



REPÚBLICA DE PANAMÁ

MINISTERIO DE EDUCACIÓN

INSTITUTO SUPERIOR TECNOLÓGICO DEL CLAUSTRO GÓMEZ

**TRABAJO FINAL DE INVESTIGACIÓN PARA OPTAR POR EL TÍTULO DE
TÉCNICO SUPERIOR EN PROGRAMACIÓN EN INFORMÁTICA**

**DESARROLLO DE UN SISTEMA DE RECOMENDACIÓN BASADO EN
ALGORITMOS DE INTELIGENCIA ARTIFICIAL**

ELABORADO POR: JOSÉ CARLOS PATIÑO - 8-712-1779

Julio 2024

Índice

I.	RESUMEN	3
II.	INTRODUCCIÓN	4
III.	JUSTIFICACIÓN	6
IV.	OBJETIVOS	7
V.	MARCO TEÓRICO	8
VI.	METODOLOGÍA	9
VII.	DESARROLLO O CUERPO DEL TRABAJO.....	11
VIII.	CONCLUSIÓN	12
IX.	RECOMENDACIONES.....	14
X.	BIBLIOGRAFÍA	15

I. RESUMEN

Esta tesina se centra en el desarrollo de un sistema de recomendación basado en algoritmos de inteligencia artificial (IA), con el objetivo de crear una solución que ofrezca recomendaciones personalizadas y precisas en plataformas digitales. Los sistemas de recomendación se han vuelto fundamentales en la mejora de la experiencia del usuario, ya que permiten ofrecer sugerencias que se alinean con los intereses y comportamientos previos del usuario. A través de este trabajo, se busca investigar y desarrollar un sistema eficiente que pueda generar recomendaciones personalizadas utilizando técnicas de inteligencia artificial, como el filtrado colaborativo, el filtrado basado en contenido y modelos híbridos que combinen ambos enfoques.

La investigación se basa en la aplicación de diferentes algoritmos de recomendación y su evaluación en un conjunto de datos adecuado, buscando optimizar la precisión y relevancia de las recomendaciones generadas. Se utilizaron varias técnicas de IA, como la regularización, la validación cruzada y el ajuste de hiperparámetros, para mejorar los resultados de los modelos. Además, se identificaron y abordaron los principales problemas comunes en los sistemas de recomendación, como el sobreajuste o la escasez de datos, a través de la implementación de estrategias innovadoras y el uso de modelos avanzados de aprendizaje automático. El sistema se desarrolló en un entorno de programación flexible y escalable, utilizando lenguajes como Python y librerías de machine learning como Scikit-learn, TensorFlow y Keras.

El trabajo se dividió en varias etapas, que incluyeron la revisión de la literatura existente sobre sistemas de recomendación, la selección de los algoritmos a utilizar, la preparación de los datos y el desarrollo del sistema en sí. Durante el proceso, se entrenaron diferentes modelos utilizando un conjunto de datos específico, evaluando su desempeño mediante métricas como la precisión, el recall y el error cuadrático medio (RMSE). Los resultados mostraron que los modelos híbridos, que combinan técnicas de filtrado colaborativo y basado en contenido, obtuvieron un rendimiento superior en términos de precisión y relevancia de las recomendaciones.

El sistema de recomendación desarrollado en esta tesina se evaluó mediante pruebas con usuarios reales, lo que permitió comprobar su efectividad en la entrega de recomendaciones personalizadas y en la mejora de la interacción del usuario con la plataforma. Se identificaron áreas de mejora, como la capacidad del sistema para adaptarse a nuevos datos y la optimización continua del modelo en función de las interacciones del usuario. A lo largo de la investigación, se subrayó la importancia de un enfoque iterativo y flexible en el desarrollo de sistemas de recomendación, así como la necesidad de aplicar técnicas de IA para hacer frente a desafíos como la escasez de datos y el sobreajuste.

En conclusión, el desarrollo de sistemas de recomendación basados en inteligencia artificial tiene un gran potencial para mejorar la experiencia del usuario en diversas plataformas digitales. La aplicación de técnicas de optimización, como el ajuste de hiperparámetros y la validación cruzada, resultó fundamental para obtener recomendaciones más precisas y relevantes. Los modelos híbridos demostraron ser la opción más efectiva para generar recomendaciones personalizadas, adaptándose a las necesidades y preferencias de los usuarios. Este trabajo muestra que los sistemas de recomendación basados en IA no solo son viables, sino que pueden ser herramientas poderosas en la personalización de servicios en áreas como el comercio electrónico, las plataformas de entretenimiento y la educación en línea. El futuro de estos sistemas depende de la capacidad de mejorar continuamente sus algoritmos y adaptarlos a nuevas tendencias y tecnologías emergentes.

