

UNA REVISIÓN DE MÉTODOS, TÉCNICAS Y ALGORITMOS PARA SISTEMAS DE RECOMENDACIÓN DE PRODUCTOS TECNOLÓGICOS

ALEXANDER GUEVARA FERNANDEZ

2017101042@ucss.pe

<https://orcid.org/0000-0001-5032-5522>

Universidad Católica Sedes Sapientiae, Lima, Perú

MARCO A. CORAL YGNACIO

mcoral@ucss.edu.pe

<https://orcid.org/0000-0001-6628-1528>

Universidad Católica Sedes Sapientiae, Lima, Perú

Recibido: 28 de abril del 2023 / Aceptado: 16 de octubre del 2023

doi: <https://doi.org/10.26439/interfases2023.n018.6357>

RESUMEN. Los sistemas de recomendación son herramientas de filtrado de información que ayudan a presentar elementos a los usuarios en función de sus gustos y preferencias. Por ejemplo, pueden realizar sugerencias de artículos para el hogar o productos específicos para un usuario. Actualmente, existen diversos tipos de sistemas de recomendación (SR) para abordar el incremento de información en internet por parte de las empresas y, de esa manera, mejorar la eficiencia en sus procesos de venta de productos. Así mismo, existen diferentes tipos de sistemas de recomendación que utilizan técnicas específicas para cumplir con los objetivos del rubro de la empresa. Están los sistemas de popularidad, por ejemplo, que se centran en la popularidad de un producto, teniendo como criterios los *likes*, comentarios, el tiempo que un cliente se tomó para revisar el producto, etcétera. También existen los de contenido que, basándose en el historial de un cliente, intentan predecir qué busca el usuario y sugerir productos en relación a posibles gustos del cliente. Finalmente, los sistemas de recomendación de filtrado colaborativo, que generan recomendaciones analizando datos, identificando usuarios y comparando la información del perfil del usuario con la de un colectivo de usuarios. En base a lo antes mencionado, en el presente artículo de investigación se propone una revisión de métodos, técnicas y algoritmos para sistemas de recomendación de productos eléctricos. El objetivo es apoyar y facilitar la toma de decisiones, así como también ayudar en el mejoramiento continuo de las empresas y, de esta manera, incrementar la eficiencia de los sistemas al momento de su implementación.

PALABRAS CLAVE: sistema de recomendación / métodos / técnicas / modelos / algoritmos / electrodomésticos

A REVIEW OF METHODS, TECHNIQUES AND ALGORITHMS FOR TECHNOLOGY PRODUCT RECOMMENDATION SYSTEMS

ABSTRACT. Recommendation systems are information filtering tools that help present elements to users based on their tastes and preferences, for example, making suggestions for household items or specific products for a user. Currently, there are various types of recommendation systems. recommendation (SR) to address the increase in information on the Internet by companies and thus improve efficiency in their product sales processes through recommendations. Likewise, there are different types of recommendation systems that use specific techniques that meet the business objectives such as popularity systems that focus on the popularity of a product based on the criteria of likes, comments, the time a customer took to review the product, content that based on history of a client tries to predict what the user is looking for and suggest products in relation to the client's possible tastes and collaborative filtering in recommendation systems generate recommendations by analyzing data, identifying users and comparing the information of the user's profile and that of a group of users, in Based on the aforementioned, this research article proposes a review of methods, techniques and algorithms for electrical product recommendation systems, with the objective of supporting and facilitating decision making as well as helping in the continuous improvement of companies and in this way increase the efficiency of the systems at the time of their implementation.

KEYWORDS: recommender system / methods / techniques / models / algorithms / home appliances

1. INTRODUCCIÓN

Internet crece a un ritmo acelerado. En el 2019 se registraron 4388 billones de usuarios, y en el año 2017 el comercio electrónico a nivel global obtuvo ganancias de 7,7 billones de dólares (Salas-Rubio et al., 2021). Hoy en día, internet se ha convertido en el centro principal de transferencia de datos, soportando procesos de comercio electrónico, ventas *online* de productos, bienes o servicios. Gracias a internet, las empresas pueden actualizar su información de productos, ofertas y promociones desde cualquier lugar, para que sean vistas a nivel global. Esto genera una sobrecarga de información entre los clientes, los cuales cambian de opinión, gusto o estado de ánimo rápidamente (Barrientos Felipa, 2017).

En Latinoamérica existen muchas empresas que venden con el método tradicional. Un ejemplo son las micro, pequeñas o medianas empresas (PyME) en el Perú, las cuales no cuentan con personal capacitado ni soporte tecnológico para el comercio electrónico. Algunas de estas iniciativas muestran páginas web que no están debidamente estructuradas y el contenido que se presenta a los usuarios no es el adecuado (Soler Grillo, 2021). Esto evidencia que los procesos de *marketing* digital o la forma de hacer *marketing* de las PyME carece de implementación tecnológica. Para ello se propone un sistema de recomendación que permita mejorar estos procesos de *marketing* basados en tecnología, y de esta manera ayude a los usuarios a elegir sus recursos en base a sus gustos y preferencias (Milovančević & Gračanac, 2019).

Existen sistemas de recomendación orientados a las ventas que tienen dificultades para realizar recomendaciones porque existe el problema del arranque frío (escasez de datos), presentando así recomendaciones inexactas al momento de filtrar la información (Amer et al., 2021). También se han visto sistemas de recomendación que utilizan las sugerencias basándose en iteraciones previas, para así guiar a los usuarios a descubrir contenido de sus preferencias de manera más rápida y adaptándose a las necesidades de los usuarios (Mlika & Karoui, 2020).

En estos sistemas de recomendación se ha verificado que existen inadecuadas combinaciones entre los métodos, técnicas y algoritmos para el tema de ventas *online* orientadas a productos tecnológicos, debido a que no se utilizaron los métodos, técnicas o algoritmos adecuados y relacionados con el cumplimiento del objetivo de la organización. Ello nos motiva a investigar las implementaciones de sistemas de recomendación existentes para la venta de productos tecnológicos. El trabajo busca identificar los métodos, técnicas y algoritmos que pueden ser utilizados en una implementación de un sistema de recomendación de productos tecnológicos, a fin de optimizar el proceso de ventas (C. Zhang et al., 2018), y también se busca mejorar su eficiencia al momento de ser implementados (Fang et al., 2021). Para lograr el objetivo, se ha realizado una revisión sistemática de literatura, utilizando las bases de datos ScienceDirect e IEEEExplore.

