aguascalientes, México
pamela.rr@pabellon.tecnm.mx

*Autor de correspondencia

RESUMEN

Este artículo analiza el impacto de ChatGPT, un modelo de conversación de IA, y de otros modelos generativos de lenguaje en la educación superior. Revisa evidencia reciente sobre los beneficios de su uso, como mejorar las habilidades de escritura de los estudiantes y generar preguntas de exámenes. La literatura muestra que el uso de estos modelos puede tener beneficios, tales como la mejora de habilidades de escritura y fácil generación de preguntas para exámenes. Sin embargo, también hay desafíos y riesgos asociados con su uso; problemas con la calidad de la información generada, sobrecarga cognitiva y aspectos éticos. La conclusión destaca la necesidad de establecer pautas y realizar más investigación para implementar estos modelos de forma que mejore la educación sin comprometer la agencia humana.

TLATEMOANI, No. 44, diciembre 2023.
<https://www.eumed.net/rev/tlatemoani/index.html>



Palabras Clave: Inteligencia artificial, enseñanza superior, modelos de lenguaje generativos, ChatGPT, investigación en inteligencia artificial en educación.

Abstract

This article analyzes the impact of ChatGPT, an AI conversational model, and other generative language models on higher education. It reviews recent evidence on the benefits of their use, such as improving students' writing skills and generating exam questions. The literature shows that the use of these models can have benefits, such as improving writing skills and easily generating exam questions. However, there are also challenges and risks associated with their use, including issues with the quality of generated information, cognitive overload, and ethical considerations. The conclusion highlights the need to establish guidelines and conduct further research to implement these models in a way that enhances education without compromising human agency.

Keywords: Artificial Intelligence, higher education, generative language models, ChatGPT, artificial intelligence in education research.

INTRODUCCIÓN

La educación superior es un nivel de formación que tiene como objetivo desarrollar las competencias profesionales, científicas y humanísticas de los estudiantes, así como contribuir al desarrollo social, económico y cultural de la sociedad. La educación superior se enfrenta a diversos retos y oportunidades en el contexto actual, como la globalización, la digitalización, la innovación, la diversidad, la calidad, la equidad y la inclusión (UNESCO, 2019).

La inteligencia artificial (IA) es una de las tecnologías que está transformando la educación superior, ofreciendo nuevas posibilidades para mejorar los procesos de enseñanza y aprendizaje, la gestión académica, la investigación, la extensión y la vinculación con el entorno. La IA puede facilitar la personalización, la adaptación, la colaboración, la interacción, la evaluación, la retroalimentación, el apoyo, la orientación y el seguimiento de los estudiantes, así como la generación, el análisis y la difusión del conocimiento (UNESCO, 2020).

La IA y el aprendizaje automático han experimentado un rápido avance en los últimos años, lo que ha llevado al desarrollo de modelos generativos de lenguaje como el Generative Pre-trained Transformer (GPT) de OpenAI. Estos modelos han mostrado un impacto significativo en diversas áreas, incluida la educación superior (Radford et al., 2019). Algunos de los beneficios que se vislumbran incluyen el apoyo a estudiantes para desarrollar habilidades de escritura, la generación de preguntas de examen para

profesores, y el desarrollo de asistentes virtuales que pueden guiar a los estudiantes a lo largo de su aprendizaje.

Antes del surgimiento de los modelos generativos de lenguaje, había técnicas y enfoques utilizados en el campo de la inteligencia artificial para abordar problemas relacionados con el lenguaje natural. Inicialmente se intentó abordar el procesamiento del lenguaje natural mediante el desarrollo de reglas y gramáticas específicas para comprender y generar texto. Sin embargo, este enfoque resultó limitado debido a la complejidad y la variedad del lenguaje natural.

Los parámetros de los modelos generativos son aquellos valores o argumentos que definen las operaciones dentro del mismo. Simplificando mucho el significado, podemos decir que los parámetros son los coeficientes de cada término presente en el modelo matemático (Arnold, 2023). Uno de los modelos más avanzados de generación de lenguaje natural es GPT-4 también de OpenAI, que se hizo disponible el 14 de marzo de 2023. Para entender su grado de innovación es necesario mencionar que GPT-3 (el motor de ChatGPT en su versión gratuita) fue lanzado en 2020 con 175,000 millones de parámetros. En el caso de GPT-4, varios editores de tecnología creen que fue entrenado con 100 billones de parámetros, aunque otros creen que el número de parámetros no es mucho mayor que el de GPT-3, pero los utiliza de forma más eficiente.

METODOLOGÍA

Revisión bibliográfica

Se realizó una búsqueda bibliográfica en Google Académico (<https://scholar.google.com/>), buscando como palabras clave: ChatGPT, inteligencia artificial, modelos generativos de lenguaje y ChatGPT en educación superior. Además de la búsqueda computadorizada se realizó una búsqueda manual entre las referencias de los estudios seleccionados.

Estudio de caso

Con el fin de abordar el estudio de caso se aplicó una encuesta sobre el uso de ChatGPT mediante la aplicación Poe, se creó un ChatBot con el Prompt señalado en la figura 1. Una vez probado este ChatBot durante una clase de 21 estudiantes de tercer semestre de la carrera de Ingeniería Industrial del Tecnológico Nacional de México Campus Pabellón de Arteaga se aplicó una encuesta diseñada para obtener percepciones significativas y representativas (Fig. 2). La encuesta se estructuró con preguntas mixtas, combinando la escala de Likert y preguntas dicotómicas para capturar matices y respuestas directas. La encuesta se administró de manera electrónica a través de Google Forms, facilitando la recopilación eficiente de datos. Se garantizó la confidencialidad de los participantes, quienes recibieron

información previa sobre el propósito de la encuesta y su derecho a retirarse en cualquier momento sin consecuencias. Tras la recopilación de datos, se realizó un análisis estadístico descriptivo, empleando medidas como promedios y frecuencias para examinar patrones en las respuestas de la escala de Likert y preguntas dicotómicas.

Figura 1.

Prompt empleado para generar el ChatBot denominado DraPamelaBot empleado en este estudio de caso.



Figura 2.

Encuesta aplicada en este estudio de caso.

Uso de DraPamelaBot
Se asegura la confidencialidad de los datos.
drapamelaromog@gmail.com [Cambiar de cuenta](#)
No compartido
* Indica que la pregunta es obligatoria

¿Te gusto usar DraPamelaBot en esta clase? *

Sí
 No

¿Consideras que DraPamelaBot mejoraría tu comprensión de los temas discutidos en la clase? *

Sí
 No

Creo que el DraPamelaBot mejoraría mi experiencia general en esta clase. *

1 2 3 4 5
Nada de acuerdo Totalmente de acuerdo

¿Crees que el uso de DraPamelaBot debería expandirse para incluir más funciones en información sobre la vida estudiantil? *

Sí
 No

¿El DraPamelaBot te ayudaría a resolver dudas específicas relacionadas con el contenido de la materia? *

Sí
 No

¿Crees que DraPamelaBot puede facilitar la comunicación con el profesor o los compañeros de clase? *

Sí
 No

¿Te sientes más comprometido/a en la clase gracias a la presencia de DraPamelaBot ? *

Opción 1

Recomendaría la implementación del DraPamelaBot en otras clases. *

Sí
 No

¿DraPamelaBot influyó positivamente en tu participación activa durante las actividades en clase? *

Sí
 No

¿DraPamelaBot te motiva a explorar más recursos y materiales relacionados con la clase? *