II. INTRODUCCIÓN

El desarrollo de sistemas de recomendación basados en algoritmos de inteligencia artificial es un área de investigación de gran relevancia en la actualidad. Estos sistemas se han convertido en una parte fundamental de múltiples plataformas digitales, como servicios de streaming, comercio electrónico, redes sociales y bibliotecas digitales. Su principal función es analizar grandes volúmenes de datos para ofrecer a los usuarios sugerencias personalizadas, mejorando así su experiencia y optimizando la toma de decisiones.

El avance de la inteligencia artificial ha permitido el desarrollo de modelos más sofisticados para la personalización de contenidos. En este contexto, los sistemas de recomendación emplean diferentes enfoques, como el filtrado colaborativo, el filtrado basado en contenido y los modelos híbridos. Estos métodos permiten identificar patrones en los datos de los usuarios y generar predicciones sobre sus preferencias futuras. Sin embargo, cada uno de estos enfoques presenta desafíos, como la escasez de datos en nuevos usuarios (problema de "arranque en frío"), la necesidad de grandes volúmenes de información y la interpretación de los resultados generados por los algoritmos.

El presente estudio se centra en la investigación y desarrollo de un sistema de recomendación basado en inteligencia artificial que optimice la precisión de las sugerencias mediante modelos híbridos avanzados. A través de la implementación y evaluación de distintos algoritmos, se busca identificar cuáles ofrecen un mejor desempeño en términos de personalización, eficiencia computacional y satisfacción del usuario. Este estudio no solo contribuye a la mejora de las experiencias digitales, sino que también aporta conocimientos fundamentales para la aplicación de la inteligencia artificial en otros ámbitos, como la educación, la salud y la gestión del conocimiento.

Además del análisis cuantitativo, se consideró la interpretación de los resultados obtenidos a través de herramientas de visualización de datos, lo que permitió una mejor comprensión del comportamiento de los algoritmos de recomendación en distintos escenarios. Se utilizaron gráficos y representaciones estadísticas para identificar tendencias, patrones de uso y posibles sesgos en los datos, lo que facilitó la optimización del modelo propuesto. Asimismo, se compararon los resultados con estudios previos en el campo de los sistemas de recomendación, lo que permitió contextualizar los hallazgos dentro del estado actual de la investigación en inteligencia artificial aplicada a la personalización de contenidos.

Finalmente, con base en los resultados obtenidos, se plantearon mejoras en la implementación del sistema de recomendación, explorando la integración de técnicas avanzadas como modelos de deep learning y redes neuronales. Se propuso la posibilidad de utilizar embeddings generados por modelos de procesamiento del lenguaje natural (NLP)

para mejorar la comprensión del contenido y ofrecer recomendaciones más precisas. Además, se discutió la importancia de la interpretabilidad de los modelos, ya que la opacidad de algunos algoritmos basados en IA puede representar un desafío en términos de confianza y transparencia para los usuarios. Estos aspectos fueron considerados como líneas de investigación futuras, con el objetivo de seguir optimizando los sistemas de recomendación y su aplicación en diferentes sectores.

III. JUSTIFICACIÓN

Los sistemas de recomendación son una pieza clave en la era digital, donde el acceso masivo a la información y la personalización de contenidos han transformado la forma en que los usuarios interactúan con diversas plataformas. La cantidad de datos generados diariamente en internet es abrumadora, y sin herramientas efectivas para filtrar y priorizar la información relevante, los usuarios pueden experimentar una sobrecarga cognitiva que dificulta su experiencia de navegación y toma de decisiones.

Desde una perspectiva comercial, las empresas que implementan sistemas de recomendación eficientes logran aumentar la retención y satisfacción del usuario, lo que se traduce en un incremento en la fidelización y en las ventas. Servicios como Netflix, Spotify, Amazon y YouTube dependen en gran medida de estos sistemas para ofrecer contenido altamente relevante a sus usuarios, mejorando así su competitividad en el mercado. Sin embargo, la calidad y efectividad de los sistemas de recomendación aún representan un desafío, ya que los modelos tradicionales pueden generar resultados poco precisos o sesgados, lo que limita su aplicabilidad en contextos más amplios.