El trabajo está organizado de la siguiente manera: en la sección 1 se detalla la introducción, la sección 2 muestra el estado del arte del tema, seguido de la revisión

sistemática en la sección 3; la sección 4 muestra el análisis de datos, seguido de las conclusiones; y, finalmente, se dan a conocer las referencias utilizadas.

2. MARCO TEÓRICO

2.1 Sistema de recomendación

Son herramientas que interactúan directamente con el usuario, mediante la recomendación de artículos. Se basan en predicciones hechas a partir de las valoraciones que los usuarios dan a los artículos, para poder filtrar información de acuerdo con sus gustos y preferencias, mejorando la efectividad de las ventas y atrayendo la atención de más usuarios que buscan comprar según sus intereses (Belkhadir et al., 2019). Estos sistemas incluyen el hecho de que, cuanto más precisas sean las recomendaciones, el sitio recuerda quién es el usuario y qué le gusta, dándole así un sentido de pertenencia, mostrando el contenido de su preferencia y sin perder su atención (Mendoza Olguín et al., 2019).

2.2 Ontologías para sistemas de recomendación

Una ontología es una especificación explícita de una conceptualización, que consiste en un conjunto de atributos que describen conceptos propios o heredados (Huamán Acuña & Cánepa Pérez, 2018). Además, ofrecen al desarrollador la libertad de consultar dinámicamente la información solicitada, la posibilidad de establecer relaciones entre la información, y agregar registros nuevos de información sin afectar su funcionamiento (P. Vera & Ulloa, 2018).

2.2.1 Propiedades de la ontología

Las propiedades que cumple la ontología son: la claridad, que sirve para que los términos definidos sean entendibles; la coherencia, que ayuda a presentar un razonamiento correcto al hacer inferencias, y la extensibilidad que contribuye a mejorar su precisión al anticipar (Gamba Castro, 2013).

2.2.2 Ontología y comercio electrónico

La ontología se utiliza en este campo para estructurar la información. También ayuda a detallar la tendencia y relación que existe entre los usuarios, facilitando la agrupación de los usuarios de acuerdo con sus comportamientos e intereses similares por los productos (Gamba Castro, 2013). Además, sirve para la clasificación de productos, el mapeo de propiedades y la creación de valores de instancias (Blandón Andrade & Zapata Jaramillo, 2018).

2.3 Tipos de sistemas de recomendación

La variedad de algoritmos que pueden utilizar los sistemas de recomendación conduce a la formación de diferentes familias o tipos de sistemas recomendadores, los cuales se detallan a continuación.

2.3.1 Sistemas de popularidad

Este sistema es utilizado con el fin recomendar de acuerdo con la popularidad de un producto. No recomienda a las preferencias de los usuarios, sino que recomienda de manera general al rubro en el que se encuentre el artículo. Este sistema se basa en la cantidad de ventas, en la valoración del producto y las promociones (Jain et al., 2020). También se basa en la varianza de los vectores de calificación de otros usuarios con respecto a los productos, para de esta manera recomendar de manera más precisa (Pajuelo Holguera, 2021).

2.3.2 Sistemas de contenido

Los sistemas basados en contenido son aquellos que utilizan el historial de los usuarios (ya sea marca, color, precio y calificaciones) para predecir qué producto puede ser interesante, tanto para el usuario como para la empresa, y a raíz de ello mostrar sugerencias similares a los intereses del cliente (Afoudi et al., 2021). El objetivo de este sistema en la empresa es mejorar el desempeño y facultar la toma de decisiones de manera más rápida (Soto-Rodríguez & Hernández-Cervantes, 2019).

2.3.3 Filtrado colaborativo

El sistema de recomendación basado en filtrado colaborativo es uno de los sistemas más utilizados hoy en día, ya que su mecanismo de recomendación se basa en filtrar únicamente los gustos y preferencias de los usuarios. También se encarga de evaluar las calificaciones de los productos y predecir cuáles podrían gustar al cliente (Tewari, 2020). Una de las deficiencias que presenta este sistema es que, si los usuarios no evalúan la mayor cantidad de ítems, la recomendación será imprecisa (Mendoza Olguín et al., 2019).

2.4 Marketing digital

El *marketing* digital comprende la utilización de sistemas de información para promover la venta de productos o servicios. En concreto, se basa en la utilización de internet y redes de telecomunicación. En este sentido, el *marketing* digital viene a ser la estrategia que tienen las organizaciones para llegar a sus clientes mediante la implementación de tecnologías de información (Luque-Ortiz, 2021). Para lograr los objetivos del *marketing* y mejorar los procesos de ventas en las empresas, se utilizan los diseños de páginas web, una tienda virtual y tecnologías digitales como sistemas de recomendación mediante la aplicación de inteligencia artificial para vender en línea (Uribe & Sabogal Neira, 2021).

2.4.1 Tecnología para marketing digital

Machine Learning y *Big Data* analítica son modelos de aprendizaje profundo, expertos en el reconocimiento de patrones y en la toma de decisiones, para las empresas que buscan recopilar una gran cantidad de datos tomados de las redes sociales y entornos IoT

(Luque-Ortiz, 2021). Estas técnicas ayudan a aumentar las visitas de los clientes, categorizando las diferentes respuestas de *clicks* que los usuarios dan a productos y filtrando solo la información de importancia (Ullal et al., 2021).

Los sistemas de recomendación y análisis de sentimientos son herramientas esenciales en el campo del *marketing* digital, pues aplicando algoritmos inteligentes, lógica difusa y percepción por análisis de valores, aumentan la productividad en las empresas y mejoran la eficiencia en las ventas ayudando a los usuarios a encontrar productos de su preferencia y acordes a sus gustos (Marín López & López Trujillo, 2020). Esta lógica de análisis se basa en las preferencias, en las calificaciones sobre un producto y busca a los usuarios que han tomado decisiones parecidas para poder realizar las recomendaciones (Guevara Albán et al., 2018).

3. METODOLOGÍA

Se realiza una revisión sistemática de literatura en base al método que plantea Hanna Snyder, que consta de cuatro fases: diseño de la revisión, realización de la revisión, análisis de datos y redacción de la reseña (Snyder, 2019).

3.1. Diseño de la revisión

El propósito de la siguiente investigación es determinar cuáles son los métodos y técnicas más usados para llevar a cabo la implementación de un sistema de recomendación orientado a productos tecnológicos. También se busca conocer cuáles son los algoritmos más usados para la implementación de un sistema de recomendación en ventas de productos tecnológicos y, de esta manera, dar respuesta a las siguientes preguntas de investigación planteadas.