Sí
 No

La interfaz de DraPamelaBot era fácil de usar y entender. *

1 2 3 4 5
Nada de acuerdo Totalmente de acuerdo

DraPamelaBot sería útil para recibir retroalimentación instantánea sobre mi entendimiento de los temas de clase. *

1 2 3 4 5
Nada de acuerdo Totalmente de acuerdo

La respuesta de DraPamelaBot a mis preguntas fue precisa y relevante. *

1 2 3 4 5
Nada de acuerdo Totalmente de acuerdo

¿Consideras que DraPamelaBot debería personalizarse más para adaptarse a las necesidades específicas de la clase? *

Sí
 No

¿Te sentiste cómodo/a expresando tus inquietudes a través de DraPamelaBot en comparación con otros métodos de comunicación? *

Sí
 No

RESULTADOS

Software de inteligencia artificial disponible actualmente

Aunque la atención actual está en los modelos generativos de lenguaje, no es el único tipo de software de inteligencia artificial disponible actualmente. Además de estos modelos tenemos:

- **Sistemas expertos:** Los primeros ejemplos de IA, están basados en el conocimiento y la lógica. Sistemas como MYCIN, desarrollado en la década de 1970, se utilizan para el diagnóstico médico (Feigenbaum, 1991). Otros sistemas expertos se utilizan en la ingeniería, la agricultura y los negocios (Russell, 2016).
- **Aprendizaje automático:** El aprendizaje automático y la minería de datos han experimentado un rápido crecimiento y adopción en la última década. Esto incluye redes neuronales, aprendizaje profundo, procesamiento del lenguaje natural y visión por computadora (Zhang et al, 2016). Plataformas como TensorFlow, PyTorch y Scikit-learn han hecho que estos algoritmos sean más accesibles (Pedregosa, 2011) (Goodfellow, 2016).
- **Robótica y automatización:** Éstos se están volviendo más sofisticados y omnipresentes. Los robots realizan tareas físicas en entornos como fábricas, almacenes y hogares (Russell, 2016). Vehículos autónomos también están siendo desarrollados activamente (Thrun, 2006).

- Procesamiento del lenguaje natural: (PLN) permite a los sistemas de IA analizar, comprender y generar lenguaje humano. Esto incluye traducción automática, resumen de textos, chatbots, reconocimiento de voz y más. Modelos como BERT, GPT-2 – y sus variantes- y Transformer han impulsado grandes avances en PLN (Kaiser, 2017). El PLN ha dado como resultado el desarrollo de modelos generativos de lenguaje que están ahora al alcance de todos.

Principales modelos generativos de lenguaje

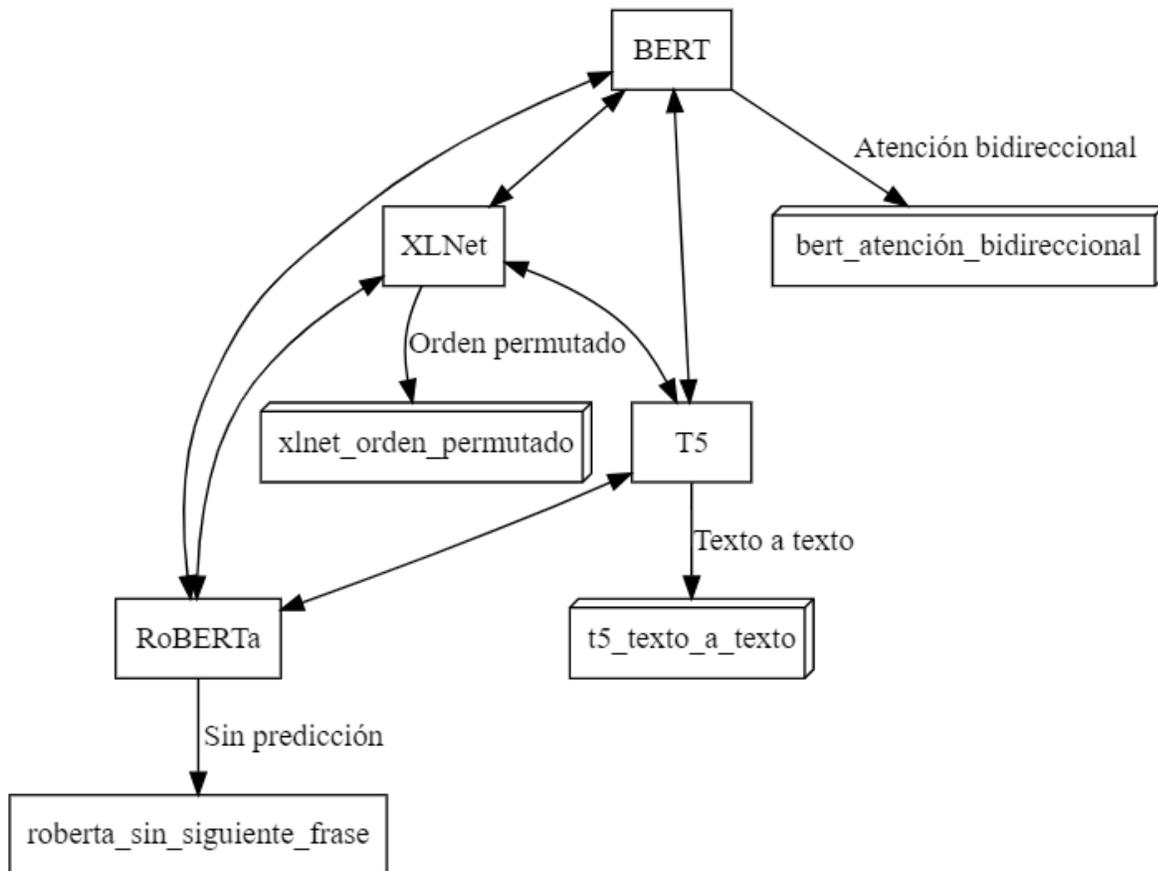
El más notorio de los modelos generativos de lenguaje -por la amplia publicidad que ha recibido- es ChatGPT, basado en el modelo GPT-3 en su versión gratuita y con la opción de usar el modelo GPT-4 en su versión de paga. Sin embargo, existen varios modelos generativos de lenguaje que han demostrado ser competidores notables en el campo del lenguaje natural y que pueden rivalizar con ChatGPT en términos de rendimiento y aplicaciones. Entre estos modelos están:

- BERT (Bidirectional Encoder Representations from Transformers): Desarrollado por Google AI Language, BERT es un modelo de aprendizaje profundo bidireccional basado en la arquitectura Transformer (Devlin et al., 2018). Este modelo ha establecido nuevos estándares en tareas de comprensión del lenguaje natural y ha sido ampliamente adoptado en diversas aplicaciones, principalmente en el buscador de Google que ahora interpreta el lenguaje de forma más natural y elimina la necesidad de usar símbolos para refinar las búsquedas.
- XLNet (eXtreme Multi-task Learning Network): Propuesto por Yang en 2019, XLNet es un modelo de lenguaje autoregresivo basado en la arquitectura Transformer que supera algunas limitaciones de BERT al considerar todas las permutaciones posibles de las palabras en una secuencia. Este enfoque permite a XLNet capturar información contextual de manera más efectiva. Entre sus aplicaciones se encuentra la recomendación de contenido, como artículos, noticias o documentos basándose en el texto introducido.
- T5 (Text-to-Text Transfer Transformer): Desarrollado por Google Research, T5 es un modelo basado en la arquitectura Transformer que trata todas las tareas de procesamiento del lenguaje natural como problemas de traducción de texto a texto (Raffel et al., 2019). T5 ha demostrado un rendimiento excepcional en una amplia gama de tareas de lenguaje natural. Gracias a su arquitectura de todo en uno, T5 permite una amplia gama de tareas de procesamiento del lenguaje natural como resumen, generación, clasificación, compleción y comprensión.
- RoBERTa: RoBERTa (Robustly optimized BERT approach) es una variante de BERT desarrollada por Facebook AI (Liu et al., 2019). A través de la optimización del preentrenamiento y la modificación de algunos hiperparámetros, RoBERTa ha logrado mejoras significativas en el rendimiento en comparación con BERT en varias tareas de lenguaje natural. Algunas de sus aplicaciones son: clasificación de texto, resumen automático y respuestas a preguntas.