Desde un punto de vista tecnológico, la inteligencia artificial ha demostrado ser una herramienta poderosa para optimizar los sistemas de recomendación, permitiendo el desarrollo de algoritmos más robustos y adaptables. No obstante, la implementación de estos sistemas conlleva retos importantes, como la necesidad de grandes volúmenes de datos, el consumo computacional elevado y la dificultad de explicar las decisiones tomadas por los modelos de aprendizaje automático. Por ello, este estudio es relevante, ya que busca superar estas limitaciones mediante la exploración de modelos híbridos avanzados que

combinan diferentes enfoques de recomendación para obtener un rendimiento más preciso y eficiente.

Además, la importancia de los sistemas de recomendación va más allá del ámbito comercial. En sectores como la educación y la salud, estos sistemas pueden utilizarse para personalizar el aprendizaje de los estudiantes, recomendar materiales académicos o sugerir tratamientos médicos basados en datos previos. En este sentido, los avances en este campo no solo benefician a empresas y usuarios individuales, sino que también tienen un impacto significativo en la sociedad en su conjunto.

IV. OBJETIVOS

- **General**

- Desarrollar un sistema de recomendación basado en algoritmos de inteligencia artificial que optimice la precisión y relevancia de las sugerencias mediante la implementación de modelos híbridos avanzados, mejorando la personalización y la experiencia del usuario.

- **Específicos**

- Investigar y analizar los diferentes enfoques de sistemas de recomendación utilizados en la actualidad, incluyendo el filtrado colaborativo, el filtrado basado en contenido y los modelos híbridos, para identificar sus fortalezas y debilidades.
- Diseñar e implementar un modelo de recomendación híbrido que combine técnicas de filtrado colaborativo y basado en contenido, integrando algoritmos avanzados de inteligencia artificial para mejorar la calidad de las recomendaciones.
- Evaluar el rendimiento del sistema de recomendación desarrollado utilizando métricas estándar como precisión, recall y error cuadrático medio (RMSE), con el fin de determinar su eficacia en comparación con enfoques tradicionales.

V. MARCO TEÓRICO

El concepto de sistemas de recomendación ha evolucionado significativamente en las últimas décadas, convirtiéndose en una herramienta esencial para la personalización de contenidos en plataformas digitales. Estos sistemas utilizan algoritmos de inteligencia artificial para predecir las preferencias de los usuarios y ofrecer recomendaciones personalizadas, basadas en el análisis de su comportamiento y las interacciones pasadas. Existen diferentes enfoques para el desarrollo de sistemas de recomendación, siendo los más destacados el filtrado colaborativo, el filtrado basado en contenido y los modelos híbridos que combinan ambos. El filtrado colaborativo se basa en la idea de que los usuarios que han mostrado preferencias similares en el pasado también compartirán gustos en el futuro, mientras que el filtrado basado en contenido utiliza las características de los ítems para hacer recomendaciones. Los sistemas híbridos, por su parte, intentan superar las limitaciones de los dos enfoques anteriores combinándolos de manera eficiente para mejorar la precisión de las recomendaciones.

La literatura sobre sistemas de recomendación abarca una amplia gama de estudios, desde los primeros enfoques de filtrado colaborativo hasta los avances actuales que integran técnicas de aprendizaje automático y redes neuronales profundas. En su trabajo, Ricci et al. (2015) destacan la importancia de la personalización en la experiencia del usuario y exploran cómo los sistemas de recomendación pueden ser utilizados en diversos contextos, desde el comercio electrónico hasta las plataformas de entretenimiento. Por otro lado, Shani y Gunawardana (2011) proporcionan una revisión exhaustiva de los algoritmos más utilizados en sistemas de recomendación, analizando su rendimiento y eficiencia. Estos estudios señalan los desafíos que enfrentan estos sistemas, como el sobreajuste, la escasez de datos y la necesidad de modelos más dinámicos que se adapten a las nuevas interacciones de los usuarios.

En términos teóricos, el marco de las "redes neuronales profundas" ha revolucionado la manera en que se desarrollan los sistemas de recomendación. Estas redes, inspiradas en el funcionamiento del cerebro humano, permiten a los sistemas aprender patrones complejos a

partir de grandes volúmenes de datos, mejorando la capacidad de personalización. Modelos como el "Deep Collaborative Filtering" (Hidasi et al., 2015) y "Neural Collaborative Filtering" (He et al., 2017) han demostrado una mejora significativa en la precisión de las recomendaciones, superando las limitaciones de los métodos tradicionales. Estos avances se enmarcan dentro de la tendencia hacia el uso de técnicas de aprendizaje profundo y redes neuronales en el ámbito de los sistemas de recomendación, proporcionando un camino hacia soluciones más robustas y efectivas.