- P1: ¿Cuáles son las técnicas y algoritmos que utilizan los sistemas de recomendación orientados a las ventas de productos tecnológicos?
- P2: ¿Cuáles son los modelos de construcción utilizados en sistemas de recomendación orientados a productos tecnológicos?
- P3: ¿Qué técnicas son las más eficientes para los sistemas de recomendación orientados a las ventas de productos tecnológicos?

Para elaborar la investigación, se ha definido un análisis cuantitativo. Como se ha mencionado antes, el propósito de la investigación consiste en encontrar los métodos más eficientes para la implementación de un sistema de recomendación, así como también los algoritmos y modelos usados para la recomendación de productos tecnológicos. Además, se formularon las palabras clave referentes al tema en estudio y basándonos en las preguntas de investigación, para luego, mediante las cadenas de búsqueda, hacer uso de las bases de datos ScienceDirect e IEEEExplore. El principal motor de búsqueda

utilizado fue la base de datos “ScienceDirect”, ya que mostró la mayor cantidad de resultados y proporcionó acceso directo a sus artículos mediante la búsqueda avanzada. La cadena de búsqueda se introdujo el 28 de abril del 2022. La investigación se llevó a cabo durante 4 meses, durante los cuales se introdujo la cadena de búsqueda en diferentes bases de datos en esa fecha específica. Esto se hizo así porque los resultados podrían variar si se realizaba la búsqueda en momentos diferentes en distintas bases de datos. Después de aplicar los criterios de inclusión y exclusión establecidos, como el año y el tipo de investigación, se obtuvieron 487 artículos. Para realizar un análisis más exhaustivo y aplicar todos los criterios de inclusión y exclusión, se presenta la Tabla 1.

Tabla 1

Criterios de inclusión y exclusión

Inclusión	Exclusión
Artículos de base de datos conocidas como (ScienceDirect, IEEEExplore).	Artículos que no sean de investigación.
Artículos del 2018, 2019, 2020, 2021.	Se excluyeron documentos como libros, tesis o capítulos de libros.
Los términos de búsqueda en inglés (Methods, algorithms, recommendation system, home appliances, techniques, Implementation).	Artículos publicados en el año 2018 que no hablen de sistemas de recomendación y recomendación para ventas.
Se considera literatura de la forma (Artículos de investigación).	Artículos que no cuenten con un Doi.
Los artículos incluidos deben tener un Doi.	Artículos en español.
Artículos de acceso libre.	Artículos no indexados
Artículos en inglés.	

3.2. Realización de la revisión


En esta fase se realizó la ejecución de la cadena de búsqueda elaborada en base a las preguntas de la investigación ya mencionadas. Habiendo realizado la búsqueda, se detallan en una tabla los datos obtenidos en las bases de datos ScienceDirect e IEEEExplorer: título, autor, journal, año de publicación, doi, país, palabras clave y número de citas. Con los datos obtenidos detallados anteriormente se elaboró la Tabla 2 en la que se muestra la cadena de búsqueda y la cantidad de artículos seleccionados.

Tabla 2
Cadena de búsqueda

Fecha	Cadena de búsqueda	Journal	Cantidad de artículos	Artículos seleccionados
28/04/2022	(methods OR techniques OR algorithms) AND ("recommendation system" OR "implementation")AND ("home appliances").	ScienceDirect	487	48
		IEEEExplore	232	2

Junto con ello, se procedió a elaborar una figura donde se expande el detalle de la selección de artículos paso a paso, tal y como se muestra en la Figura 1.

Figura 1
Fases de la revisión



En primer lugar, se obtuvieron 487 artículos en la base de datos ScienceDirect y 232 en IEEEExplore. Aplicando los criterios de inclusión y exclusión (como el año, tipo y acceso libre), se redujo la cantidad de investigaciones y se conservaron sólo las que hablan sobre nuestro tema. Quedaron así 150 artículos para la base de datos IEEEExplore y 152 para ScienceDirect. ,En el tercer paso, aplicamos el criterio de exclusión y filtramos solo los artículos que traten de sistemas de recomendación, con lo cual quedaron 87 para ScienceDirect y 5 para IEEEExplore. En el cuarto paso se realizó una revisión textual


exhaustiva en base a la cual se seleccionaron sólo aquellos que aporten estrictamente con el tema de investigación y traten acerca de métodos, técnicas, algoritmos e implementación de sistemas de recomendación. De este modo, quedaron 48 artículos de ScienceDirect y dos de IEEEExplore, llegando a tener una muestra final de 50 artículos que aportan nuestra investigación.

3.3. Análisis de datos

Después de haber seleccionado los artículos válidos para nuestra investigación, se analizó la cantidad de investigaciones relacionadas con el tema por país (de un total de 18 países). China se ubica en el primer lugar y como el país que más investigaciones realiza con respecto a nuestro tema de estudio; le sigue Australia, que se ubica como el segundo país con más investigaciones. Vietnam y Brasil, en cambio, tienen un índice de investigaciones más bajo, así como Canadá y los demás países cuyo índice de investigación con respecto a sistemas de recomendación es muy bajo, tal como se detalla en la Figura 2.

Figura 2


Número de investigaciones publicadas por país



En la Figura 3 se muestra la cantidad de investigaciones publicadas por año, considerando los años del 2018 al 2021. Se observa que a partir del año 2020 la tendencia aumenta considerablemente con respecto a los años anteriores. Esto se explica porque, debido a la pandemia, la tecnología digital empieza a crecer a un ritmo muy acelerado. Si observamos la Figura 3, del 2020 al 2021 el aumento de investigaciones sobre nuestro tema de estudio es casi del doble. Consideramos que el presente trabajo es oportuno y constituye un aporte a las investigaciones con respecto al tema.

Figura 3


Cantidad de investigaciones publicadas por año



Con respecto a la cantidad de autores por artículo, realizando un análisis de la Figura 4 se observa que la frecuencia de autores varía, aunque la mayoría de los artículos están escritos por entre uno a cuatro autores. Esto nos lleva a la conclusión de que la mayoría de los investigadores prefiere realizar una investigación de entre dos y cuatro personas y que existen pocos que desean trabajar en una investigación con más de cinco investigadores por artículo.

Figura 4

Cantidad de autores por artículo



En la Tabla 3 se muestran los 10 artículos más citados. Allí se observa que el primero, cuya publicación se realizó en el año 2021, tiene 102 citaciones; el segundo tiene 82 citaciones y fue publicado en el año 2019; y el que fue publicado en el año 2018 tiene 55 citaciones. Estos datos representan el incremento del interés de investigadores por el tema en estudio en los últimos años.