Todos los anteriores son modelos Transformers, una arquitectura de redes neuronales que funciona con secuencias de datos, como palabras u oraciones. Estas secuencias no se procesan de forma lineal, sino que cada elemento de la secuencia es procesado en relación con todos los demás elementos. La figura 3 muestra las principales diferencias entre estos modelos: BERT utiliza atención bidireccional, lo que le permite entender el contexto en ambas direcciones, XLNet utiliza un orden permutado de las secuencias de entrada, en lugar del orden secuencial, T5 está diseñado específicamente para tareas de texto a texto, RoBERTa no utiliza la tarea de predicción de siguiente frase durante el preentrenamiento.

Figura 3.

Diferencias entre modelos generativos de lenguaje basados en Transformers



Aunque comparten una arquitectura Transformer similar, introducen mejoras distintas sobre el modelo BERT original. Se influyen mutuamente e incorporan técnicas exitosas de otros modelos. Estos modelos son los que recientemente han dominado la escena no son los únicos sistemas de generación de lenguaje También tenemos los siguientes:

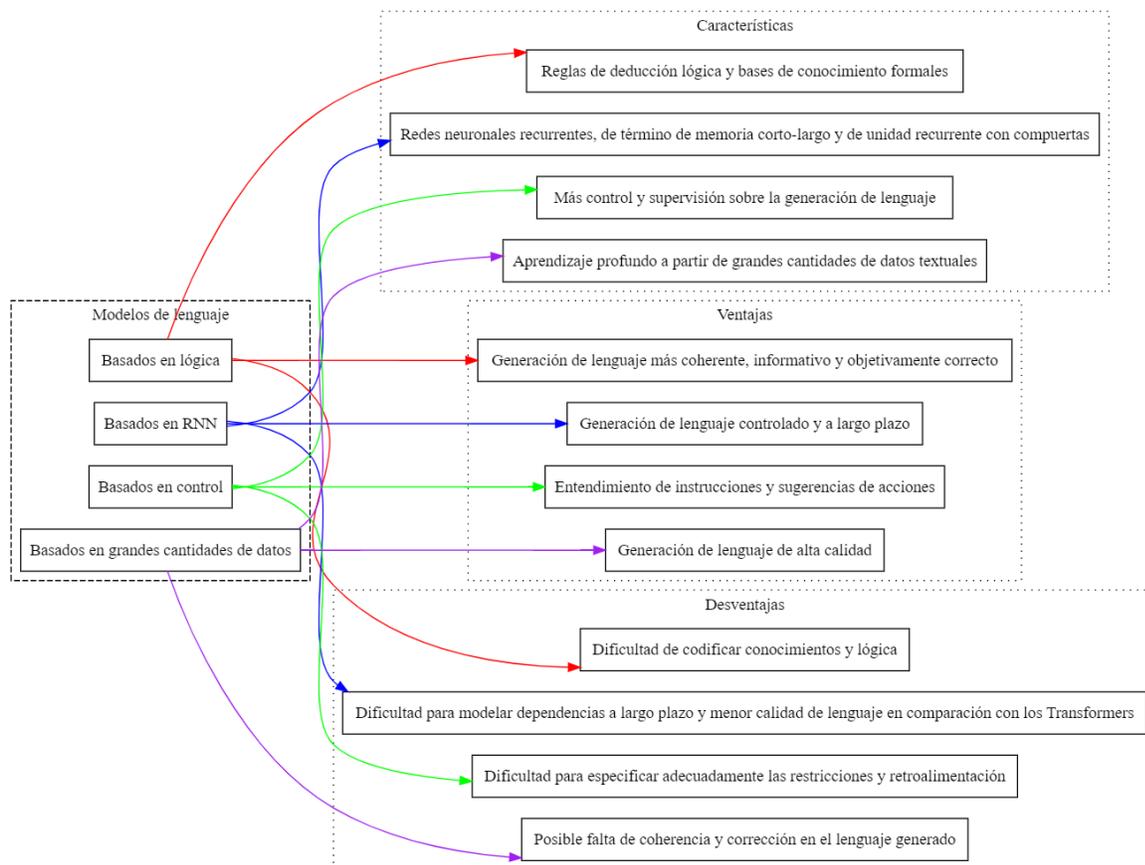
- Modelos de lenguaje basados en lógica: Estos modelos utilizan reglas de deducción lógica y bases de conocimiento formales para generar lenguaje de una manera más controlada. Por ejemplo, el sistema de Russell (2019) genera relatos cortos al aplicar reglas de trama y creación de palabras junto con restricciones lógicas. Si bien la calidad del lenguaje es inferior a la de los modelos de Transformers, los enfoques lógicos tienen el potencial de generar lenguaje más coherente, informativo y objetivamente correcto. Las limitaciones incluyen la dificultad de codificar conocimientos y lógica en estas plataformas.
- Redes neuronales recurrentes: Las redes neuronales recurrentes (RNR), las redes neurales de término de memoria corto – largo (TMCL) y las redes neuronales de unidad recurrente con compuertas (URC) dominaron la generación de lenguaje antes de la aparición de los Transformers. Por ejemplo, Mikolov (2010) y Sutskever (2011) demostraron la capacidad de las RNR y TMCL para generar texto coherente y de longitud moderada. Si bien han sido superadas por los Transformers en la calidad del lenguaje, las RNR aún muestran potencial para la generación de lenguaje controlado y a largo plazo. Sus desventajas incluyen la dificultad para modelar dependencias a largo plazo y la menor calidad de lenguaje en comparación con los Transformers. Estas redes se han usado para procesamiento de lenguaje natural, reconocimiento de patrones e incluso para reconocimiento de voz, sin embargo, su poca capacidad de memoria limita el alcance de contexto, además de que su velocidad de entrenamiento es más lenta que la de los Transformers.
- Modelos de lenguaje enfocados en el control: Intentan proporcionar más control y supervisión sobre la generación de lenguaje. Por ejemplo, los sistemas de retroalimentación de Lewis (2020) y los modelos de restricciones de Holtzman (2020) restringen las salidas de los modelos de lenguaje para satisfacer ciertos requisitos. El marco de Constitutional AI de African (2020) aplica auto-supervisión para alinear los modelos con conjuntos de normas. Los modelos de control se entrenan específicamente para entender instrucciones y sugerir acciones, por lo que su alcance es más limitado que modelos generales de lenguaje. Su principal desventaja es la dificultad de especificar adecuadamente las restricciones y retroalimentación para estos sistemas. Una aplicación de estos modelos es control de sistemas físicos basados en instrucciones de texto, como robots, vehículos autónomos o máquinas.

