



MASTERPROF UMH
UNIVERSITAS *Miguel Hernández*

**MÁSTER UNIVERSITARIO EN FORMACIÓN DEL PROFESORADO
ESO Y BACHILLERATO, FP Y ENSEÑANZAS DE IDIOMAS**

TRABAJO FIN DE MÁSTER

La inteligencia artificial generativa en el aula de física y química

Estudiante: Francisco Jose Jara Morales
Especialidad: Máster en formación del profesorado
Tutor/a: Julio Alberto Ramos Martinez
Curso académico: 2023-24

Índice

1. Resumen y palabras clave.....	3
2. Introducción	4
2.1. ¿Qué es la inteligencia artificial generativa?	4
2.2. Algunos productos comerciales con inteligencia artificial generativa	7
2.3. ¿Qué papel juega y jugará la AIGen en la educación?	7
3. Revisión bibliográfica: La inteligencia artificial generativa en la educación	8
4. Propuesta didáctica: Aplicando tecnologías de AIGen y computación en la nube para impulsar a los estudiantes de física y química a romper barreras de aprendizaje.	11
AIGen y cloud computing para introducir a alumnos de educación secundaria al análisis químico.	11
5. Conclusiones	17
6. Referencias	19
7. Anexos	23
7.1 Glosario de términos y siglas	23
7.2 Prompts y respuestas reales obtenidas correspondientes al desarrollo de la propuesta didáctica.....	24



1. Resumen y palabras clave

Este estudio se propone como un puente hacia la comprensión general de las aplicaciones de la inteligencia artificial en la educación (AIEd), de manera que se pueda contextualizar una propuesta didáctica en el ámbito científico (STEM) que utiliza esta tecnología. Se ofrece una introducción a la inteligencia artificial y al aprendizaje automático (ML), con un repaso histórico que sitúa las nuevas tendencias en este campo. Se analiza la reciente y aún limitada literatura sobre AIEd, enfocándose particularmente en las aplicaciones en STEM. Con estos fundamentos, se presenta una propuesta docente como ejemplo de las posibilidades que brindan los nuevos modelos de lenguaje a gran escala (LLM) y el acceso a plataformas de computación en la nube. Además, se discuten las implicaciones prácticas y las consecuencias de implementar estas tecnologías en el aula, así como los retos presentes y futuros que enfrentan los docentes, incluyendo la adaptación de los currículos y la necesidad de formación continua. Finalmente, se reflexiona sobre el potencial impacto de la inteligencia artificial en el sector, destacando la importancia de las colaboraciones interdisciplinarias entre educadores y especialistas en inteligencia artificial.

Palabras clave: Inteligencia Artificial Generativa (AIGen), Inteligencia Artificial en Educación (AIEd), Educación STEM, Transformación Digital en Educación, Modelos de Lenguaje a Gran Escala (LLM), Automatización en la Enseñanza, ChatGPT.

This study aims to serve as a bridge to the general understanding of applications of artificial intelligence in education (AIEd), enabling the contextualization of a didactic proposal in the scientific field (STEM) that utilizes this technology. An introduction to artificial intelligence and machine learning (ML) is provided, along with a historical overview that situates new trends in this field. The recent and still limited literature on AIEd is analyzed, with a particular focus on applications in STEM. With these foundations, a teaching proposal is presented as an example of the possibilities offered by large-scale language models (LLM) and access to cloud computing platforms. Additionally, the practical implications and consequences of implementing these technologies in the classroom are discussed, as well as the present and future challenges facing educators, including curriculum adaptation and the need for continuous training. Finally, reflection on the potential impact of artificial intelligence in the sector is provided, highlighting the importance of interdisciplinary collaborations between educators and artificial intelligence specialists.

Keywords: Generative Artificial Intelligence, Artificial Intelligence in Education (AIEd), STEM Education, Digital Transformation in Education, Large Language Models (LLMs), Automation in Teaching, ChatGPT.


2. Introducción

En los últimos años, la inteligencia artificial ha repuntado de una manera salvaje hasta convertirse en uno de los estandartes de la investigación y la inversión tecnológica. El desarrollo y dominio de la AI conlleva uno de los retos más importantes a los que se enfrenta la humanidad en el siglo XXI.

2.1. ¿Qué es la inteligencia artificial generativa?

Con el propósito de poder explicar y contextualizar el concepto de Inteligencia artificial generativa (AIGen) primero hay que definir adecuadamente qué es la inteligencia artificial (AI). Podemos considerar la AI como el diseño de máquinas o sistemas que imitan funciones cognitivas propias de las personas, tales como percibir, procesar, analizar, organizar, anticipar, interactuar, resolver problemas y, más recientemente, crear (Morduchowicz, 2023).


Imagen 1. Simulación de la vista en primer plano de una red neuronal biológica generada por DALL-E 3 (OpenAI, 2024)



Desde un punto de vista tecnológico, el objetivo principal consiste en intentar reproducir artificialmente el funcionamiento del sistema nervioso humano, para ello se intenta replicar la estructura natural que se sabe que está asociada a la

transmisión y el tratamiento de la información, las denominadas redes neuronales. Una red neuronal biológica es considerada como el sistema mejor organizado para procesar eficientemente información proveniente de diferentes sentidos. Uno de los mecanismos clave en el procesado de información compleja en el cerebro humano son las conexiones (sinapsis) entre un gran número de elementos estructuralmente simples (neuronas). Las redes neuronales artificiales son una serie de modelos que imitan la elegancia estructural del sistema nervioso y aprenden patrones por observación (Suk, 2017).

Figura 1. Esquema de la estructura de una red neuronal artificial (figura propia)



En el dibujo anterior se expone de manera simplificada la estructura de una red neuronal feed-forward (el flujo de información va hacia delante), en ella se aprecian las neuronas dispuestas en capas, las neuronas de la primera capa (izquierda) toman diferentes niveles de activación según la señal de entrada. Las neuronas se conectan con las de la siguiente capa, de manera que su nivel de activación afecta al de las neuronas de la capa siguiente teniendo cada relación un peso específico que cambia al entrenar la red. De manera análoga a una red neuronal biológica, la información es procesada a través de las sucesivas capas hasta obtener una señal de salida por la activación de las neuronas de la última capa (derecha). Los parámetros de la red varían con el entrenamiento, esto significa que proporcionando las señales de entrada y salida apropiadas, las redes neuronales dotadas de algoritmos para detectar patrones y hacer predicciones mejoran su desempeño en la realización de diferentes tareas (machine learning).

Desde su surgimiento a finales de los años 50 con el Perceptron, pasando por hitos como las neuronas sigmoides, la retropropagación, las redes convolucionales, las redes recurrentes, el aprendizaje profundo (Deep learning) o las redes generativas antagónicas, las redes neuronales y sus aplicaciones han evolucionado a lo largo de las décadas, ligadas a un progreso vertiginoso en el desarrollo de hardware. En los últimos años, el desarrollo de las GPUs, ha permitido acelerar en gran medida el procesamiento de las operaciones con las matrices que contienen los pesos y activaciones neuronales de las redes; esto ha sacado a la AI del laboratorio y la ha convertido en una tecnología omnipresente en la vida diaria de la mayoría de las personas en el mundo desarrollado.

La aplicación más popular de las redes neuronales en la actualidad es la inteligencia artificial generativa (AIGen). Esta tecnología de AI es capaz de generar contenidos de forma automática en respuesta a instrucciones escritas en interfaces conversacionales de lenguaje natural, conocidas como prompts (Miao & Holmes, 2023).