Tabla 3*Los artículos más citados*

Referencia de autor	Año	Citas
(Ficel et al., 2021).	2021	102
(Ojagh et al., 2020).	2020	82
(Li et al., 2021).	2021	72
(Nguyen Hoai Nam, 2021).	2021	70
(Ziarani & Ravanmehr, 2021).	2021	65
(Bag et al., 2019).	2019	58
(K. Zhang et al., 2021a).	2021	56
(Rezaeimehr et al., 2018).	2018	55
(Sang et al., 2021).	2021	53
(Chiu et al., 2021).	2021	52

En cuanto a los temas revisados en las publicaciones seleccionadas, como se observa en la Tabla 4, la palabra clave que más se repite es “*Recommender systems*” con 46 incidencias, seguido de “*Collaborative filtering*” con 10, y “*Matrix factorization*” con 5. También aparecen “*Recommendation algorithm*”, “*Deep learning*” y “*Clustering*” (cada uno con 3), seguido de “*Machine learning*”, “*Social networks*”, “*Slope One algorithm*” y “*Ontology*” (cada uno con 2). Finalmente, se contabilizan 149 palabras clave que se repiten una vez, lo cual demuestra que existen múltiples temas asociados a la investigación y evidencia el incremento de las investigaciones sobre sistemas de recomendación.

Tabla 4*Frecuencia de palabras clave*

Palabras clave	Frecuencia
Recommender systems	46
Collaborative filtering	10
Matrix factorization	5
Recommendation algorithm, Deep learning, Clustering	3
Machine learning, Social networks, Slope One algorithm, Ontology	2

(continúa)

(continuación)

Palabras clave	Frecuencia
The expert knowledge recommendation systems (EKRS), Differential privacy, Tourist trip design problem, Bat Algorithm, E-commerce, E-commerce recommendation system, Behavior features, Adversarial training, NLP, Ecommerce, Smart product service system, Collaborating filtering, Regression-based binary recommendation, Recommendation, Transformer, Knowledge graph, Probabilistic matrix factorization, Tag, Privacy protection, Genetic matrix factorization algorithm (GMF), Similarity, Behavioral analytics, Genetic algorithms, User-knowledge integrated decision-making (UKID), Latent factor model, Knowledge graph, MStream analysis, Markov chains, Sparsity, Orienteering problem, Group recommendation, Big data, Serendipity, Restricted Boltzmann machine, Conditional holoentropy, Feature, BPR, TF-ID, Sentiment analysis, ranking function, Natural language processing, Problem, Neural architecture, Forgetting function, Binary code learning, Clustering, Factorization machine, Autoencoder, Many-objective optimization, Deep learning, Context, edge computing, recommendation precision, tag, Movies, Extreme learning, Network science, Crowdsourcing task allocation, Consumption behavior modeling and prediction, Context-awareness, Bhattacharyya coefficient, Sequential prediction, Bipartite network, Aggregation method, Deep neural network, Artificial Bee Colony algorithm, Data sparsity, Unsupervised learning, Deep Belief Network, graph features, User reviews, learning to Rank, Semantics, Machine learning, Similarity, Trichotomy, Neural networks, Deep neural network, K-medoids algorithm, Fine-grained features, hybrid recommender algorithm, ItemRank, recommendation diversity, time factor, Deep Learning, Aggregate diversity, Artificial immune systems, Overlapping community structure, Graph convolutional networks, Ranking recommendation approach, Score preferences, Orientation context, Multistage rating prediction, Clustering nodes, Simulated annealing, Criteria preferences, Social network, Convolutional neural network, Swarm Intelligence, Content based filtering, Diffusion-based algorithms, Temporal information, Optimized deep learning, CNN, Recommendation Opinion, differential evolution, Personalization, KNN algorithm, Full search, Wu & Palmer similarity, Neural collaborative hashing, Kullback–Leibler (KL) divergence, Rating prediction, Score preferences, Cold start, User/item similarity, Collaborative learning, rough set theory, multiobjective recommendation optimization, Movielens Datasets, Reliability, Attention mechanism, Knowledge graphs, IoT devices, Non-linear similarity, Clustering algorithm, k-means, Social relationships, Genre preference, Trust, Particle swarm optimization, User profile, Grey linked chick update-based chicken swarm optimization, text features, Sentiment score, Metaheuristic, Cross validation, Recursive algorithm, Probability, Probability distribution, Synthetic coordinates, distributed parallelism, Entropy maximization, profile injection attack, Empirical evaluation, message passing interface(MPI), Fuzzy rule, cooperative coevolution, K-means clustering	1

4. ANÁLISIS

Para analizar los resultados obtenidos y responder a nuestras preguntas de investigación, se muestra a continuación la primera pregunta con los resultados respecto de los métodos que utilizaron otros autores.

P1: ¿Cuáles son las técnicas y algoritmos que utilizan los sistemas de recomendación orientados a las ventas de productos tecnológicos?

La siguiente sección responde a la pregunta uno, donde se detallan las técnicas y algoritmos conforme se especifica en las tablas 5 y 6. Para esto, en la Tabla 5 se muestran las técnicas para sistemas de recomendación, que consisten en un conjunto de procedimientos en los que se determina cierta cantidad de instrucciones para cumplir con una tarea determinada, a fin de lograr el mejor manejo de la información y de esta manera alcanzar el objetivo establecido (Avadiappan & Maravelias, 2021).

En base a nuestra primera pregunta, tenemos las técnicas que utilizan los sistemas de recomendación, como se observa en la Tabla 5. Una técnica es un conjunto de instrucciones para resolver un proceso dentro del sistema y cumplir con el objetivo de la programación: evitar posibles fallos, lograr que el programa tenga la máxima eficiencia para el campo en el que fue creado, y conseguir, de esta manera, resolver los problemas de sobrecarga de información que pueden sufrir los usuarios de plataformas tecnológicas (Madeti & Singh, 2017).

Tabla 5

Técnicas para sistemas de recomendación

Referencias	Técnicas
(Yassine et al., 2021), (Ojagh et al., 2020), (Nassar et al., 2020)	Filtrado colaborativo.
(K. Zhang et al., 2021)	Técnica de inferencia de relación social implícita.
(Belkhadir et al., 2019)	Técnicas de factorización matricial.
(Yadav et al., 2018)	Técnica heurística basada en el algoritmo Bat.
(Tewari, 2020)	Técnica de recomendación de factorización de matrices de última generación.
(Kumar Sharma et al., 2023)	Técnica NLP.
(Karthik & Ganapathy, 2021)	Técnica basada en lógica difusa.
(Amer et al., 2021)	Técnica de validación cruzada de K-fold.
(Deng et al., 2019)	Filtrado de la información.