Estos modelos podrían superar a ChatGPT permitiendo mayor coherencia temática y apego a hechos específicos, aunque aún están limitados en la calidad literaria del lenguaje que producen. En resumen, mientras que los modelos GPT de Open AI actualmente producen la mejor calidad de lenguaje general, existen algunas alternativas prometedoras basadas en lógica, control y modelos recurrentes que vale la pena considerar para la generación de lenguaje educativo y controlado. Los próximos avances en estas áreas serán cruciales para el desarrollo de sistemas de generación de lenguaje robustos y confiables para aplicaciones educativas.

La figura 4 muestra cuatro tipos de modelos de lenguaje: basados en lógica, basados en RNR, basados en control y basados en grandes cantidades de datos (como ChatGPT). También muestra las características, ventajas y desventajas de cada modelo.

Figura 4.

Características, ventajas y desventajas de modelos no Transformers



Uso de modelos generativos de lenguaje en la educación superior

La implementación de soluciones impulsadas por inteligencia artificial ha traído ventajas competitivas significativas sobre la operación tradicional, y como cualquier implementación tecnológica puede traer sus propios desafíos y limitaciones. Desde su lanzamiento, ChatGPT dividió a los profesores en dos bandos: los que veían un mundo de posibilidades para potenciar las habilidades de sus estudiantes y aquellos que preveían un alud de tareas copiadas y trampas académicas. El Departamento de Educación de la Ciudad de Nueva York decidió prohibir el uso de ChatGPT en las redes y dispositivos de sus escuelas (Rosenblatt,

2023). Poco tiempo después, un estudiante de la Universidad de Princeton desarrolló una aplicación que puede detectar si un texto ha sido escrito por un humano o por ChatGPT (Gilliard, 2023).

A pesar de la euforia original en el mundo académico, pareciera que la opinión pública se ha centrado en cómo evitar que los estudiantes incurran en prácticas poco éticas. Se siente como una reedición de lo que se vivió durante la pandemia de covid-19 y las clases dictadas por sistemas de videoconferencia como Zoom, donde parecía más importante evitar que el estudiante cayera en deshonestidad académica, que el aprovechar las tecnologías para desarrollar nuevas metodologías de enseñanza.

Uno de los principales retos del uso de modelos generativos de lenguaje en las universidades es su impacto en la evaluación estudiantil. Existe la preocupación de que los estudiantes puedan externalizar sus tareas escritas a ChatGPT u otros sistemas de IA, lo que podría socavar la integridad académica y hacer que las evaluaciones sean menos efectivas para medir el aprendizaje de los estudiantes. Además, algunos instructores pueden resistirse a adaptarse a los cambios en los métodos de evaluación y pueden tener preocupaciones sobre cómo integrar estos modelos en su enseñanza.

Es necesario señalar que, aunque los modelos generativos de lenguaje pueden proporcionar información útil, también pueden generar información incorrecta o de baja calidad. Esto plantea preocupaciones sobre la confiabilidad de la información proporcionada por estos modelos, especialmente cuando se utilizan en un contexto educativo. Es necesario evaluar y validar la calidad de la información generada por estos modelos para garantizar que los estudiantes reciban información precisa y útil (Brown et al., 2020). A continuación, se mencionan desafíos y riesgos del uso de modelos generativos de lenguaje en la educación superior.

Calidad de la información generada

La calidad de la información generada por modelos de lenguaje, es un factor crítico en su utilidad y confiabilidad. La calidad se puede evaluar en función de varios criterios, como la precisión, relevancia, coherencia, legibilidad y objetividad. A continuación, se detallan estos criterios y cómo se pueden lograr mediante el entrenamiento y ajuste de modelos generativos de lenguaje.

A) **Precisión.** La precisión se refiere a qué tan exacta es la información generada por el modelo en relación con la realidad o los hechos establecidos. La precisión de los modelos generativos de lenguaje se basa en la calidad de los datos utilizados durante su entrenamiento. Estos datos provienen de una amplia variedad de fuentes, incluido el contenido en línea, como sitios web, blogs, foros y documentos académicos. Sin embargo, dado que la información en línea está en constante cambio y puede contener errores o información desactualizada, la precisión de los modelos no es perfecta.

B) **Relevancia.** La relevancia se refiere a qué tan bien la información generada por el modelo responde a las preguntas o inquietudes del usuario. Los modelos generativos de lenguaje pueden generar información relevante al contextualizar las consultas del usuario y seleccionar información relevante de su base de conocimientos. Sin embargo, la relevancia puede verse afectada por la ambigüedad en las consultas del usuario o la falta de información específica en la base de conocimientos del modelo.

C) **Coherencia.** La coherencia se refiere a si la información generada por el modelo sigue una estructura lógica y clara. Los modelos generativos de lenguaje son capaces de generar texto coherente al analizar y aprender patrones en los datos de entrenamiento. Esto permite al modelo generar oraciones y párrafos que siguen una estructura gramatical y lógica adecuada en función del contexto.

D) **Legibilidad.** La legibilidad es la facilidad con la que el texto generado puede ser leído y comprendido por el usuario. Los modelos generativos de lenguaje están diseñados para generar texto en un lenguaje claro y conciso, utilizando vocabulario y gramática adecuados. Además, el modelo puede adaptarse a diferentes estilos de escritura y niveles de complejidad según las necesidades del usuario.

E) **Objetividad.** La objetividad se refiere a la imparcialidad y neutralidad de la información generada por el modelo. Aunque los modelos generativos de lenguaje están diseñados para proporcionar respuestas objetivas y basadas en hechos, pueden verse influenciados por los sesgos presentes en los datos de entrenamiento. Para abordar este problema, los investigadores y desarrolladores trabajan en técnicas para mitigar y detectar sesgos en los modelos.

A continuación, se muestra una comparativa de los diferentes modelos de generación de lenguaje de acuerdo a los criterios mencionados (Tab. 1).

Tabla 1.

Comparativa entre modelos generativos de lenguaje. Fuente: Elaboración propia.

<i>Modelo</i>	<i>Relevancia</i>	<i>Coherencia</i>	<i>Legibilidad</i>	<i>Objetividad</i>
<i>GPT</i>	Alta	Media	Alta	Baja
<i>BERT</i>	Alta	Alta	Media	Media
<i>XLNet</i>	Alta	Alta	Alta	Media
<i>T5</i>	Media	Alta	Alta	Alta
<i>RNR</i>	Baja	Baja	Baja	Alta
<i>Modelos basados en lógica</i>	Media	Alta	Media	Alta

Como puede verse, ningún modelo actual domina en todas las métricas, por lo que la elección del modelo depende de la aplicación de destino.

Sobrecarga cognitiva

Los modelos generativos de lenguaje pueden proporcionar una gran cantidad de información y recursos a los estudiantes, lo que puede resultar en una sobrecarga cognitiva. La sobrecarga cognitiva se refiere a la dificultad que experimenta un individuo al procesar y retener información en su memoria de trabajo cuando se enfrenta a múltiples fuentes de información o a información compleja (Sweller, 1988). Esta sobrecarga puede dificultar el aprendizaje y la comprensión de los estudiantes, especialmente cuando se presentan con múltiples fuentes de información.

La teoría de la carga cognitiva (Sweller, 1988) sugiere que el diseño de materiales instruccionales y la presentación de información deben tener en cuenta las limitaciones de la memoria de trabajo de los estudiantes. En el contexto de los modelos generativos de lenguaje como ChatGPT, esto implica diseñar interfaces y sistemas que ayuden a los estudiantes a gestionar la información proporcionada de manera efectiva y evitar la sobrecarga cognitiva.