VI. METODOLOGÍA

La investigación realizada en esta tesina se enmarca dentro de un enfoque cuantitativo, ya que se busca desarrollar, implementar y evaluar un sistema de recomendación utilizando algoritmos de inteligencia artificial. La naturaleza del estudio está dirigida a la recolección de datos numéricos, específicamente relacionados con la precisión y el rendimiento de los modelos de recomendación aplicados. A través de la medición objetiva de parámetros como la precisión, el recall y el error cuadrático medio (RMSE), se pretende cuantificar el desempeño de los algoritmos y generar conclusiones que puedan ser generalizadas y aplicables a otros contextos. Este enfoque permite no solo evaluar la efectividad del sistema propuesto, sino también aportar datos valiosos sobre la optimización de sistemas de recomendación en plataformas digitales.

Para la recopilación de datos, se recurrió a fuentes de datos públicas relacionadas con plataformas de comercio electrónico y servicios de entretenimiento, como MovieLens o Amazon. Estos conjuntos de datos contienen información relevante sobre las interacciones previas de los usuarios, tales como valoraciones, compras o visualizaciones, que se utilizan para entrenar y evaluar los modelos. Se emplearon técnicas de análisis documental, con el objetivo de seleccionar las bases de datos más adecuadas para el tipo de sistema de recomendación que se quería desarrollar. Además, se aplicaron procesos de preprocesamiento de datos, como la limpieza y normalización, para asegurarse de que los datos fueran consistentes y aptos para su uso en el entrenamiento de los algoritmos.

Una vez recopilados y procesados los datos, se implementaron diversos algoritmos de recomendación, incluidos el filtrado colaborativo, el filtrado basado en contenido y los modelos híbridos. Para evaluar el rendimiento de los modelos, se utilizaron métodos estadísticos y herramientas de machine learning, como Scikit-learn y TensorFlow, que permitieron entrenar y probar los algoritmos con los datos recopilados. Se realizó una validación cruzada para asegurar la robustez de los modelos y evitar el sobreajuste, y se llevaron a cabo ajustes de hiperparámetros para mejorar la precisión de las recomendaciones. A través de la comparación de los resultados obtenidos con cada uno de los métodos aplicados, se evaluaron las métricas estándar, lo que permitió identificar el modelo más adecuado para ofrecer recomendaciones personalizadas de manera eficiente.

Además del análisis cuantitativo, se consideró la interpretación de los resultados obtenidos a través de herramientas de visualización de datos, lo que permitió una mejor comprensión del comportamiento de los algoritmos de recomendación en distintos escenarios. Se utilizaron gráficos y representaciones estadísticas para identificar tendencias, patrones de uso y posibles sesgos en los datos, lo que facilitó la optimización del modelo propuesto. Asimismo, se compararon los resultados con estudios previos en el campo de los sistemas de recomendación, lo que permitió contextualizar los hallazgos dentro del estado actual de la investigación en inteligencia artificial aplicada a la personalización de contenidos.

Finalmente, con base en los resultados obtenidos, se plantearon mejoras en la implementación del sistema de recomendación, explorando la integración de técnicas avanzadas como modelos de deep learning y redes neuronales. Se propuso la posibilidad de utilizar embeddings generados por modelos de procesamiento del lenguaje natural (NLP) para mejorar la comprensión del contenido y ofrecer recomendaciones más precisas. Además, se discutió la importancia de la interpretabilidad de los modelos, ya que la opacidad de algunos algoritmos basados en IA puede representar un desafío en términos de confianza y transparencia para los usuarios. Estos aspectos fueron considerados como líneas de investigación futuras, con el objetivo de seguir optimizando los sistemas de recomendación y su aplicación en diferentes sectores.

VII. DESARROLLO O CUERPO DEL TRABAJO

En el desarrollo de este trabajo, se inicia con la revisión y análisis de las principales técnicas utilizadas en los sistemas de recomendación basados en inteligencia artificial. En primer lugar, se aborda el filtrado colaborativo, una de las técnicas más utilizadas en sistemas de recomendación. Este enfoque se basa en el análisis de las interacciones previas de los usuarios para identificar patrones comunes entre ellos y generar recomendaciones basadas en los gustos de otros usuarios con perfiles similares. A través de la implementación de este algoritmo, se pudo observar su efectividad en la predicción de preferencias cuando se dispone de una gran cantidad de datos de usuarios, pero también se identificaron ciertas limitaciones, como la conocida "curva fría" o "cold-start", donde los nuevos usuarios o productos no tienen suficiente información para generar recomendaciones precisas.