En cuanto a los algoritmos de recomendación, existen diversos tipos para abordar problemas de sobrecarga de información de diferentes maneras, como se observa en la Tabla 6. Los algoritmos de recomendación son un conjunto de instrucciones que se

ejecutan de manera secuencial, con el fin de proporcionar soluciones de optimización y de esta manera filtrar a los usuarios toda la información de valor o interés (Korus et al., 2021).

Tabla 6
Algoritmos para sistemas de recomendación

Referencias	Algoritmos	Campo de uso
(Yassine et al., 2021), (Seo et al., 2021)	Algoritmo k-means.	Este algoritmo de agrupamiento permite recoger información de productos con características más cercanas al de las preferencias de los usuarios mediante un método de descomposición.
(Bag et al., 2019)	Algoritmo Significant Nearest Neighbors (vecino más cercano)	Este algoritmo se centra en buscar las variables más significativas y con más peso de los vecinos más cercanos, para generar recomendaciones más precisas.
(Duma & Twala, 2019)	Algoritmo genético y algoritmo artificial del vecino más cercano.	Este algoritmo inteligente artificial del vecino más cercano con alteración genética recomienda productos a partir de imputación rápida de datos faltantes que ayuda a generar recomendaciones más precisas a raíz del incremento de datos dispersos.
(Chen et al., 2021)	Algoritmo de filtrado colaborativo (CF).	Este algoritmo de filtrado colaborativo utiliza un sistema de recomendación basado en clustering que agrupa un conjunto de datos por categoría y luego las ajusta a las del usuario objetivo y recomienda en base a la selección de un conjunto de datos de vecinos más cercanos.
(F. Zhang et al., 2020)	Algoritmo de clustering.	Este algoritmo permite la agrupación de productos según la similitud de datos que estos contengan.
(Tewari, 2020)	Algoritmo combinado filtrado colaborativo y filtrado basado en contenido.	Este algoritmo utiliza la técnica de filtrado colaborativo y filtrado basado en contenido para recomendar productos basados en productos similares y hacerlo en base a preferencias de un grupo con similitud de elementos objetivos.
(Bertani et al., 2020)	Algoritmo de difusión orientada al perfil del usuario.	Este algoritmo se centra en conocer el perfil de usuario para generar recomendaciones personalizadas a través de la difusión mediante la combinación de la popularidad de un artículo y la novedad que este tiene.
(Kumar Sharma et al., 2023)	Algoritmos de lenguaje natural procesado.	El algoritmo de lenguaje natural procesado busca predecir lo que el usuario está buscando en base a los atributos de un artículo (como el nombre y las imágenes) para recomendar productos similares, en caso no haya el producto buscado por el usuario.
(Amer et al., 2021)	Algoritmo del vecino más cercano (KNN).	Este algoritmo utiliza el cálculo de distancia euclidiana para calcular productos más cercanos a las preferencias del usuario y recomendar artículos en relación a los atributos preferenciales del usuario objetivo.

(continúa)

(continuación)

Referencias	Algoritmos	Campo de uso
(Khadem & Forghani, 2020)	Algoritmo slope one.	Se centra en las opiniones y pruebas de diferentes usuarios mediante combinación de tablas con atributos similares para generar recomendaciones personalizadas.
(Milovančević & Gračanac, 2019)	Algoritmo del vecino más cercano de tres vías.	Este algoritmo utiliza una técnica de etiquetas y ontologías basadas en el factor tiempo para generar recomendaciones en función a la evaluación de datos.
(Deng et al., 2019)	El algoritmo de recomendación de agrupamiento de K-medoids basado en la distribución de probabilidad para filtrado colaborativo.	El algoritmo pretende solucionar la escasez de datos mediante el agrupamiento de k-medoids basado en la distribución de la probabilidad.
(Song & Wu, 2020)	El algoritmo slope one en el sistema y K-means.	El algoritmo se centra en la agrupación de usuario y las preferencias de puntuación. El primer k-means divide los usuarios en varias categorías según su grado de similitud y slope one integra las preferencias de calificación de los usuarios para realizar la predicción.

En función de las tablas 5 y 6, se puede concluir que las técnicas y algoritmos más usados en los sistemas de recomendación basados en la venta de productos, se centran en realizar recomendaciones basadas en el usuario. Por ejemplo, el algoritmo k-mean, k-medias y knn, que se centran en la agrupación y distribución de datos que tengan similitud a los de otros usuarios, en relación con las preferencias de un usuario específico, y generan recomendaciones de productos que podrían llevar a realizar la compra a un cliente. Así mismo, mediante las técnicas de filtrado colaborativo, factorización matricial, lógica difusa y lenguaje procesado, mejoran la eficiencia de las recomendaciones al momento de procesar datos.

Habiendo ya respondido la pregunta uno sobre cuáles son las técnicas y algoritmos que utilizan los sistemas de recomendación, se concluye que existen diversas técnicas y algoritmos que se estructuran dentro de un sistema para agilizar el proceso de recomendación de productos. Así mismo, cada técnica y algoritmo se adapta para recomendar en relación con el motivo por el cual se desarrolló el sistema y para que trabajen de manera más eficiente y generen recomendaciones más precisas. A continuación, pasamos a responder la pregunta número dos, que habla sobre los modelos de recomendación más usados en sistemas de recomendación.

P2: ¿Cuáles son los modelos de construcción utilizados en sistemas de recomendación orientados a productos tecnológicos?

En la Tabla 7 se muestran los modelos de construcción utilizados en sistemas de recomendación de productos tecnológicos, recabados de investigaciones relacionadas con el tema. Además, se describen los estudios de diversos autores centrados con

el objetivo de la investigación, lo cual ayuda a un mejor entendimiento de los modelos utilizados.