Tabla 1. Diferentes técnicas usadas en la AI generativa (tabla propia)

Machine learning (ML)		Técnicas para mejorar desempeño de máquinas a través del análisis de datos
Deep learning (DL)		<i>conjunto de algoritmos de aprendizaje automático que intenta modelar abstracciones de alto nivel</i>
AIGen de texto	Generative transformer (GT)	<i>Analiza patrones y relaciones entre diferentes partes de bases de datos con múltiples propósitos</i>
	Large language model (LLM)	<i>Modelo de transformador que es entrenado en enormes grandes cantidades de datos</i>
	Generative pretrained transformer (GPT)	<i>Tipo de LLM que usa técnicas de deep learning para captar sutilezas del lenguaje y generar textos coherentes</i>
AI generativa multimedia	Generative antagonic network (GAN)	<i>Conjunto de redes que compiten entre sí, unas generando y otras verificando. Se entranan para generar resultados más auténticos</i>
	Variational autoencoder (VAE)	<i>Aprenden representaciones comprimidas de datos para crear variaciones de los datos aprendidos</i>

La técnica más utilizada en la AIGen es el large language model o modelo de lenguaje de gran escala (LLM). Los LLM están diseñados para comprender y generar texto utilizando técnicas avanzadas de machine learning. En la actualidad pueden ser combinados con AIs capaces de convertir audio a texto y están siendo integrados en asistentes virtuales. Esta tecnología de AI se encuentra detrás de la mayoría de las utilidades que ofrece la AIGen.



2.2. Algunos productos comerciales con inteligencia artificial generativa

La AIGen llega al usuario proporcionando diferentes utilidades, a continuación, se exponen algunas de ellas junto con ejemplos de especial relevancia:

Generación de Texto: Modelos como GPT (OpenAI, 2020) y Gemini (Google AI, 2023) son LLMs capaces de generar texto coherente y contextualizado en una gran variedad de aplicaciones.

Traducción automática: LLMs como MarianMT (Microsoft, 2020) o DeepL (DeepL GmbH, 2017) y plataformas como Google Translate (Google, 2006) están especializados en la traducción de texto entre diferentes idiomas.

Creación de Contenido Multimedia: modelos como Midjourney (Midjourney, 2022) o DALL-E (OpenAI, 2023) generan imágenes a partir de descripciones textuales. Algunas plataformas como Runway ML (Runway ML, 2020) permiten a sus usuarios entrenar modelos para crear material específico.

Asistentes Virtuales: LLMs conversacionales como DialoGPT (Microsoft, 2020) o BlenderBot (Facebook AI Research, 2021) y asistentes como Alexa (Amazon, 2014) o Siri (Apple Inc., 2011) son capaces de generar respuestas fluidas y naturales.

Simulación y Modelado: un buen ejemplo es SciBERT (Allen Institute for AI, 2019), que al estar entrenado con datos provenientes de más de un millón de artículos científicos es una herramienta especializada en abordar tareas específicas en el ámbito científico, como el modelado de moléculas y la extracción de información científica. Cabe citar aplicaciones como Wolfram Alpha (Wolfram Research, 2009) y MATLAB (MathWorks, 1984), que están utilizando complementos de AIGen que permiten simular y estudiar aspectos científicos y matemáticos.

2.3. ¿Qué papel juega y jugará la AIGen en la educación?

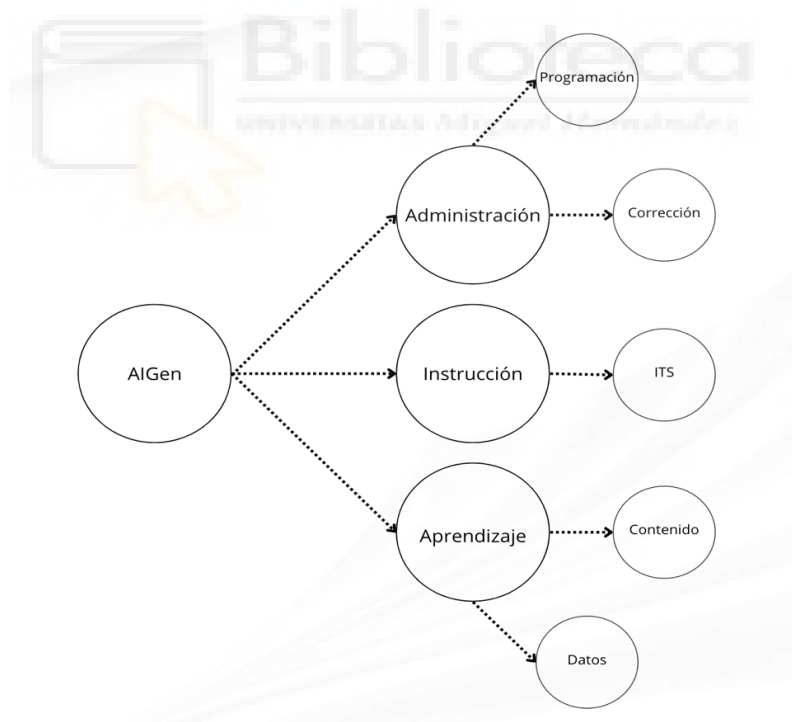
La AIGen brinda acceso a alumnos y educadores a cantidades ingentes de información a través de simples indicaciones. Esta tecnología tiene el potencial no solo de automatizar gran parte de las tareas propias de la docencia, sino de complementar y optimizar tanto la intervención docente humana como el aprendizaje autónomo por parte de los estudiantes. Descubrir las posibilidades que brinda y estudiar su impacto se vislumbra como uno de los grandes retos para los investigadores presentes y futuros, formando parte esencial de un ecosistema interdisciplinar inmerso en un crecimiento desmedido.

3. Revisión bibliográfica: La inteligencia artificial generativa en la educación

El estudio de la integración de la inteligencia artificial en la educación ha ganado popularidad en los últimos años, surgiendo algunos estudios que evalúan el fenómeno desde un punto de vista tecnológico o general, poniendo el foco en las tendencias y los resultados de implementación de diferentes técnicas con AI (Chen et al., 2020; Hwang et al., 2020; Chassignol et al., 2018; Holmes et al., 2023).

Una buena manera de abordar el estudio de la aplicación de la AI en la educación es clasificarla en diferentes ámbitos (Chen et al., 2020), Chen y su equipo segmentan el dominio de aplicación de tecnologías de AI en tres categorías: tareas administrativas, instrucción y aprendizaje.

Figura 2. Ámbitos de implementación de la AI en educación (figura propia)



La AI puede ser empleada con el propósito de agilizar tareas administrativas que consumen gran cantidad de recursos docentes, como la programación de clases, el control de la asistencia o la corrección de exámenes y tareas. En la actualidad, es posible encontrar literatura acerca de la aplicación de soluciones de AI como sistemas de corrección automáticos de manera relativamente exitosa (Azad et al., 2020).



Con respecto a las tareas relacionadas con la instrucción, están surgiendo asistentes y sistemas de tutoría inteligentes (ITS). Los ITS generan secuencias de aprendizaje personalizadas y dan feedback en tiempo real adaptado al nivel de los alumnos para ayudar a superar problemas e identificar y corregir errores (Holmes & Tuomi, 2022), los ITS también pueden ser de gran ayuda para el estudiantado con diversidad funcional (Barua et al., 2022). Los modelos recientes de AIGen permiten la elaboración automática de redacciones, de manera que con un prompt se pueden generar ensayos o fragmentos de ellos que son prácticamente indistinguibles de las escritas por personas, sin embargo, las tecnologías de AI también pueden ser entrenadas para discernir si un escrito incurre en actividades fraudulentas. El uso de sistemas antiplagio como Turnitin (Turnitin, 2022) está ya ampliamente extendido en las instituciones educativas.