Una forma de abordar este problema es mediante el uso de técnicas de reducción de carga cognitiva, como la segmentación y la preentrenación (Mayer & Moreno, 2003). La segmentación implica dividir la información en fragmentos más pequeños y presentarlos de manera secuencial, lo que permite a los estudiantes centrarse en una parte de la información a la vez. La preentrenación implica presentar conceptos clave antes de proporcionar información más detallada, lo que ayuda a los estudiantes a construir un esquema mental que facilite la comprensión de la información posterior.

Además, es esencial que los educadores y los desarrolladores de modelos de IA trabajen juntos para crear sistemas de apoyo adaptativos que puedan identificar y adaptarse a las necesidades individuales de los estudiantes (Kalyuga, 2007). Estos sistemas pueden ajustar la cantidad y complejidad de la información generada por modelos generativos de lenguaje en función de la experiencia y el conocimiento previo del estudiante, lo que ayuda a evitar la sobrecarga cognitiva y promueve un aprendizaje más efectivo.

Un hecho innegable es que los estudiantes se beneficiarían al poder obtener respuestas a sus consultas más rápidamente a través de conversaciones, en lugar de búsquedas en línea. Esto sugiere que los modelos generativos de lenguaje podrían tener un impacto positivo en la educación al proporcionar una forma más rápida y eficiente para que los estudiantes obtengan respuestas a sus preguntas.

De la implementación en educación superior

Un ejemplo de la aplicación de estos modelos que podría no ser tan obvio es en las licenciaturas de marketing digital y comercio electrónico, ya puede mejorar significativamente la experiencia del cliente al proporcionar interacciones personalizadas con los usuarios. Además, reduce el costo de brindar servicio al cliente al automatizar muchas tareas. Esto puede llevar a una mayor satisfacción del cliente y mayores beneficios operativos y financieros para las empresas. Al ser un modelo de generación de lenguaje natural, puede aportar una mayor precisión para comprender solicitudes de usuarios que hablan diferentes idiomas, dando a las empresas acceso a nuevos mercados (George et al., 2023).

Para María Blasco, responsable de tecnología del Instituto de Enseñanza Secundaria Ramón y Cajal (que en 2021 ganó el reconocimiento a escuela del año por parte de la fundación Princesa de Girona), ChatGPT “es la última evolución de internet, es la máquina parlante de Asimov”, que puede ayudar mucho a desarrollar las potencialidades de los estudiantes (Valgañón, 2023).

Jorge Aranda, representante de Estudiantes en Defensa de la Universidad, estudia en la facultad zaragozana de ingeniería. Él señala que “lo que hay que hacer es educar al alumno para que vea en los trabajos el desarrollo de las competencias y no como una tarea que solo sirve para conseguir una nota al final del curso” (Valgañón, 2023).

Podría decirse que el reto principal es garantizar que los modelos generativos de lenguaje sean utilizados de manera ética y responsable. Por ejemplo, se debe asegurar que se utilice para apoyar el aprendizaje y no para reemplazarlo por completo. También es importante garantizar que se utilice de manera justa y equitativa para todos los estudiantes, independientemente de su nivel socioeconómico o habilidades lingüísticas.

Por otro lado, el uso de estos modelos presenta varias oportunidades para mejorar el aprendizaje y la enseñanza. Una de las principales oportunidades es proporcionar retroalimentación personalizada a los estudiantes. ChatGPT puede analizar el trabajo de un estudiante y proporcionar comentarios específicos sobre cómo mejorar su escritura, lo que puede ayudar a los estudiantes a desarrollar habilidades de escritura más efectivas. Otra oportunidad es apoyar a los estudiantes con discapacidades. Los modelos generativos de lenguaje pueden ser utilizados para proporcionar apoyo adicional a los estudiantes con discapacidades visuales o auditivas, así como para aquellos que tienen dificultades para escribir debido a discapacidades físicas. También pueden ser utilizados para apoyar el aprendizaje de idiomas, ya que pueden proporcionar traducciones precisas y sugerencias de gramática y vocabulario, lo que podría ser especialmente útil para estudiantes internacionales.

Al proporcionar ejemplos de escritura y ofrecer retroalimentación instantánea, estos modelos pueden aumentar la eficiencia del proceso de escritura y ayudar a los estudiantes a desarrollar sus habilidades. Además, al proporcionar sugerencias de redacción y correcciones gramaticales, pueden mejorar la calidad de los trabajos escritos de los estudiantes (Cui et al., 2021).

La creación de preguntas de exámenes es una tarea fundamental en la educación superior, pero también puede ser un proceso laborioso y que consume tiempo. Los modelos generativos de lenguaje, pueden facilitar este proceso al generar automáticamente preguntas basadas en el contenido del curso. Esto permite a los profesores centrarse en la enseñanza y la evaluación, en lugar de invertir tiempo en la creación de preguntas (Wang et al., 2020).

Jürgen Rudolph (2023), jefe de investigación en la Kaplan Higher Education Academy ofrece algunas recomendaciones a las instituciones de educación superior sobre cómo utilizar mejor las capacidades de los modelos generativos de lenguaje, específicamente de ChatGPT:

1. Desarrollar políticas claras y coherentes sobre el uso de ChatGPT en la evaluación estudiantil y garantizar que se utilice de manera ética y responsable.
2. Proporcionar capacitación a los instructores sobre cómo integrar ChatGPT en su enseñanza y cómo utilizarlo para proporcionar retroalimentación personalizada a los estudiantes.
3. Fomentar la colaboración entre estudiantes y profesores en el desarrollo de ChatGPT para asegurarse de que se adapte a las necesidades específicas del entorno académico.
4. Evaluar regularmente el impacto del uso de ChatGPT en el aprendizaje y la enseñanza, incluyendo su efectividad en la mejora del rendimiento estudiantil y su impacto en la integridad académica.

Estudio de caso

En la actualidad, la Educación Superior enfrenta diversos desafíos relacionados con la adaptación a las tecnologías emergentes y la mejora continua de los métodos de enseñanza. En este contexto, el uso de modelos generativos de lenguaje, como ChatGPT, ha ganado relevancia como una herramienta potencialmente revolucionaria para mejorar la experiencia educativa. Sin embargo, su implementación en entornos académicos de nivel superior plantea una serie de interrogantes y desafíos que requieren una investigación detallada. Esta investigación busca abordar esta problemática explorando el impacto potencial de la integración de ChatGPT en la Educación Superior y proporcionando perspectivas valiosas para informar futuras estrategias educativas y decisiones de implementación.