Tabla 7
Modelos para sistemas de recomendación

Referencias	Modelo	Descripción
(Valdiviezo Díaz, 2019)., (Walid, 2017), (Vanesa et al., 2022), (Afoudi et al., 2021).	Modelo de filtrado basado en contenido	Este modelo se usa para recomendar productos similares a los que a un usuario predeterminado le gustó en un tiempo pasado, basado en los ítems e iteraciones con el sistema.
(Mendoza Olguín et al., 2019), (Gómez et al., 2019), (Cristóbal González, 2018).	Modelo de recomendación con filtrado colaborativo	Este modelo ayuda al sistema de recomendación a realizar predicciones de preferencias de los usuarios de forma automática, mediante la recopilación de datos en su historial.
(Valecillos, 2019), (Vences Nava et al., 2019), (Choi et al., 2012), (Cai et al., 2020).	Modelo de recomendación basado en filtrado híbrido	Este modelo de recomendación permite realizar recomendaciones a los usuarios basados en métricas de similitud (es decir, en usuarios con iguales intereses).
(Y. Zhang & Liu, 2021), (Valcarce et al., 2019), (Kong et al., 2018), (Lima et al., 2020) .	Modelo de recomendación con filtrado basado en memoria	Este modelo permite realizar recomendaciones de productos a raíz de las valoraciones que otros usuarios realizaron en función de sus preferencias y mostrarlos al usuario.
(Srilakshmi et al., 2022), (Xu et al., 2023), (J. Vera et al., 2018), (Walid, 2017).	Modelo de recomendación basado en ítems	El modelo de recomendación basado en ítems realiza recomendaciones de productos de acuerdo con la valoración del usuario hacia un producto y su popularidad.
(Tewari, 2020), (Hurtado Ortiz, 2020), (H. Wang et al., 2022)	Modelo de recomendación basado en usuarios	Este modelo recomienda productos en base a los gustos de usuarios similares y recomienda las preferencias de los nodos más cercanos al usuario base.

(continúa)

(continuación)

Referencias	Modelo	Descripción
(Afoudi et al., 2021), (Vega Moreno & Ismael Hurtado Ortiz, 2021), (J. Zhang et al., 2021), (J. Wang & Liu, 2020)	Modelo de recomendación basado en redes neuronales	Estos modelos de redes neuronales simulan el procesamiento de la información a similitud del cerebro humano, mediante el procesamiento de neuronas interconectadas que ayudan en el proceso de la información.
(Romero et al., 2017), (Pita Pérez, 2020),	Modelo de recomendación basado en aprendizaje supervisado (knn)	Este modelo utiliza un modelo matemático basado en los clusters de distancia más cercanas a los usuarios vecinos con similitud de preferencias para realizar recomendaciones en base a ellas.

La pregunta 3 indaga sobre las técnicas que utilizan los sistemas de recomendación e intenta analizar cuáles son más eficientes.

P3: ¿Qué técnicas son las más eficientes para los sistemas de recomendación orientados a las ventas de productos tecnológicos?

Se elaboró la Tabla 8 en la que se especifican las técnicas usadas por diferentes investigadores en relación con el tema, según los resultados que obtuvieron en base a la investigación realizada y la eficiencia con la que calificaron las técnicas al final de la investigación. Esto último se detalla en la columna "eficiencia".

Tabla 8

Análisis de técnicas para sistemas de recomendación

Técnica	Resultados obtenidos	Eficiencia
Filtrado colaborativo.	La técnica de filtrado colaborativo descrita es factible en cuanto a la precisión y el rendimiento de las recomendaciones (Yassine et al., 2021). Una de las ventajas de esta técnica es usar criterios múltiples con redes profundas para la colaboración de sistema de recomendación de filtrado (Nassar et al., 2020). Todo esto ayuda a generar recomendaciones más precisas y personalizadas (Ojagh et al., 2020).	Eficiente.
Técnica de inferencia de relación social implícita.	La técnica de recomendación social propuesta supera los enfoques tradicionales, tanto para usuarios activos y de arranque en frío, en la predicción de calificaciones de criterios (K. Zhang et al., 2021).	Muy eficiente.

(continúa)

(continuación)

Técnica	Resultados obtenidos	Eficiencia
Fac- torización matricial.	La técnica fusiona la matriz de calificación de usuario-elemento y la técnica factorización matricial. Los resultados experimentales muestran que esta combinación supera los algoritmos de filtrado colaborativo tradicionales y puede evitar el problema del arranque en frío (Belkhadir et al., 2019).	Muy eficiente.
Técnica heurística basada en el algoritmo Bat.	La técnica heurística basada en el algoritmo Bat ayudó a proporcionar recomendaciones a todos los usuarios, ya que generó un conjunto diferente de pesos para cada uno. Los resultados también confirmaron que la técnica basada en el algoritmo bat logra un error absoluto medio más bajo en comparación con otras técnicas tradicionales de filtrado colaborativo, y también se desempeña mejor que otras técnicas basadas en enjambres (Yadav et al., 2018).	Poco eficiente.
Técnica de factori- zación de matrices de última generación.	La técnica de factorización de matrices de última generación mostró una mejora significativa del 21 % en comparación con la técnica estándar de filtrado colaborativo basada en el usuario, y del 8 % en comparación con la técnica actual de recomendación de factorización matricial de última generación (Tewari, 2020).	Eficiente.
Técnica de lenguaje natural procesado.	El sistema de recomendación propuesto mediante la técnica de lenguaje natural procesado y un algoritmo pueden predecir muy bien los productos parecidos a los que el usuario había seleccionado (Kumar Sharma et al., 2023).	Muy eficiente.
Técnica basada en lógica difusa.	La técnica basada en lógica difusa muestra un mejor rendimiento en el sistema de recomendación. A diferencia de los otros sistemas, la técnica mejora la precisión en la predicción de productos destacados para el usuario y mejora el tiempo para realizar las recomendaciones (Karthik & Ganapathy, 2021).	Muy eficiente.
Técnica de filtrado de la información.	La técnica de filtrado de la información aplicada más el algoritmo de recomendación hacen exitoso al sistema por su simplicidad y alta eficiencia al momento de recomendar (Deng et al., 2019).	Eficiente.

En base a las preguntas propuestas, se expresa la diferencia entre técnica, modelo, algoritmo y métodos. Un método está propuesto por una función dentro del sistema que nos ayudará a obtener datos filtrados en relación a las preferencias de un cliente. Un algoritmo propone funciones matemáticas que ayudan en el procesamiento de la información, a diferencia de un modelo que se centra en la estructuración del sistema para poder implementar de manera eficiente sus objetivos. Una técnica está relacionada a la combinación de algoritmos que ayuden a mejorar la eficiencia del sistema, predecir y recomendar productos de manera oportuna, basados en datos de preferencias de los usuarios.

El análisis realizado evidencia que la técnica de inferencia de relaciones sociales implícitas, que se basa en la predicción de las valoraciones por criterios, es la más eficiente para

abarcando problemas de arranque frío que se dan al tener un usuario nuevo y no contar con un historial sobre sus gustos y preferencias. La técnica de factorización matricial fusiona una matriz de valoración del usuario y la red social del usuario para añadir más precisión a las recomendaciones finales, mejorando las predicciones al momento de hacer recomendaciones. Otra técnica eficiente en cuanto a la predicción de productos parecidos es el procesamiento del lenguaje natural (NLP). Por último, la lógica difusa mejora la precisión en la predicción de productos destacados y mejora el tiempo de respuesta de los sistemas.