Con respecto a las tareas relacionadas con el aprendizaje, quizás el uso más destacado y obvio de la AIGen es la generación automática de material de aprendizaje. En adición a lo anterior, se podrían implementar sistemas de aprendizaje adaptativo que empleen algoritmos de machine learning para analizar datos de los estudiantes como desempeño, evaluaciones, progreso y estilo de aprendizaje (Alam, 2023). Los datos serían procesados y usados para ajustar el currículo educativo, los métodos de enseñanza y los materiales de aprendizaje en función de las necesidades individuales de los estudiantes. Dos buenos ejemplos aplicaciones destinadas al aprendizaje son Spark (Domoscio, 2022) o Gooru navigator (Gooru, 2011). Gooru navigator es un software cuyo propósito específico es el navigated learning (Songer et al., 2020). Songer y su equipo definen el navigated learning (aprendizaje navegado) como una aplicación pedagógica que se fundamenta en la ciencia del aprendizaje y opera a través del análisis de datos (Data Science). La herramienta para ponerlo en práctica es el learning navigator (navegador de aprendizaje), diseñado para detectar continuamente información actualizada del proceso de aprendizaje personalizado de cada estudiante. A pesar de las posibilidades que brindan estas nuevas herramientas, por el momento las aplicaciones del análisis de datos en este ámbito están siendo investigadas (Martins da Silva et al., 2021) y quizás no tienen el grado de madurez y evidencia para ser puestas en práctica de manera masiva por el público general.

En lo respectivo a revisiones específicas de AIEd en el ámbito STEM, especialmente en los estadios de educación primaria y secundaria, la literatura es escasa, pero empiezan a surgir estudios revisando aspectos como herramientas de aprendizaje, estrategias pedagógicas o evaluando resultados de la aplicación de estas tecnologías (Jia et al., 2024; Xu & Ouyang, 2022; Jang et al., 2022). También empiezan a surgir aplicaciones que influyen a nivel de generación de experiencias y contenido en el aula como la realidad aumentada (AR), que permite visionar modelos moleculares 3D interactivos (Fombona-Pascual et al., 2022), laboratorios interactivos con asistentes virtuales (Menikrama et al., 2021) o ITS especializados en STEM, como ReAQ (Portillo et al., 2021).



La AIGen está empezando a ser una tendencia cada vez más relevante en la literatura relacionada con la educación, y el futuro de la investigación en el sector se presenta prometedor en cuanto a la cantidad y calidad de las aplicaciones que empiezan surgir desde un sinfín de aproximaciones y disciplinas.



4. Propuesta didáctica: Aplicando tecnologías de AIGen y computación en la nube para impulsar a los estudiantes de física y química a romper barreras de aprendizaje.

A continuación, se propone una experiencia didáctica que trata de introducir elementos de AIGen y otras tecnologías de vanguardia para la enseñanza de la física y la química en la educación secundaria. Se hace referencia a todas las herramientas necesarias y se explicita de manera genérica el procedimiento aproximado a seguir. La experiencia pretende ser flexible y adaptable a gran variedad de estudiantes en distintos contextos educativos.

AIGen y cloud computing para introducir a alumnos de educación secundaria al análisis químico.

Con el objetivo de ejemplificar el uso AIEd aspirando a mejorar las habilidades STEM de los estudiantes y explorar el potencial de estas nuevas tecnologías, se propone una experiencia problema en la que un LLM actúa como guía. Esto pretende ayudar a los alumnos a superar barreras en el aprendizaje de fenómenos fisicoquímicos, sus instrumentos y técnicas de medida, así como en la utilización de software de análisis de datos. El enfoque pedagógico escogido es el aprendizaje basado en problemas, la intención es trabajar el pensamiento crítico a la par que se proporciona una experiencia inmersiva en un problema relevante que motive el aprendizaje (Yew & Goh, 2016). Las herramientas necesarias para llevar a cabo la experiencia serán Google Collab (Google, 2017), ChatGPT (OpenAI, 2020) y computadoras con conexión a internet para cada alumno o grupo de alumnos.

La sesión empieza exponiendo un problema apropiado, que debe despertar el interés del alumnado y abarcar cuestiones relacionadas con la materia que vayan más allá del currículo ordinario. El problema queda a elección y criterio del docente, pudiéndose adaptar a diferentes niveles, temáticas y necesidades del alumnado, en esta ocasión se ha escogido un caso dirigido para alumnos de Química de 2º de Bachillerato del sistema educativo español, regulado por la Ley Orgánica 3/2020, de 29 de diciembre (Gobierno de España, 2020). También es aplicable a estudiantes de un grado superior relacionado.



El ejemplo propuesto se desarrollaría de la siguiente forma:

1. Como introducción, se advierte de los peligros de la ingesta de mercurio en la dieta, relacionándolo con problemas de salud en el sistema nervioso. Tras esto, se lanza la siguiente pregunta: ¿Cómo podemos saber cuánto mercurio está presente en el pescado que comemos?

2. Se anima a los alumnos a preguntar a ChatGPT por las técnicas disponibles para el análisis in vitro del contenido en mercurio orientando a los alumnos a estructurar su prompt de manera correcta.

Ejemplo de prompt: "Haz una lista con las técnicas más empleadas para el análisis in vitro del contenido de mercurio en alimentos"

Respuesta esperada: Lista con múltiples técnicas analíticas que incluyen las basadas en absorción atómica.

3. Después de obtener los listados de técnicas de análisis, en los que normalmente se incluirán técnicas basadas en la absorción atómica, se procederá a describir dicho fenómeno de manera simple, haciendo hincapié en la relación de proporcionalidad directa entre la absorción de radiación (a la que llamaremos absorbancia sin entrar en detalle) y la cantidad de mercurio (que expresaremos en términos de concentración).

4. Después se pide a los alumnos que pregunten a ChatGPT por el fenómeno de absorción y específicamente por la ley de Lambert - Beer. Se espera que obtengan de inmediato la ecuación de proporcionalidad directa que relaciona absorbancia con concentración de mercurio.

Ejemplo de prompts: "Me gustaría conocer el fenómeno de absorción y específicamente la ley de Lambert – Beer"; "Me gustaría que me detallaras como encontrar la longitud de onda apropiada para medir"

Respuesta esperada: Explicación del fenómeno de absorción y de la ecuación de la ley de Lambert – Beer.

5. Es necesario sugerir a los alumnos que busquen en internet el contenido medio de mercurio presente en el atún enlatado y la longitud de onda de absorción característica del mercurio en el ultravioleta. Estos datos son relevantes para simular el barrido de frecuencias y la medida de los estándares.

6. Los estudiantes piden a ChatGPT un ejemplo de procedimiento de calibrado y análisis. Se espera que de entre los pasos obtenidos en el procedimiento estén la realización de un barrido de frecuencias para detectar el pico de la banda de absorción del mercurio y la creación de una recta de calibrado con estándares cuyas concentraciones estarán listadas.

Ejemplo de prompt: “Exponme un ejemplo de procedimiento de calibrado y análisis para la determinación de mercurio en una muestra de atún”

Respuesta esperada: Ejemplo de procedimiento de calibrado y análisis para la determinación de mercurio en una muestra de atún utilizando espectrometría de absorción atómica. Sugerencia de realizar un barrido de frecuencias.

7. Los alumnos piden a ChatGPT que cree código que permita representar un gráfico con Python (Python Software Foundation, 2020) para simular el barrido de frecuencias. Pegan el código en Google Collab y compilan.

Ejemplo de prompt: “Simula una gráfica en Python de un barrido de frecuencias de un espectrómetro que marce la banda de absorción a 254nm y añada ruido a la señal para que se asemeje a un resultado experimental”

Respuesta esperada: líneas de código que pueden ser ejecutadas en Python y generan la gráfica deseada.