A continuación, se exploró el filtrado basado en contenido, que utiliza las características de los productos o servicios para hacer recomendaciones personalizadas. Este enfoque tiene la ventaja de no depender de las interacciones previas de los usuarios, lo que lo hace útil en situaciones donde los datos son limitados. Sin embargo, se encontró que el filtrado basado en contenido puede ser menos efectivo cuando se busca explorar una variedad de recomendaciones, ya que tiende a recomendar solo productos similares a los que el usuario ya ha mostrado interés. Para superar las limitaciones de ambos enfoques, se desarrolló un modelo híbrido que combina las fortalezas de los dos métodos anteriores. La implementación de este modelo híbrido mostró una mejora significativa en la precisión de las recomendaciones, ya que permite combinar la personalización basada en el comportamiento de los usuarios con la relevancia de las características de los productos.

En paralelo al análisis de los métodos tradicionales, se integraron técnicas avanzadas de inteligencia artificial, como el uso de redes neuronales profundas para la creación de modelos de recomendación más sofisticados. Se implementaron redes neuronales convolucionales (CNN) y redes neuronales recurrentes (RNN), que han demostrado ser eficaces para modelar relaciones complejas en grandes volúmenes de datos. El uso de estas

técnicas avanzadas permitió mejorar la precisión de las recomendaciones, especialmente en contextos donde los datos eran más escasos o complejos. Se realizaron pruebas exhaustivas con diferentes arquitecturas de redes neuronales, y se ajustaron los hiperparámetros para optimizar el rendimiento del modelo. El análisis de los resultados indicó que los modelos basados en redes neuronales superaron a los enfoques tradicionales en cuanto a la capacidad para ofrecer recomendaciones más personalizadas y con mayor precisión.

Finalmente, se evaluaron los resultados obtenidos utilizando métricas estándar como el error cuadrático medio (RMSE), la precisión y el recall, que proporcionaron una medida cuantitativa del desempeño de los diferentes modelos de recomendación. Los resultados mostraron que, aunque los algoritmos híbridos y las redes neuronales profundas ofrecieron un rendimiento superior, aún existían áreas de mejora, especialmente en la capacidad de los modelos para adaptarse a cambios rápidos en los comportamientos de los usuarios. Se discutieron posibles soluciones para abordar estos desafíos, como la implementación de algoritmos de aprendizaje online y la optimización continua de los modelos en función de los datos más recientes. La discusión también destacó la importancia de la interpretación de las recomendaciones por parte de los usuarios, ya que la calidad de las recomendaciones no solo depende de la precisión técnica, sino también de la percepción que los usuarios tienen sobre la utilidad y relevancia de las sugerencias generadas por el sistema.

VIII. CONCLUSIÓN

La investigación realizada ha permitido profundizar en el análisis y desarrollo de un sistema de recomendación basado en inteligencia artificial, utilizando distintos enfoques como el filtrado colaborativo, el filtrado basado en contenido y modelos híbridos. Uno de los hallazgos más relevantes ha sido la identificación de las fortalezas y limitaciones de cada uno de estos enfoques. El filtrado colaborativo demostró ser altamente efectivo cuando los datos de interacciones de los usuarios son abundantes, pero presenta desafíos en situaciones con datos escasos o nuevos usuarios y productos. El filtrado basado en contenido, por otro lado, se destacó por su capacidad de hacer recomendaciones incluso con

información limitada sobre el comportamiento de los usuarios, pero limitó la diversidad de las sugerencias, al centrarse únicamente en productos similares a los ya preferidos por el usuario.

El modelo híbrido, que combina los dos enfoques anteriores, demostró ser una solución efectiva para superar las limitaciones individuales de cada técnica. Este enfoque permitió mejorar la precisión de las recomendaciones y garantizar una mayor personalización, al integrar tanto el comportamiento de los usuarios como las características de los productos. En particular, la combinación de los dos enfoques permitió mitigar el problema de la "curva fría" y mejorar la calidad de las recomendaciones incluso en escenarios con datos limitados. Un hallazgo adicional fue el impacto positivo de las redes neuronales profundas en la mejora de la capacidad predictiva de los sistemas de recomendación. Los modelos basados en inteligencia artificial, como las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN), demostraron ser capaces de manejar grandes volúmenes de datos y relaciones complejas, lo que resultó en recomendaciones más precisas y diversificadas. Sin embargo, se observó que estos modelos requieren una mayor cantidad de datos y poder de cómputo, lo que puede ser un desafío en escenarios con recursos limitados.