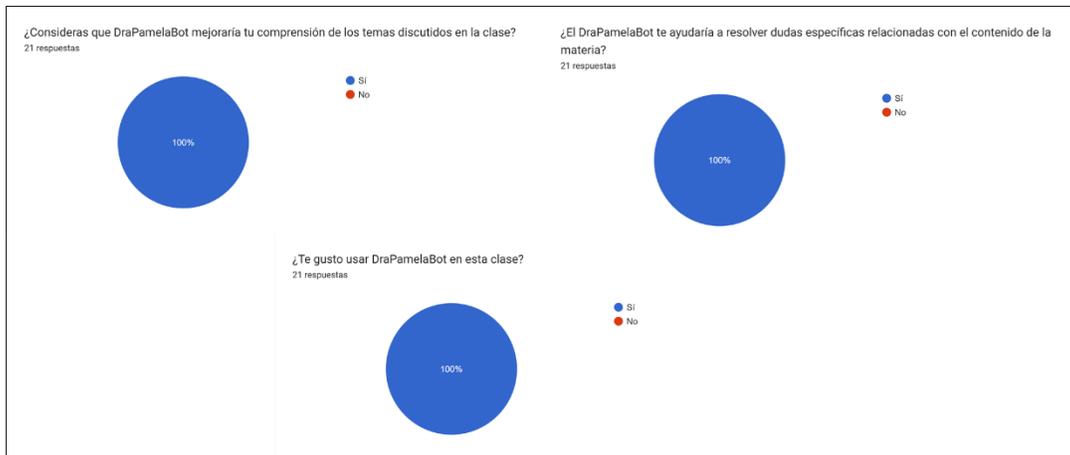
Basándonos en las respuestas recopiladas de la encuesta sobre la opinión de los estudiantes después de usar el ChatBot, se pueden extraer algunas conclusiones clave:

1. Aceptación Positiva del ChatBot:

La mayoría de los estudiantes indicaron la aceptación de utilizar el ChatBot en la clase, y una proporción significativa expresó que mejora su comprensión de los temas y les ayudó a resolver dudas específicas. Esto sugiere una aceptación generalizada de la herramienta como un recurso educativo beneficioso (Fig. 5).

Figura 5.

Preguntas y respuestas de aspecto “Aceptación del ChatBot”.



2. Impacto en la Participación y Compromiso:

Los resultados también muestran que muchos estudiantes sienten que el ChatBot podría facilitar la comunicación con el profesor y los compañeros, y contribuir a un mayor compromiso en la clase. Esto podría indicar un impacto positivo en la interactividad y la participación activa (Fig. 6).

Figura 6.

Preguntas y respuestas de aspecto “Impacto en la participación y compromiso”.

3. Percepción de Utilidad y Efectividad:

Las respuestas sugieren que la mayoría de los estudiantes encontraron que el ChatBot era fácil de usar, ofrecía retroalimentación útil y proporcionaba respuestas precisas. Esto sugiere una percepción general de utilidad y efectividad de la herramienta (Fig. 7).

Figura 7.

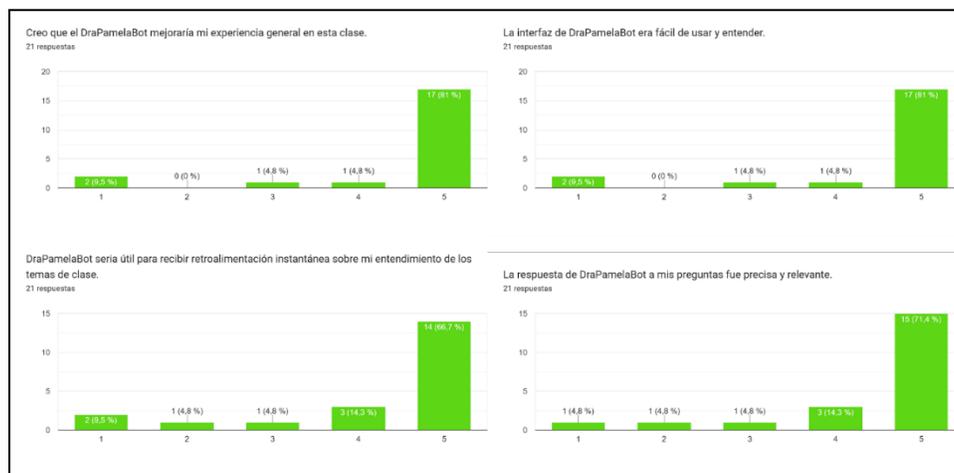
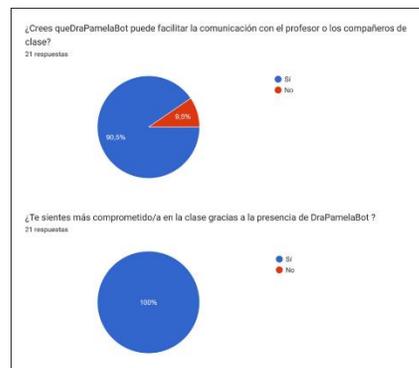
Preguntas y respuestas de aspecto “Percepción de utilidad y efectividad”.

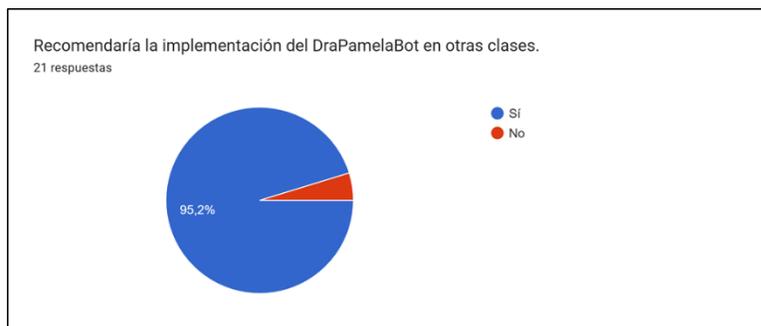
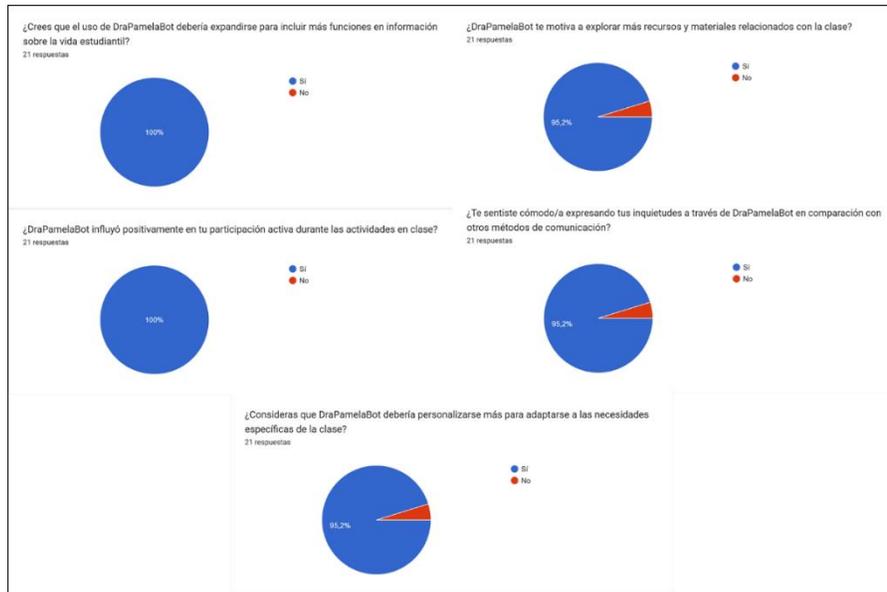
4. Recomendación para la Implementación Futura:

La recomendación positiva de muchos estudiantes para la implementación del ChatBot en otras clases indica un interés continuo y un deseo de aprovechar esta tecnología en entornos académicos (Fig. 8).

Figura 8.

Preguntas y respuestas de aspecto “Recomendaciones”.





5. Áreas de Mejora Potenciales:

Aunque la respuesta general es positiva, algunas áreas específicas, como la personalización del ChatBot y la necesidad de funciones adicionales, podrían señalar áreas de mejora para satisfacer las necesidades específicas de los estudiantes (Fig. 9).