Figura 3. Captura de pantalla de la interfaz de ChatGPT, que muestra cómo se obtienen respuestas en código Python (figura propia)

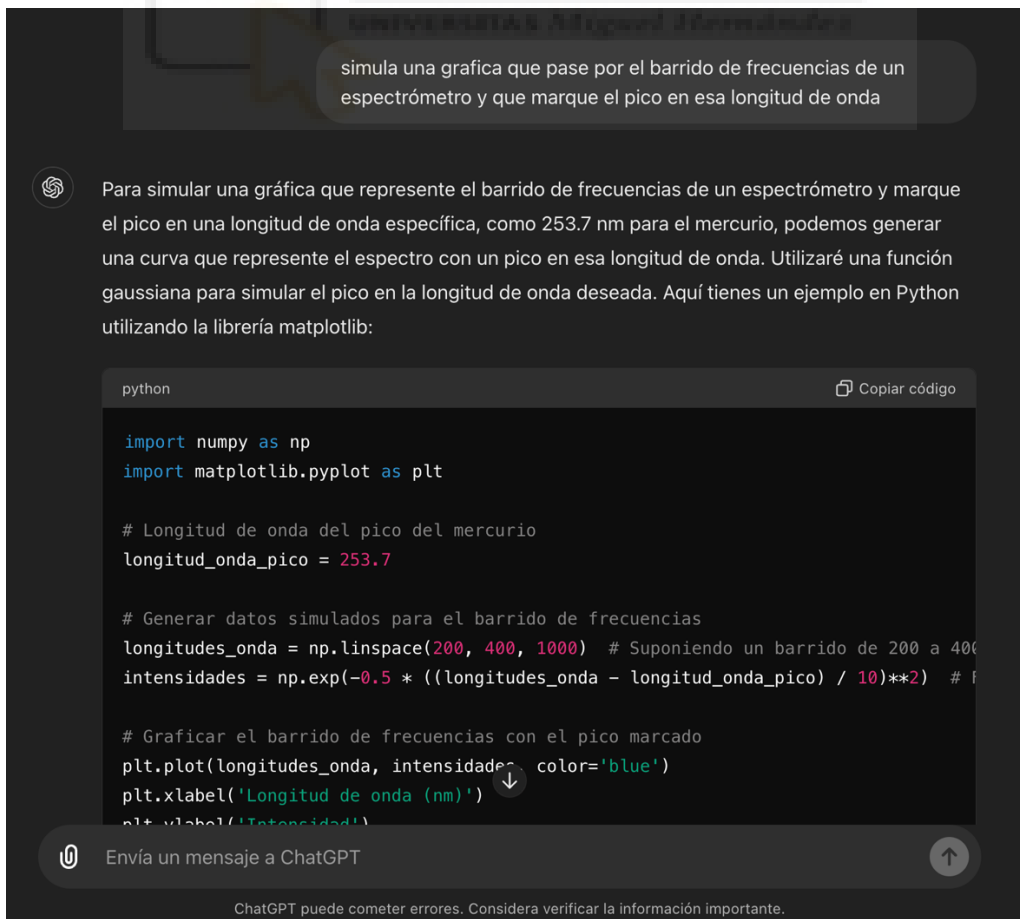


Figura 4. Captura de pantalla de la interfaz de Google Collab, que muestra cómo se compila el código generado por Chat GPT (figura propia)

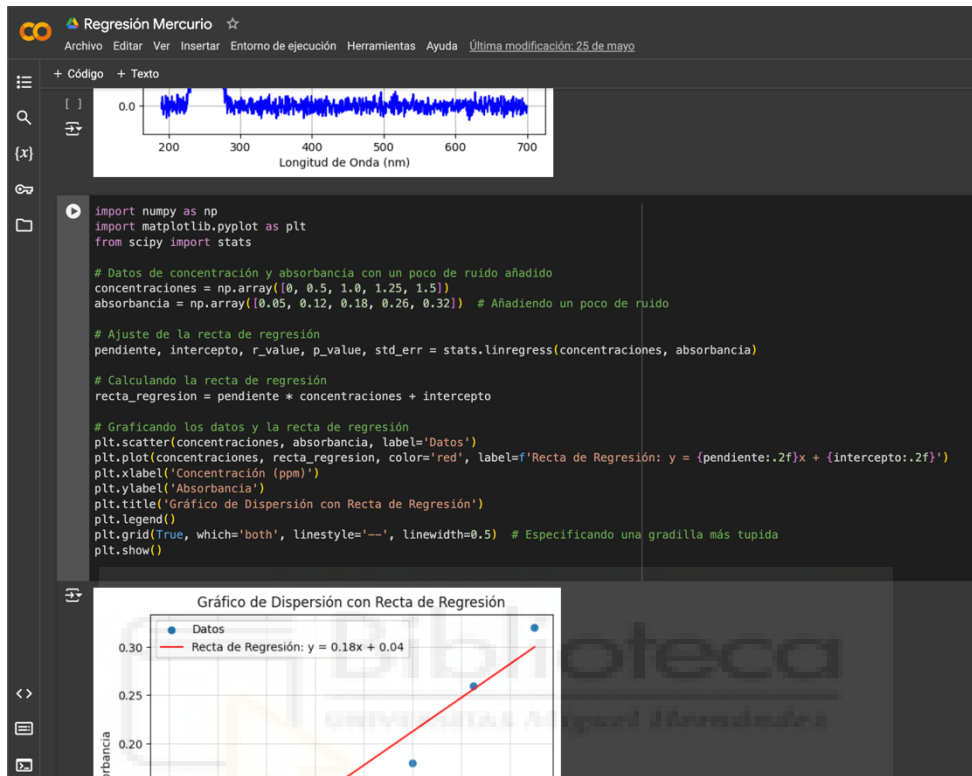



Figura 5. Gráfico de la simulación de un barrido de frecuencias en un estándar de mercurio (figura propia)




8. Cuando todos tengan el contenido esperado, procederán a pedirle a ChatGPT que le genere y grafique con código de Python una señal analítica compatible con la producida por un espectrómetro de absorción atómica en llama. Además, tienen que hacer que se les calcule la recta de regresión correspondiente. Normalmente, con algo de prueba y error obtendrían una tabla con los datos de absorbancia de los estándares y código para generar un gráfico de dispersión con las absorbancias y las concentraciones de los estándares y que se asemeje a la que puede ser obtenida experimentalmente.

Ejemplos de prompts: "Genera una tabla simulando los datos que se obtendrían midiendo las absorbancias de los estándares con concentraciones de mercurio entre 0 y 1 ppm, añade ruido a la señal para que se asemeje a un resultado experimental"; "Genera un diagrama de dispersión con los datos de la tabla que incluya la recta de regresión y su ecuación en la leyenda"

Respuestas esperadas: líneas de código para generar la tabla y el diagrama de dispersión con la ecuación de la recta de regresión.

Figura 6. Gráfico simulado de la dispersión de Absorbancias frente a las concentraciones de los estándares de mercurio, con su correspondiente recta de regresión (figura propia)





9. Cuando tengan los resultados esperados, con el fin de evaluar la comprensión de los contenidos desarrollados, se les pide que calculen la absorbancia que esperarían obtener de una muestra con la cantidad media de mercurio, usando la ecuación de la recta de regresión obtenida en la simulación. También se les pregunta cómo usarían la ecuación para calcular la concentración de mercurio de una muestra con una cantidad desconocida de mercurio. Esto daría respuesta a la pregunta problema planteada al inicio de la práctica.

Como resultado de la experiencia, se espera que las herramientas de AIEd hayan servido para que los alumnos de educación secundaria que participen puedan acercarse, aunque de manera superficial, a aspectos propios de la educación terciaria en STEM. El papel de la AI es acercar a los estudiantes a la utilización de herramientas sofisticadas de análisis de datos y a la simulación de experimentos científicos. Recursos como la regresión lineal, la generación de señales gaussianas con ruido y el uso de programación para el tratamiento de datos son demandados en el devenir de la práctica, y constituyen fuertes barreras de aprendizaje para los alumnos de secundaria, ya que para ser aplicados requieren sólidos conocimientos previos en campos como las matemáticas o las ciencias de la información. Esta experiencia es un ejemplo práctico de como un LLM puede ayudar a saltar esas barreras, no obstante la situación novedosa de estas tecnologías impide, por ahora, conocer una amplitud suficiente de recursos bibliográficos de los que servirse para prever los resultados de la experiencia en términos de rendimiento y utilidad.