Además, se evaluaron los modelos utilizando métricas estándar como el error cuadrático medio (RMSE), la precisión y el recall, lo que permitió obtener una visión cuantitativa del rendimiento de los sistemas de recomendación. Los resultados indicaron que las técnicas más avanzadas, como los modelos híbridos y las redes neuronales profundas, superaron a los métodos tradicionales en términos de precisión y capacidad de personalización. Sin embargo, también se identificaron áreas de mejora, especialmente en la capacidad de los modelos para adaptarse a cambios rápidos en los comportamientos de los usuarios, lo que subraya la necesidad de algoritmos que sean capaces de aprender de manera continua y adaptarse a los datos más recientes. En cuanto a la percepción de los usuarios, se concluyó que, si bien la precisión técnica es crucial, la interpretación y la aceptación de las recomendaciones por parte de los usuarios son factores igualmente importantes para el éxito del sistema.

IX. RECOMENDACIONES

A partir de los hallazgos obtenidos, se sugieren varias líneas para futuras investigaciones y aplicaciones prácticas. En primer lugar, es recomendable explorar más a fondo el uso de algoritmos de aprendizaje online y continuo, que puedan adaptarse a las interacciones más recientes de los usuarios sin necesidad de entrenar el modelo desde cero cada vez. Esto permitiría que el sistema de recomendación se mantuviera actualizado de manera dinámica, mejorando su capacidad para adaptarse a cambios rápidos en los patrones de comportamiento de los usuarios. Además, sería útil investigar el impacto de diferentes técnicas de regularización en redes neuronales profundas para mejorar la capacidad de generalización de los modelos y evitar el sobreajuste, especialmente en escenarios con datos limitados.

Otra recomendación importante es la integración de factores contextuales en el sistema de recomendación, tales como el tiempo, el lugar y el dispositivo que utiliza el usuario, lo que podría mejorar aún más la precisión y relevancia de las recomendaciones. La inclusión de estos factores contextuales ha sido poco explorada en los sistemas tradicionales, pero podría ofrecer una ventaja significativa al personalizar las recomendaciones según el contexto en el que se encuentra el usuario. Además, se sugiere estudiar la implementación de modelos que permitan explicar las recomendaciones generadas, ya que la transparencia y la interpretabilidad son aspectos cada vez más importantes para los usuarios, especialmente en el contexto de las recomendaciones personalizadas. Los sistemas que pueden explicar por qué una recomendación fue realizada aumentan la confianza del usuario y mejoran la experiencia general.

Desde una perspectiva práctica, las empresas y plataformas que implementen sistemas de recomendación deben considerar el diseño de interfaces de usuario que no solo muestren las recomendaciones, sino que también proporcionen feedback sobre la utilidad de las mismas. Esto no solo mejorará la satisfacción del usuario, sino que también permitirá al sistema aprender de manera más efectiva a partir de las preferencias expresadas. Por

último, sería relevante llevar a cabo estudios de satisfacción del usuario a gran escala para evaluar no solo la precisión de las recomendaciones, sino también la percepción de los usuarios sobre la relevancia y la utilidad de las sugerencias que reciben, asegurando así una experiencia personalizada y efectiva.

X. BIBLIOGRAFÍA

- Castellanos Becerra, J. D., & Niño Parada, E. G. (2021). Prototipo de aplicación móvil para la sugerencia de recetas culinarias utilizando algoritmos de inteligencia artificial.
- Aparicio-Gómez, O. Y., & Aparicio-Gómez, W. O. (2024). Innovación educativa con sistemas de aprendizaje adaptativo impulsados por Inteligencia Artificial. *Revista Internacional de Pedagogía e Innovación Educativa*, 4(2), 343-363.
- Arana, C. (2021). Inteligencia artificial aplicada a la educación: logros, tendencias y perspectivas. *INNOVA UNTREF. Revista Argentina de Ciencia y Tecnología*.
- Rubio, P. E. V., González, G. P. B., Salcán, A. C. Q., & Yedra, H. M. C. (2023). La inteligencia artificial en la educación superior: un enfoque transformador. *Polo del conocimiento*, 8(11), 67-80.
- Corredera, J. C. (2023). Inteligencia artificial generativa. In *Anales de la Real academia de Doctores* (Vol. 8, No. 3, pp. 475-489).