Figura 9.

Preguntas y respuestas de aspecto “Áreas de mejora”.

En resumen, la mayoría de los estudiantes tienen una visión positiva del uso del ChatBot en clase, indicando su potencial para mejorar la experiencia educativa y la interacción estudiante-profesor. Sin embargo, es importante considerar las áreas de mejora identificadas para garantizar una implementación efectiva y continua de esta tecnología en el futuro.

Recomendaciones finales

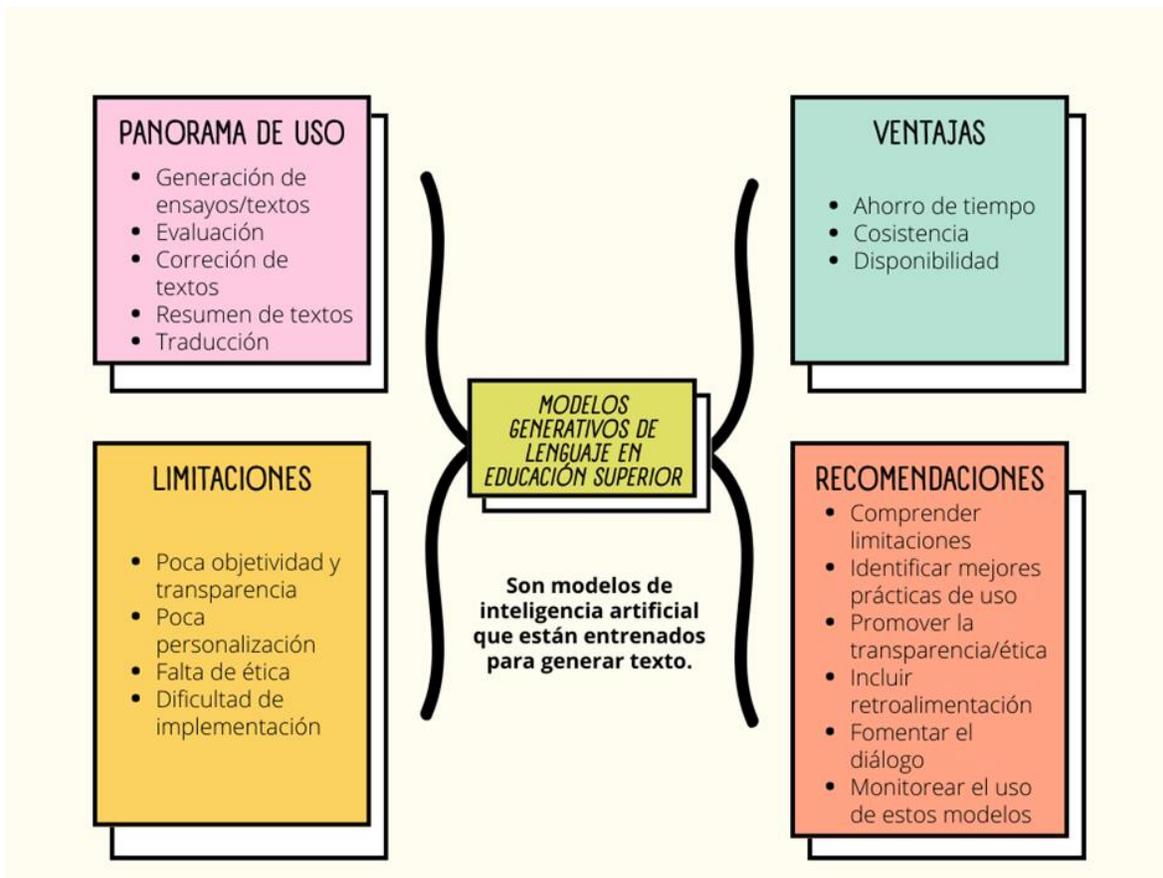
Después de esta revisión sobre los modelos generativos de lenguaje, se recomienda que las instituciones de educación superior opten por la regulación en lugar de la prohibición de su uso por parte de los estudiantes, de tal manera que se logre el impacto deseado (Fig. 10). Para lograr esto, es necesario proporcionar una adecuada capacitación de los profesores y estudiantes, así como el desarrollo de actividades que incorporen el uso de estos modelos de manera planificada y regulada.

A continuación, presentamos algunas recomendaciones generales:

- **Comprender las limitaciones de los modelos generativos de lenguaje:** Es importante que tanto los profesores como los estudiantes comprendan que los modelos generativos de lenguaje son una herramienta de inteligencia artificial y tienen sus limitaciones. Los modelos generativos de lenguaje pueden generar respuestas que no sean completamente precisas o apropiadas para la situación. Por lo tanto, es importante utilizar esta herramienta con precaución y siempre verificar la respuesta generada.
- **Identificar las mejores prácticas de uso:** El uso de modelos generativos de lenguaje en la educación superior debe ser cuidadosamente planificado y diseñado para cumplir con los objetivos educativos específicos. Esto puede incluir la identificación de las mejores prácticas para el uso del chatbot, como la selección de la tarea adecuada, la personalización del modelo y la retroalimentación humana.
- **Promover la transparencia y la ética:** Los chatbots como ChatGPT pueden ser poderosas herramientas, pero también pueden ser utilizados de manera inapropiada o para fines malintencionados. Es importante promover la transparencia y la ética en el uso de estas herramientas, incluyendo la divulgación de las limitaciones del modelo y la fuente de los datos de entrenamiento.
- **Incluir la retroalimentación humana:** Los modelos generativos de lenguaje no son perfectos y pueden generar respuestas que no sean completamente precisas o apropiadas para la situación. Por lo tanto, es importante incluir la retroalimentación humana en el proceso, para corregir cualquier error o proporcionar una mejor respuesta.
- **Utilizar modelos generativos de lenguaje para fomentar la colaboración y el diálogo:** El uso de modelos generativos de lenguaje en la educación superior puede ser una oportunidad para fomentar la colaboración y el diálogo entre profesores y estudiantes. Al utilizar el chatbot para generar respuestas a preguntas o para explorar un tema en particular, los estudiantes pueden trabajar juntos para desarrollar nuevas ideas y perspectivas.
- **Monitorear el uso de los modelos generativos de lenguaje:** Es importante monitorear el uso de los modelos generativos de lenguaje para evaluar su efectividad en el contexto educativo. Esto puede incluir la evaluación de la calidad de las respuestas generadas, la frecuencia de uso y la satisfacción de los usuarios.

Figura 10.

Mapa mental del impacto de los modelos generativos de lenguaje en la educación superior.



CONCLUSIONES

Los modelos generativos de lenguaje tienen un tremendo potencial para transformar la educación superior, con aplicaciones que van desde asistentes de aprendizaje personalizados hasta chatbots educativos. No obstante, es crucial evaluar cuidadosamente sus beneficios y limitaciones para implementarlo de forma que mejore realmente los resultados de aprendizaje, la experiencia de los estudiantes, y la carga de trabajo de profesores, sin comprometer la agencia humana o la calidad educativa. Más investigación es necesaria para guiar el uso ético y efectivo de estos modelos en la educación.

REFERENCIAS

African, A., Agarwal, S., Fookes, C., Jia, Y., y Quitadamo, A. (2020, April). Constitutional AI: Learning to Generate Constitutional Feedback for AI Alignment. In ICLR 2020 : Eighth International Conference on Learning Representations (Conference track).