En el transcurso de la investigación y consecuente análisis de las preguntas sobre cuáles son los métodos, técnicas y algoritmos para sistemas de recomendación de productos tecnológicos, encontramos el método de precisión Rcall, que se basa en el reconocimiento de patrones y clasificación de información para hacer recomendaciones precisas. Otro de los métodos para sistemas de recomendación eficientes es el aprendizaje profundo. También encontramos el de procesamiento de lenguaje natural no supervisado, que se basa en el análisis para ayudar a mejorar las recomendaciones. También está el método de factorización matricial, "*Softmax-ATT*" y "*Correlated-ATT*". En cuanto a las técnicas de implementación más eficientes, se tiene el filtrado colaborativo, factorización matricial (MF) y la técnica de filtrado de la información. Finalmente, para dar respuesta a la pregunta uno, se encontraron los algoritmos más utilizados en los sistemas de recomendaciones, siendo el *k-mean* el más importante. También se encuentra el algoritmo knn, conocido como "el vecino más cercano", que se basa en la clasificación correcta de instancias nuevas, y el algoritmo K-medoids, que se basa en el agrupamiento y que guarda mucha relación con los algoritmos antes mencionados.

5. CONCLUSIONES

Las investigaciones evidencian el uso de métodos, técnicas y algoritmos para las implementaciones de sistemas de recomendación asociados a productos tecnológicos. Los algoritmos más utilizados para sistemas de recomendación de productos tecnológicos se centran en la agrupación de datos con similitud de otros usuarios que compartan algunos criterios de preferencias con los demás usuarios. Por ejemplo, los algoritmos *k-means*, knn, k-medoids y *slope one* que, mediante técnicas, filtran recomendaciones en relación con las preferencias de los clientes. También se considera adecuado el uso de la técnica de filtrado colaborativo, por ser considerada una técnica eficiente, ya que su principal objetivo es recoger los datos de los usuarios que presenten una medida alta en similitud a la de los demás usuarios y generar recomendaciones de diversos productos que podrían ser de interés para los clientes; además, son capaces de solucionar el problema de arranque frío en sistemas de recomendación.

Para las recomendaciones de productos tecnológicos, los algoritmos funcionan en base a los datos generados por cada producto a ser evaluado. En este sentido, la popularidad del producto genera los primeros datos de evaluación, seguido por las calificaciones del usuario. También puede utilizarse la similitud del producto, siendo esta

la más utilizada en la lógica de una recomendación. Entre los algoritmos más utilizados para este fin tenemos el *K-means*, KNN y K-medoids.

En base a los antecedentes revisados, se puede concluir que los sistemas recomendación de productos tecnológicos se centran en utilizar algoritmos que busquen encontrar vecinos más cercanos para predecir y recomendar en función a las preferencias de un usuario, mediante la toma de datos dispersos que se adapten a los deseos de otros clientes.

REFERENCIAS

- Afoudi, Y., Lazaar, M., & Al Achhab, M. (2021). Hybrid recommendation system combined content-based filtering and collaborative prediction using artificial neural network. *Simulation Modelling Practice and Theory*, 113(April), 102375. <https://doi.org/10.1016/j.simpat.2021.102375>
- Amer, A. A., Abdalla, H. I., & Nguyen, L. (2021). Enhancing recommendation systems performance using highly-effective similarity measures [Formula presented]. *Knowledge-Based Systems*, 217, 106842. <https://doi.org/10.1016/j.knosys.2021.106842>
- Avadiappan, V., & Maravelias, C. T. (2021). State estimation in online batch production scheduling: concepts, definitions, algorithms and optimization models. *Computers and Chemical Engineering*, 146, 107209. <https://doi.org/10.1016/j.compchemeng.2020.107209>
- Bag, S., Ghadge, A., & Tiwari, M. K. (2019). An integrated recommender system for improved accuracy and aggregate diversity. *Computers and Industrial Engineering*, 130(February), 187-197. <https://doi.org/10.1016/j.cie.2019.02.028>
- Barrientos Felipa, P. (2017). Marketing + internet = e-commerce: oportunidades. *Finanzas y Política Económica*, 9(1), 41-56.
- Belkhadir, I., Omar, E. D., & Boumhidi, J. (2019). An intelligent recommender system using social trust path for recommendations in web-based social networks. *Procedia Computer Science*, 148, 181-190. <https://doi.org/10.1016/j.procs.2019.01.035>
- Bertani, R. M., Bianchi, R. A. C., & Costa, A. H. R. (2020). Combining novelty and popularity on personalised recommendations via user profile learning. *Expert Systems with Applications*, 146, 113149. <https://doi.org/10.1016/j.eswa.2019.113149>
- Blandón Andrade, J. C., & Zapata Jaramillo, C. M. (2018). Una revisión de la literatura sobre población de ontologías. *Ingeniería y Desarrollo*, 36(1), 26.
- Cai, X., Hu, Z., Zhao, P., Zhang, W. S., & Chen, J. (2020). A hybrid recommendation system with many-objective evolutionary algorithm. *Expert Systems with Applications*, 159, 113648. <https://doi.org/10.1016/j.eswa.2020.113648>