5. Conclusiones

La inteligencia artificial se ha consolidado como la punta de lanza de la innovación tecnológica en la década de 2020, encontrando aplicaciones transversales en diversas disciplinas. En el sector industrial, el machine learning ha transformado los procesos de automatización, permitiendo una mayor eficiencia y precisión. En el campo financiero, los modelos de IA están revolucionando la manera de procesar grandes volúmenes de datos y predecir patrones de mercado, lo que ha generado una auténtica revolución en el sector de la inversión. En el ámbito del diseño, la IA generativa (IAGen) ha acelerado la capacidad de crear contenido automáticamente, transformando la industria a un ritmo vertiginoso. Estos ejemplos ilustran cómo la IA está reconfigurando aspectos fundamentales de nuestras economías y sociedades. Asimismo, la investigación tecnológica y científica se está beneficiando enormemente de la IA, con aplicaciones que abarcan desde el desarrollo de nuevos materiales hasta la simulación de fenómenos físicos, la creación de sistemas autónomos avanzados y la prevención de epidemias.

El sector de la educación no permanece al margen de esta revolución tecnológica e industrial. Las múltiples aplicaciones emergentes de la IA en educación, previamente discutidas, demuestran un potencial prometedor que apenas comienza a ser comprendido y explotado. No obstante, ya se observan los primeros efectos del acceso casi universal de los estudiantes a la IA en los países desarrollados. Un claro ejemplo es el cambio en la percepción de los educadores sobre la utilidad de tareas tradicionales, como redacciones o ensayos, debido a la expectativa de que los estudiantes utilicen herramientas de generación de texto asistida por IA. Estas repercusiones están llevando a una revisión crítica de las prácticas docentes, con voces que advierten sobre posibles consecuencias negativas para el sistema educativo.

La AIEd también presenta serios problemas y desafíos, uno de ellos es la desigualdad de oportunidades sobrevenida por un acceso no equitativo a utilidades avanzadas de IA. El acceso a datos personales de cantidades enormes de estudiantes por parte de las compañías se posiciona como otra gran preocupación para quienes dirimen aspectos éticos. En cuanto a los recursos humanos en el sector educativo, una temida consecuencia de las herramientas de automatización podría ser la deshumanización parcial de la enseñanza, desplazando en algunos casos el papel de los docentes y privando a los estudiantes de la interacción humana necesaria para un aprendizaje saludable, que incluye el desarrollo de competencias sociales. Las tecnologías emergentes están forzando una adaptación constante en la educación, subrayando la necesidad de que los docentes se formen continuamente para adaptarse a los rápidos y continuos cambios en las tecnologías de IA. Estos cambios incluyen conocer las últimas aplicaciones y algoritmos de machine learning para comprender mejor la toma de decisiones automáticas en intervenciones docentes. Al igual que en otros sectores del mercado laboral, se espera que la



introducción de la IA tenga consecuencias en términos de empleo aún difíciles de predecir. Estos retos imponen la necesidad de aplicar un enfoque ético y responsable en el desarrollo y aplicación de la AIEd, garantizando que estas tecnologías beneficien tanto a estudiantes como a docentes sin comprometer principios esenciales de justicia y privacidad. Para ello, es conveniente la revisión de estas aplicaciones tecnológicas por expertos de diversas disciplinas, como la informática, el derecho, la sociología y la documentación, con el fin de establecer junto con los docentes, medidas profilácticas adecuadas para mitigar las amenazas mencionadas anteriormente.

Considerando la enseñanza en las disciplinas STEM, la integración de la AIEd ha demostrado un potencial significativo para ayudar a los estudiantes en la redacción de informes, la resolución de problemas complejos y la colaboración en proyectos de investigación. En conjunto, estas aplicaciones subrayan el potencial de la AIEd para enriquecer el aprendizaje de fenómenos fisicoquímicos, fomentar el pensamiento crítico y preparar a los estudiantes para enfrentar los desafíos del futuro con un enfoque basado en el análisis de datos y la innovación tecnológica.





6. Referencias

- Alam, A. (2023). Harnessing the Power of AI to Create Intelligent Tutoring Systems for Enhanced Classroom Experience and Improved Learning Outcomes. *Lecture Notes on Data Engineering and Communications Technologies*, 171, 571–591. https://doi.org/10.1007/978-981-99-1767-9_42
- Allen Institute for AI. (2019). SciBERT [Modelo de lenguaje científico]. Recuperado de <https://github.com/allenai/scibert>
- Amazon. (2014). Alexa [Asistente virtual]. Recuperado de <https://www.amazon.es/b?ie=UTF8&node=15823644031>
- Apple Inc. (2011). Siri [Asistente virtual]. Recuperado de <https://www.apple.com/siri/>
- Azad, S., Chen, B., Fowler, M., West, M., & Zilles, C. (2020). Strategies for deploying unreliable AI graders in high-transparency high-stakes exams. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12163 LNAI, 16–28. https://doi.org/10.1007/978-3-030-52237-7_2
- Barua, P. D., Vicnesh, J., Gururajan, R., Oh, S. L., Palmer, E., Azizan, M. M., Kadri, N. A., & Acharya, U. R. (2022). Artificial Intelligence Enabled Personalised Assistive Tools to Enhance Education of Children with Neurodevelopmental Disorders—A Review. *International Journal of Environmental Research and Public Health* 2022, Vol. 19, Page 1192, 19(3), 1192. <https://doi.org/10.3390/IJERPH19031192>
- Chassignol, M., Khoroshavin, A., Klimova, A., & Bilyatdinova, A. (2018). Artificial Intelligence trends in education: a narrative overview. *Procedia Computer Science*, 136, 16–24. <https://doi.org/10.1016/J.PROCS.2018.08.233>
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial Intelligence in Education: A Review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/ACCESS.2020.2988510>
- da Silva, L. M., Dias, L. P. S., Barbosa, J. L. V., Rigo, S. J., Anjos, J. C. S. D., Geyer, C. F. R., & Leithardt, V. R. Q. (2022). Learning Analytics and Collaborative Groups of Learners in Distance Education: A Systematic Mapping Study. *Informatics in Education*, 21(1), 113–146. <https://doi.org/10.15388/INFEDU.2022.05>



- DeepL GmbH. (2017). DeepL [Herramienta de traducción]. Recuperado de <https://www.deepl.com/es/translator-mobile>
- Domoscio. (2022). Spark [Plataforma de aprendizaje adaptativo]. Recuperado de <https://domoscio.com/en/domoscio-spark-2/>
- Facebook AI Research. (2021). BlenderBot: A Large Language Model for Conversational AI [Modelo de lenguaje para IA conversacional]. Recuperado de <https://about.fb.com/news/2022/08/blenderbot-ai-chatbot-improves-through-conversation/>
- Fombona-Pascual, A., Fombona, J., & Vicente, R. (2022). Augmented Reality, a Review of a Way to Represent and Manipulate 3D Chemical Structures. *Journal of chemical information and modeling*, 62(8), 1863–1872. <https://doi.org/10.1021/acs.jcim.1c01255>
- Google. (1998). Google Search. [Motor de búsqueda] Recuperado de <https://www.google.com>
- Google. (2006). Google Translate [Herramienta de traducción]. Recuperado de <https://translate.google.com/>
- Google. (2017). Colaboratory [Entorno de notebook colaborativo]. Recuperado de <https://colab.research.google.com/>
- Google AI. (2018). BERT [Modelo de lenguaje contextual bidireccional]. Recuperado de <https://github.com/google-research/bert>
- Google AI. (2023). Gemini [Modelo de lenguaje]. Recuperado de <https://gemini.google.com/app>
- Gobierno de España. (2020). Ley Orgánica 3/2020, de 29 de diciembre, por la que se modifica la Ley Orgánica 2/2006, de 3 de mayo, de Educación. *Boletín Oficial del Estado*, 340, de 30 de diciembre de 2020. <https://www.boe.es/eli/es/lo/2020/12/29/3>
- Gooru Labs. (2014). Gooru Navigator [Plataforma de aprendizaje adaptativo]. Recuperado de <https://goorulearning.com/navigator/>
- Holmes, W., Bialik, M., & Fadel, C. (2023). Artificial intelligence in education. *Data Ethics: Building Trust: How Digital Technologies Can Serve Humanity*, 621–653. <https://doi.org/10.58863/20.500.12424/4276068>
- Holmes, W., & Tuomi, I. (2022). State of the art and practice in AI in education. *European Journal of Education*, 57(4), 542–570. <https://doi.org/10.1111/EJED.12533>