- Arnold, V. (2023, February 21). Parámetros GPT-4 rumores y previsiones. Neuroflash. [En línea]<https://neuroflash.com/es/parametros-gpt-4-rumores-y-previsiones/>
- Bai, Y., Kadavath, S., Kundu, S., Askell, A., Kernion, J., Jones, A., y Kaplan, J. (2022). Constitutional AI: Harmlessness from AI Feedback. arXiv preprint arXiv:2212.08073.
- Bolukbasi, T., Chang, K. W., Zou, J. Y., Saligrama, V., y Kalai, A. T. (2016). Man is to Computer Programmer as Woman is to Homemaker? Debiasing Word Embeddings. *Advances in Neural Information Processing Systems*, 29, 4349-4357.
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., y Agarwal, S. (2020). Language Models are few-Shot Learners. arXiv preprint arXiv:2005.14165.
- Cui, Y., Che, W., Liu, T., Qin, B., y Liu, T. Y. (2021). Pre-training with Whole Word Masking for Chinese BERT. arXiv preprint arXiv:1906.08101.
- Devlin, J., Chang, M. W., Lee, K., y Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805.
- Feigenbaum, E. A. (1991). *Expert systems: principles and practice*. Knowledge Systems Laboratory, Department of Computer Science, Stanford University.
- George, A., George, A., y Martin, A. (2023). A Review of ChatGPT AI's Impact on Several Business Sectors. Zenodo (CERN European Organization for Nuclear Research). [En línea] <https://doi.org/10.5281/zenodo.7644359>
- Gilliard, C. (2023, 17 febrero). La respuesta de las universidades al ChatGPT necesita más imaginación. *Letras Libres*. <https://letraslibres.com/ciencia-tecnologia/future-tense-inteligencia-artificial-chatgpt-educacion-universidades/>
- Goodfellow, I. (2016). Nips 2016 tutorial: Generative adversarial networks. arXiv preprint arXiv:1701.00160.
- Holtzman, A., Buys, J., Forbes, M., y Choi, Y. (2020). The Curious Case of Neural Text Degeneration. arXiv preprint arXiv:1904.09751.
- Kaiser, L., Gomez, A. N., Shazeer, N., Vaswani, A., Parmar, N., Jones, L., y Uszkoreit, J. (2017). One model to learn them all. arXiv preprint arXiv:1706.05137.
- Kalyuga, S. (2007). Expertise Reversal Effect and Its Implications for Learner-Tailored Instruction. *Educational Psychology Review*, 19(4), 509-539
- Lewis, M., Yarats, D., Dauphin, Y., Parikh, D., y Batra, D. (2020). Deal or no deal? End-to-end learning for negotiation dialogues. arXiv preprint arXiv:2004.13332.
- Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., y Stoyanov, V. (2019). Roberta: A robustly optimized bert pretraining approach. arXiv preprint arXiv:1907.11692.
- Mayer, R. E., y Moreno, R. (2003). Nine Ways to Reduce Cognitive Load in Multimedia Learning. *Educational Psychologist*, 38(1), 43-52
- Mikolov, T., Karafiát, M., Burget, L., Cernocký, J., y Khudanpur, S. (2010, September). Recurrent neural network based language model. In *Interspeech* (Vol. 2, No. 3, pp. 1045-1048).

- Mitchell, M., Wu, S., Zaldívar, A., Barnes, P., Vasserman, L., Hutchinson, B., y Gebru, T. (2019). Model Cards for Model Reporting. *Proceedings of the Conference on Fairness, Accountability, and Transparency*, 1, 295-304.
- Pedregosa, F. (2016, June). Hyperparameter optimization with approximate gradient. In *International conference on machine learning* (pp. 737-746). PMLR.
- Radford, A., Narasimhan, K., Salimans, T., y Sutskever, I. (2018). Improving Language Understanding by Generative Pre-Training. OpenAI. <https://www.semanticscholar.org/paper/Improving-Language-Understanding-by-Generative-Radford-Narasimhan/dfcbc03c9b776fbf54e3bb8e40e31b9966e90e6c>
- Radford, A., Wu, J., Amodei, D., Amodei, D., Clark, J., Brundage, M., y Sutskever, I. (2019). Better language models and their implications. *OpenAI Blog* [En línea] <https://openai.com/blog/better-language-models>, 1(2).
- Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., y Liu, P. J. (2020). Exploring the limits of transfer learning with a unified text-to-text transformer. *The Journal of Machine Learning Research*, 21(1), 5485-5551.
- Rosenblatt, K. (2023, 5 enero). ChatGPT banned from New York City public schools' devices and networks. *NBC News*. <https://www.nbcnews.com/tech/tech-news/new-york-city-public-schools-ban-chatgpt-devices-networks-rcna64446>
- Rudolph, J., Tan, S., y Tan, S. (2023). ChatGPT: Bullshit spewer or the end of traditional assessments in higher education? *Journal of Applied Learning and Teaching*, 6(1). <https://doi.org/10.37074/jalt.2023.6.1.9>
- Russell, N. (2016). Russell S., Norvig P. *Artificial intelligence: A modern approach*, Malaysia.
- Russell, S. J., Torralba, A., Pustejovsky, J., y Castelano, M. S. (2019). Logic-based approaches for helping to ensure the truthfulness of generated text. *arXiv preprint arXiv:1909.02164*.
- Sutskever, I., Hinton, G. E., y Taylor, G. W. (2011). The recurrent temporal restricted boltzmann machine. In *Advances in neural information processing systems* (pp. 1601-1608).
- Sweller, J. (1988). Cognitive Load during Problem Solving: Effects on Learning. *Cognitive Science*, 12(2), 257-285
- Sweller, J. (2011). Cognitive Load Theory. In J. Mestre & B. Ross (Eds.), *Psychology of Learning and Motivation* (Vol. 55, pp. 37-76). Academic Press
- Thrun, S., Montemerlo, M., Dahlkamp, H., Stavens, D., Aron, A., Diebel, J., y Mahoney, P. (2006). Stanley: The robot that won the DARPA Grand Challenge. *Journal of field Robotics*, 23(9), 661-692.
- UNESCO. (2019). *Declaración Mundial sobre la Educación Superior en el siglo XXI: Visión y Acción*. [En línea] https://unesdoc.unesco.org/ark:/48223/pf0000113878_spa?posInSet=2&queryId=91f39b8f-89fa-4060-9f05-1df9c5657854
- UNESCO. (2020). *Artificial intelligence in education: challenges and opportunities for sustainable development*. [En línea]

https://unesdoc.unesco.org/ark:/48223/pf0000366994?_ga=2.18342332.488254523.1586333171-1419012959.1586333171

Valgañón, S. H. (2023, 15 enero). Las opiniones sobre ChatGPT: «Es la última evolución de internet, es la máquina parlante de Asimov». El Periódico de Aragón. <https://www.elperiodicodearagon.com/aragon/2023/01/15/opiniones-chatgpt-ultima-evolucion-internet-81223723.html>

Yang, Z., Dai, Z., Yang, Y., Carbonell, J., Salakhutdinov, R. R., y Le, Q. V. (2019). Xlnet: Generalized autoregressive pretraining for language understanding. *Advances in neural information processing systems*, 32.

Wang, L., Cheng, J., y Chen, H. H. (2020). Automatic Generation of Multiple-Choice Questions from Domain Ontologies. *Applied Sciences*, 10(12), 4062.

Zhang, L., Xia, G. S., Wu, T., Lin, L., y Tai, X. C. (2016). Deep learning for remote sensing image understanding. *Journal of Sensors*, 2016.