- Hwang, G. J., Xie, H., Wah, B. W., & Gašević, D. (2020). Vision, challenges, roles and research issues of Artificial Intelligence in Education. *Computers and Education: Artificial Intelligence*, 1, 100001. <https://doi.org/10.1016/J.CAEAI.2020.100001>
- Jang, J., Jeon, J., & Jung, S. K. (2022). Development of STEM-Based AI Education Program for Sustainable Improvement of Elementary Learners. *Sustainability*, 14(22), 15178. <https://doi.org/10.3390/SU142215178>
- Jia, F., Sun, D., & Looi, C. K. (2024). Artificial Intelligence in Science Education (2013–2023): Research Trends in Ten Years. *Journal of Science Education and Technology*, 33(1), 94–117. <https://doi.org/10.1007/S10956-023-10077-6>
- MathWorks. (1984). MATLAB [Software de cálculo técnico]. Recuperado de <https://www.mathworks.com/products/matlab.html>
- Microsoft. (2020). MarianMT [Sistema de traducción neuronal]. Recuperado de <https://marian-nmt.github.io/>
- Microsoft Research. (2020). DialoGPT [Modelo de generación de lenguaje para diálogos]. Recuperado de <https://github.com/microsoft/DialoGPT>
- Midjourney. (2022). Midjourney [Plataforma de aprendizaje adaptativo]. Recuperado de <https://www.midjourney.com/>
- Morduchowicz, R. (2023). Documento de programa o de reunión [Documento en línea]. UNESCO Office Montevideo and Regional Bureau for Science in Latin America and the Caribbean. Recuperado de <https://unesdoc.unesco.org/ark:/48223/pf0000386262>
- Menikrama, M. R. L. Y., Liyanagunawardhana, C. S., Amarasekara, H. G. D. M. I., Ramasinghe, M. S., Weerasinghe, L., & Weerasinghe, I. (2021). ARChem: Augmented Reality Chemistry Lab. En *2021 IEEE 12th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)* (pp. 0276-0280). IEEE. <https://doi.org/10.1109/IEMCON53756.2021.9623121>
- Miao, F., & Holmes, W. (2023). Guidance for generative AI in education and research (44 pages). <https://doi.org/10.54675/EWZM9535>
- OpenAI. (2020). GPT-3 [Generative Pre-trained Transformer 3]. Recuperado de <https://openai.com/>



- OpenAI. (2024). DALL-E 3 [Modelo de generación de imágenes]. Recuperado de <https://openai.com/dall-e-3/>
- Python Software Foundation. (2020). Python 3.9.2 [Lenguaje de programación]. Recuperado de <https://www.python.org/>
- Runway ML, Inc. (2020). Runway ML [Plataforma de aprendizaje automático]. Recuperado de <https://runwayml.com/>
- Suk, H. I. (2017). An Introduction to Neural Networks and Deep Learning. Deep Learning for Medical Image Analysis, 3–24. <https://doi.org/10.1016/B978-0-12-810408-8.00002-X>
- Turnitin. (2022). *Turnitin* [Sistema de detección de plagio]. Recuperado de <https://www.turnitin.com/>
- Uriarte Portillo, Aldo & Zatarain Cabada, Ramón & Barron Estrada, Maria & Ibáñez, María. (2021). ReAQ: [An Intelligent Tutoring System with Augmented Reality Technology Focused on Chemistry]. Recuperado de https://rcs.cic.ipn.mx/2020_149_12/ReAQ_%20An%20Intelligent%20Tutoring%20System%20with%20Augmented%20Reality%20Technology%20Focused%20on%20Chemistry.pdf
- Wolfram Research. (2009). Wolfram Alpha [Motor de conocimiento computacional]. Recuperado de <https://www.wolframalpha.com/>
- Xu, W., & Ouyang, F. (2022). The application of AI technologies in STEM education: a systematic review from 2011 to 2021. *International Journal of STEM Education*, 9(1), 1–20. <https://doi.org/10.1186/S40594-022-00377-5>
- Yew, E. H. J., & Goh, K. (2016). Problem-Based Learning: An Overview of its Process and Impact on Learning. *Health Professions Education*, 2(2), 75–79. <https://doi.org/10.1016/j.hpe.2016.01.004>

7. Anexos

7.1 Glosario de términos y siglas

Término	Siglas / Abreviatura	Definición
Inteligencia artificial	AI	Diseño de máquinas o sistemas que imitan funciones cognitivas propias de las personas
Inteligencia artificial generativa	AI Gen	Tecnología de AI capaz de generar contenidos de forma automática en respuesta a instrucciones escritas
Prompt		Instrucciones escritas en interfaces conversacionales de lenguaje natural
Machine learning	ML	Técnicas para mejorar desempeño de máquinas a través del análisis de datos
Deep learning	DL	<i>conjunto de algoritmos de aprendizaje automático que intenta modelar abstracciones de alto nivel</i>
Large language model	LLM	<i>Modelo de transformador que es entrenado enormes grandes cantidades de datos</i>
Backpropagation o Retropropagación		Algoritmo para entrenar redes neuronales con el objetivo de minimizar los errores en el proceso de machine learning
Convolutional neural network o Red convolucional	CNN	Red neuronal artificial donde las neuronas, corresponden a campos receptivos de una manera muy similar a las neuronas en la corteza visual primaria de un cerebro biológico
Redes generativas antagónicas o Generative antagonic network	GAN	<i>Conjunto de redes que compiten entre sí, unas generando y otras verificando. Se entrenan para generar resultados más auténticos</i>
Graphics processing unit	GPU	Tarjeta gráfica o de video
Intelligent tutoring system o sistema de tutoría inteligente	ITS	Sistema de software que utiliza técnicas de inteligencia artificial (IA) para apoyar el aprendizaje
Science, Technology, Engineering and Maths	STEM	Acrónimo del inglés para referirse a disciplinas del ámbito científico
Cloud computing o computación en nube		Acceso remoto a recursos de computación por internet
Navigated learning o aprendizaje navegado		Aprendizaje asistido por software que reacciona en función de los datos de los estudiantes
Data Science o Análisis de datos		Campo que usa estadística, métodos, algoritmos y sistemas científicos para obtener, tratar, analizar y presentar informes a partir de datos ruidosos
Augmented Reality o Realidad Aumentada	AR	Versión interactiva de un entorno real lograda a través de elementos visuales digitales, sonidos y otros estímulos sensoriales mediante tecnología holográfica.
Perceptron		Red neuronal feed forward pionera en el desarrollo de la inteligencia artificial



7.2 Prompts y respuestas reales obtenidas correspondientes al desarrollo de la propuesta didáctica.

Aclaración profiláctica ante el incurrimento en fraude o plagio:

El contenido de este anexo está generado por inteligencia artificial.

Las siguientes respuestas se obtuvieron con el acceso gratuito a la plataforma de ChatGPT, en mayo de 2024. Los gráficos obtenidos en las figuras 5 y 6 mostradas en la propuesta didáctica fueron el resultado de compilar sin modificación alguna las líneas de código proporcionadas por el LLM. El material se adjunta como texto debido al gran volumen de las respuestas.

Prompt 1: “Haz una lista con las técnicas más empleadas para el análisis in vitro del contenido de mercurio en alimentos”

Respuesta 1: “Aquí tienes una lista de algunas técnicas comunes utilizadas para el análisis in vitro del contenido de mercurio en alimentos:

1. *Espectrometría de Absorción Atómica (AAS): Esta técnica mide la absorción de radiación por átomos de mercurio en una muestra después de la vaporización del mercurio en un horno de cuarzo.*

2. *Espectrometría de Emisión Atómica (AES): Se utiliza para medir la cantidad de mercurio presente en una muestra mediante la medición de la emisión de radiación electromagnética característica de los átomos de mercurio.*

3. *Espectrometría de Masas con Plasma Acoplado Inductivamente (ICP-MS): Esta técnica permite la detección y cuantificación precisa de mercurio mediante la ionización de la muestra en un plasma acoplado inductivamente y la medición de la masa de los iones resultantes.*

4. *Voltametría de Mercurio en Gotas de Mercurio (HMDE): En esta técnica, se utiliza una gota de mercurio como electrodo de trabajo para determinar el contenido de mercurio en una muestra mediante la medición de la corriente eléctrica generada.*

5. *Espectroscopía de Fluorescencia de Rayos X (XRF): Esta técnica analiza la fluorescencia de rayos X emitida por una muestra cuando se bombardea con rayos X de alta energía, lo que permite determinar la concentración de mercurio y otros elementos presentes.*

6. *Cromatografía de Gases (GC) con Detector de Captura de Electrones (ECD): Se utiliza para separar y cuantificar los compuestos orgánicos de mercurio en una muestra después de su extracción, utilizando un detector de captura de electrones para la detección específica del mercurio.*



7. *Espectroscopía de Absorción Molecular (MAS): Esta técnica mide la absorción de luz por complejos de mercurio formados en una muestra, lo que permite determinar la cantidad de mercurio presente.*

Estas son algunas de las técnicas más comunes utilizadas en el análisis in vitro del contenido de mercurio en alimentos, cada una con sus ventajas y limitaciones dependiendo de la naturaleza de la muestra y la precisión requerida en la medición.”

Prompt 2: “Me gustaría conocer el fenómeno de absorción y específicamente la ley de Lambert – Beer”

Respuesta 2: “¡Claro! El fenómeno de absorción es un proceso en el cual la energía de una radiación electromagnética es absorbida por la materia. Esto puede ocurrir en diversas formas, como la absorción de luz visible por un pigmento en una pintura, la absorción de rayos X por un material radiográfico en medicina, o la absorción de luz ultravioleta por una molécula en espectroscopía.

La ley de Lambert-Beer, también conocida como ley de Beer-Lambert o simplemente ley de Beer, es una relación empírica que describe la atenuación de la luz (o radiación electromagnética) que atraviesa un medio absorbente, como una solución. Esta ley establece que la absorbancia (A) de una solución es directamente proporcional a la concentración (c) del soluto y a la longitud del camino recorrido por la luz (l) a través del medio. Matemáticamente, la ley de Lambert-Beer se expresa de la siguiente manera:

$$A = \epsilon \cdot l \cdot c$$

Donde:

A es la absorbancia, una medida adimensional de la cantidad de luz absorbida por la solución.

ϵ es el coeficiente de absorción molar (también conocido como coeficiente de extinción molar), que es una constante característica de cada sustancia y depende de la longitud de onda de la radiación.

l es la longitud del camino óptico, es decir, la distancia que recorre la luz a través del medio absorbente.

c es la concentración de la sustancia absorbente en la solución, generalmente expresada en mol/L.

Esta ley es útil en espectroscopía para determinar la concentración de una sustancia en una muestra mediante la medición de la absorbancia de la luz que pasa a través de ella. Se utiliza comúnmente en química analítica y bioquímica para cuantificar la concentración de solutos en soluciones, así como en otros campos como la espectroscopía UV-visible.



Prompt 3: “Exponme un ejemplo de procedimiento de calibrado y análisis para la determinación de mercurio en una muestra de atún.”

Respuesta 3: “Aquí tienes un ejemplo de procedimiento de calibrado y análisis para la determinación de mercurio en una muestra de atún utilizando espectrometría de absorción atómica (AAS), una de las técnicas comunes para este propósito:

Procedimiento de Calibrado:

Preparación de las soluciones estándar:

Preparar soluciones estándar de mercurio de concentraciones conocidas, por ejemplo, 1, 5, 10, 25, 50 ppb (partes por mil millones). Estas soluciones se pueden obtener diluyendo una solución stock de mercurio de concentración conocida.

Preparación de las muestras:

Preparar las muestras de atún siguiendo un protocolo establecido. Esto puede incluir la digestión de la muestra para liberar el mercurio presente en una forma que sea adecuada para su análisis.

Calibración del equipo:

Calibrar el espectrómetro de absorción atómica utilizando las soluciones estándar preparadas. Medir la absorbancia de cada solución estándar a la longitud de onda específica del mercurio.

Construcción de la curva de calibración:

Graficar los valores de absorbancia versus la concentración de mercurio de las soluciones estándar. Ajustar una línea de mejor ajuste a los puntos de datos para obtener una curva de calibración.

Procedimiento de Análisis:

Preparación de las muestras:

Preparar las muestras de atún para el análisis de mercurio. Esto puede implicar la digestión de la muestra y la dilución adecuada para ajustarse al rango de concentración lineal de la curva de calibración.

Medición de la absorbancia:

Medir la absorbancia de las muestras de atún digeridas a la longitud de onda específica del mercurio utilizando el espectrómetro de absorción atómica.

Determinación de la concentración:

Utilizando la curva de calibración previamente construida, determinar la concentración de mercurio en las muestras de atún a partir de sus valores de absorbancia.

Control de calidad:

Realizar controles de calidad, como la replicación de muestras y el análisis de materiales de referencia, para garantizar la precisión y la exactitud de los resultados.

Interpretación de los resultados:

Informar los resultados de la concentración de mercurio en las muestras de atún, asegurando que estén dentro de los límites establecidos por las regulaciones de seguridad alimentaria.

Este procedimiento proporciona una forma sistemática y precisa de determinar el contenido de mercurio en muestras de atún utilizando espectrometría de absorción atómica, lo que es crucial para garantizar la seguridad alimentaria y cumplir con las regulaciones ambientales. Es importante seguir los protocolos establecidos y realizar controles de calidad adecuados para obtener resultados confiables y precisos.”

Figura 7. Captura de pantalla donde se muestra cómo se accede a la información de la concentración de mercurio típica en una muestra de atún usando el buscador de Google (Google, 1998)



En función de lo que se encuentre en una búsqueda rápida se ajustan las concentraciones de los estándares en la simulación.



Prompt 4: “Me gustaría que me detallaras como encontrar la longitud de onda apropiada para medir”

Respuesta 4: “Para encontrar la longitud de onda apropiada para medir la concentración de mercurio en una muestra utilizando espectrofotometría de absorción atómica (AAS), se siguen varios pasos:

Conocer las características del mercurio: Es importante conocer las propiedades del mercurio, incluyendo su espectro de absorción. El mercurio tiene varias líneas de absorción características en el rango ultravioleta-visible (UV-Vis), siendo la más común la línea de absorción en 253.7 nm.

Consultar la literatura: La longitud de onda más comúnmente utilizada para la determinación de mercurio en AAS es 253.7 nm. Sin embargo, dependiendo del equipo específico y las condiciones de la muestra, podría ser necesario ajustar esta longitud de onda. La literatura científica y los manuales de equipos proporcionan información sobre las longitudes de onda recomendadas para diferentes análisis.

Realizar un barrido espectral: Si no se está seguro de la longitud de onda óptima, se puede realizar un barrido espectral en el rango de interés (generalmente entre 200 nm y 600 nm) utilizando una solución estándar de mercurio. Se mide la absorbancia de la solución estándar en diferentes longitudes de onda y se observa el pico de absorbancia más pronunciado.

Seleccionar la longitud de onda máxima de absorbancia: Después de realizar el barrido espectral, se selecciona la longitud de onda en la que se observe la mayor absorbancia para el mercurio. Esta será la longitud de onda óptima para medir la concentración de mercurio en la muestra.

Realizar ajustes finos: Si es necesario, se pueden realizar ajustes finos en la longitud de onda seleccionada para optimizar la sensibilidad y la precisión del análisis. Esto se puede hacer variando ligeramente la longitud de onda y observando cómo afecta la señal medida.

Una vez que se ha seleccionado la longitud de onda apropiada, se puede proceder con el análisis de las muestras de acuerdo con el procedimiento establecido, utilizando esta longitud de onda para medir la absorbancia y determinar la concentración de mercurio en la muestra. Es importante recordar que la selección adecuada de la longitud de onda es fundamental para obtener resultados precisos y confiables en el análisis de mercurio por AAS.”



Prompt 5: “Pretendo simular los datos de un experimento que consiste en medir la cantidad de mercurio en un trozo de atún mediante espectrometría de absorción atómica en llama. Necesito que me generes una tabla con datos que pasen por ser experimentales de una recta de calibrado del espectrómetro. Usa estándares de calibrado que oscilen entre 0 y 1 ppm de mercurio en intervalos de 0,1 ppm y genera los valores de Absorbancia que tengan un determinado ruido que los haga asemejarse a datos obtenidos experimentalmente.”

Respuesta 5: “Para simular datos experimentales de una recta de calibrado de un espectrómetro, podemos utilizar Python para generar valores de concentración de mercurio (en ppm) y sus correspondientes valores de absorbancia, con la adición de ruido para simular la variabilidad experimental. Vamos a utilizar librerías como NumPy y matplotlib para generar los datos y graficar la recta de calibrado. Asumiremos una relación lineal entre la concentración de mercurio y la absorbancia.

Aquí tienes un ejemplo de cómo hacer esto:

```
import numpy as np
import matplotlib.pyplot as plt

# Establecer parámetros de la recta de calibrado
# Concentraciones de estándares de calibración en ppm (de 0 a 1 en intervalos de 0.1)
concentraciones = np.arange(0, 1.1, 0.1)

# Parámetros de la recta de calibrado (simulación)
pendiente = 0.8 # Pendiente de la recta de calibrado
intercepto = 0.1 # Intercepto de la recta de calibrado

# Simulación de la relación lineal entre concentración y absorbancia
absorbancia_sin_ruido = pendiente * concentraciones + intercepto

# Agregar ruido gaussiano para simular variabilidad experimental
desviacion_estandar_ruido = 0.03 # Desviación estándar del ruido (simular variabilidad)
ruido = np.random.normal(0, desviacion_estandar_ruido, len(concentraciones))
absorbancia_con_ruido = absorbancia_sin_ruido + ruido

# Graficar la recta de calibrado
plt.figure(figsize=(8, 6))
plt.scatter(concentraciones, absorbancia_con_ruido, color='b', label='Datos experimentales con ruido')
plt.plot(concentraciones, absorbancia_sin_ruido, color='r', label='Recta de calibrado ideal')
plt.xlabel('Concentración de Mercurio (ppm)')
plt.ylabel('Absorbancia')
```



```
plt.title('Recta de Calibrado del Espectrómetro')  
plt.legend()  
plt.grid(True)  
plt.show()
```

En este código:

concentraciones representa las concentraciones de mercurio en ppm de los estándares de calibración que van de 0 a 1 en intervalos de 0.1.

pendiente y *intercepto* son parámetros de la recta de calibrado simulada.

absorbancia_sin_ruido calcula los valores teóricos de absorbancia basados en la relación lineal.

ruido es un ruido gaussiano que se agrega a los valores de absorbancia para simular la variabilidad experimental.

absorbancia_con_ruido son los valores de absorbancia con el ruido agregado.

Finalmente, se grafican los datos experimentales simulados (*absorbancia_con_ruido*) junto con la recta de calibrado ideal (*absorbancia_sin_ruido*).

Puedes ajustar los parámetros como la pendiente, el intercepto y la desviación estándar del ruido para ajustar la simulación a tus necesidades experimentales.

Esta aproximación te permitirá generar datos que asemejen una recta de calibrado típica obtenida mediante espectrometría de absorción atómica en llama.

Prompt 6: “ahora realiza un ajuste de regresión lineal por mínimos cuadrados con los datos de la tabla y representa el gráfico de dispersión que contenga la ecuación de la recta de regresión”.

Respuesta 6: “Para realizar un ajuste de regresión lineal por mínimos cuadrados con los datos de la tabla y representar el gráfico de dispersión que incluya la ecuación de la recta de regresión, podemos utilizar la librería *scikit-learn* en Python para realizar el ajuste y *matplotlib* para graficar los resultados. A continuación, te muestro cómo hacerlo:

```
import numpy as np  
import pandas as pd  
from sklearn.linear_model import LinearRegression  
import matplotlib.pyplot as plt  
# Datos de la tabla (simulados)  
data = {  
    'Concentración de Mercurio (ppm)': np.array([0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6,  
0.7, 0.8, 0.9, 1.0]),  
    'Absorbancia': np.array([0.0983, 0.1966, 0.3581, 0.4343, 0.5282, 0.6065,  
0.6893, 0.7760, 0.8522, 0.9294, 1.0331])  
}  
  
df = pd.DataFrame(data)
```



```
# Extraer las variables independiente (X) y dependiente (y)
X = df['Concentración de Mercurio (ppm)'].values.reshape(-1, 1) # Convertir a
matriz columna
y = df['Absorbancia'].values

# Crear el modelo de regresión lineal
model = LinearRegression()
model.fit(X, y)

# Obtener los coeficientes de la recta de regresión
pendiente = model.coef_[0]
intercepto = model.intercept_

# Predicción de absorbancia para los datos originales
y_pred = model.predict(X)

# Graficar los datos de dispersión y la recta de regresión
plt.figure(figsize=(8, 6))
plt.scatter(X, y, color='b', label='Datos experimentales con ruido')
plt.plot(X, y_pred, color='r', label=f'Recta de regresión: y = {pendiente:.4f}x +
{intercepto:.4f}')
plt.xlabel('Concentración de Mercurio (ppm)')
plt.ylabel('Absorbancia')
plt.title('Ajuste de Regresión Lineal por Mínimos Cuadrados')
plt.legend()
plt.grid(True)
plt.show()

# Mostrar la ecuación de la recta de regresión
print(f"Ecuación de la recta de regresión: y = {pendiente:.4f}x + {intercepto:.4f}")
```

En este código:

Se extraen las variables independiente (X) y dependiente (y) a partir de los datos de la tabla.

Se crea un modelo de regresión lineal utilizando LinearRegression de scikit-learn y se ajusta a los datos (X, y).

Se obtienen los coeficientes de la recta de regresión (pendiente y intercepto).

Se realiza una predicción de la absorbancia (y_pred) utilizando el modelo ajustado.

Se grafican los datos de dispersión junto con la recta de regresión.

Se muestra la ecuación de la recta de regresión en la leyenda del gráfico y también se imprime en la consola.

Este código te permitirá visualizar el ajuste de regresión lineal sobre los datos de absorbancia en función de la concentración de mercurio, junto con la ecuación de la recta de regresión. Los coeficientes de la recta (pendiente y intercepto) te

indicarán la relación lineal entre la concentración de mercurio y la absorbancia estimada por el modelo de regresión.