- Chen, Z., Wang, Y., Zhang, S., Zhong, H., & Chen, L. (2021). Differentially private user-based collaborative filtering recommendation based on k-means clustering. *Expert Systems with Applications*, 168, 114366. <https://doi.org/10.1016/j.eswa.2020.114366>
- Chiu, M. C., Huang, J. H., Gupta, S., & Akman, G. (2021). Developing a personalized recommendation system in a smart product service system based on unsupervised learning model. *Computers in Industry*, 128, 103421. <https://doi.org/10.1016/j.compind.2021.103421>
- Choi, K., Yoo, D., Kim, G., & Suh, Y. (2012). A hybrid online-product recommendation system: Combining implicit rating-based collaborative filtering and sequential pattern analysis. *Electronic Commerce Research and Applications*, 11(4), 309-317. <https://doi.org/10.1016/j.eierap.2012.02.004>
- Criado González, M. (2018). *Análisis e implementación de un sistema de recomendación para la lista de la compra* [Trabajo de Grado, Universidad Carlos III de Madrid]. https://e-archivo.uc3m.es/bitstream/handle/10016/29430/TFG_Marta_Criado_Gonzalez.pdf?sequence=1&isAllowed=y
- Deng, J., Guo, J., & Wang, Y. (2019). A Novel K-medoids clustering recommendation algorithm based on probability distribution for collaborative filtering. *Knowledge-Based Systems*, 175, 96-106. <https://doi.org/10.1016/j.knosys.2019.03.009>
- Duma, M., & Twala, B. (2019). Sparseness reduction in collaborative filtering using a nearest neighbour artificial immune system with genetic algorithms Duma, Mlungisi, and Bhakisipho Twala. *Expert Systems with Applications*, 132, 110-125. <https://doi.org/10.1016/j.eswa.2019.04.034>
- Fang, X., Wang, J., Seng, D., Li, B., Lai, C., & Chen, X. (2021). Recommendation algorithm combining ratings and comments. *Alexandria Engineering Journal*, 60(6), 5009-5018. <https://doi.org/10.1016/j.aej.2021.04.056>
- Ficel, H., Haddad, M. R., & Baazaoui Zghal, H. (2021). A graph-based recommendation approach for highly interactive platforms. *Expert Systems with Applications*, 185, 115555. <https://doi.org/10.1016/j.eswa.2021.115555>
- Gamba Castro, C. (2013). *Diseño de una ontología de representación del conocimiento desde el dominio de la lectura* [Trabajo de Grado, Universidad de La Salle, Bogotá]. https://ciencia.lasalle.edu.co/cgi/viewcontent.cgi?article=1043&context=sistemas_informacion_documentacion
- Gómez, P., Guarda, T., Cedeño, J., Benavides, A., Alejandro, C., Mosquera, G., García, T., & Benavides, V. (2019). Sistemas de recomendación: un enfoque a las técnicas de filtrado. *Egyptian Informatics Journal*, 16(3), 261-273.
- Guevara Albán, G. P., Guevara Albán, C., & Valverde, I. (2018). Sistemas de recomendaciones: una herramienta para mejorar la gestión de la información en las PYMES. *Journal*

- of Science and Research: Revista Ciencia e Investigación*, 3(CITT2017), 121-127. <https://doi.org/10.26910/issn.2528-8083vol3isscitt2017.2018pp121-127>
- Huamán Acuña, D. G., & Cánepa Pérez, C. A. (2018). Diseño de un sistema de recomendación de libros y tesis basado en ontologías asociadas a tesauros: el caso de las bibliotecas de la UNMSM. *Revista Peruana de Computación y Sistemas*, 1(2), 13. <https://doi.org/10.15381/rpcs.v1i2.15379>
- Hurtado Ortiz, R. (2020). *Recomendación a grupos de usuarios usando el concepto de singularidades*. http://oa.upm.es/58148/1/REMIGIO_ISMAEL_HURTADO_ORTIZ.pdf
- Jain, A., Nagar, S., Singh, P. K., & Dhar, J. (2020). EMUCF: Enhanced multistage user-based collaborative filtering through non-linear similarity for recommendation systems. *Expert Systems with Applications*, 161, 113724. <https://doi.org/10.1016/j.eswa.2020.113724>
- Karthik, R. V., & Ganapathy, S. (2021). A fuzzy recommendation system for predicting the customers interests using sentiment analysis and ontology in e-commerce. *Applied Soft Computing*, 108, 107396. <https://doi.org/10.1016/j.asoc.2021.107396>
- Khadem, M. M., & Forghani, Y. (2020). A recursive algorithm to increase the speed of regression-based binary recommendation systems. *Information Sciences*, 512(2), 1324-1334. <https://doi.org/10.1016/j.ins.2019.10.072>
- Kong, F., Li, J., & Lv, Z. (2018). Construction of intelligent traffic information recommendation system based on long short-term memory. *Journal of Computational Science*, 26, 78-86. <https://doi.org/10.1016/j.jocs.2018.03.010>
- Korus, K., Salamak, M., & Jasiński, M. (2021). Optimization of geometric parameters of arch bridges using visual programming FEM components and genetic algorithm. *Engineering Structures*, 241(April). <https://doi.org/10.1016/j.engstruct.2021.112465>
- Kumar Sharma, A., Bajpai, B., Adhvaryu, R., Dhruvi Pankajkumar, S., Parthkumar Gordhanbhai, P., & Kumar, A. (2023). An efficient approach of product recommendation system using NLP technique. *Materials Today: Proceedings*, 80(3), 3730-3743. <https://doi.org/10.1016/j.matpr.2021.07.371>
- Li, G., Zhuo, J., Li, C., Hua, J., Yuan, T., Niu, Z., Ji, D., Wu, R., & Zhang, H. (2021). Multi-modal visual adversarial Bayesian personalized ranking model for recommendation. *Information Sciences*, 572, 378-403. <https://doi.org/10.1016/j.ins.2021.05.022>
- Lima, G. R., Mello, C. E., Lyra, A., & Zimbrão, G. (2020). Applying landmarks to enhance memory-based collaborative filtering. *Information Sciences*, 513, 412-428. <https://doi.org/10.1016/j.ins.2019.10.041>

- Luque-Ortiz, S. (2021). Estrategias de marketing digital utilizadas por empresas del retail deportivo. *Revista CEA*, 7(13), 0-22. <https://doi.org/10.22430/24223182.1650>
- Madeti, S. R., & Singh, S. N. (2017). A comprehensive study on different types of faults and detection techniques for solar photovoltaic system. *Solar Energy*, 158(June), 161-185. <https://doi.org/10.1016/j.solener.2017.08.069>
- Marín López, J. C., & López Trujillo, M. (2020). Análisis de datos para el marketing digital emprendedor: caso de estudio Parque de Innovación Empresarial - Universidad Nacional sede Manizales. *Revista Universidad y Empresa*, 22(38), 65. <https://doi.org/10.12804/revistas.urosario.edu.co/empresa/a.7135>
- Mendoza Olguín, G., Laureano de Jesús, Y., & Pérez de Celis Herrero, M. C. (2019). Métricas de similaridad y evaluación para sistemas de recomendación de filtrado colaborativo. *Revista de Investigación en Tecnologías de la Información*, 7(14), 224-240. <https://doi.org/10.36825/riti.07.14.019>
- Milovančević, N. S., & Gračanac, A. (2019). Time and ontology for resource recommendation system. *Physica A: Statistical Mechanics and Its Applications*, 525, 752-760. <https://doi.org/10.1016/j.physa.2019.04.005>
- Mlika, F., & Karoui, W. (2020). Proposed model to intelligent recommendation system based on markov chains and grouping of genres. *Procedia Computer Science*, 176, 868-877. <https://doi.org/10.1016/j.procs.2020.09.082>
- Nassar, N., Jafar, A., & Rahhal, Y. (2020). A novel deep multi-criteria collaborative filtering model for recommendation system. *Knowledge-Based Systems*, 187. <https://doi.org/10.1016/j.knosys.2019.06.019>
- Nguyen Hoai Nam, L. (2021). Latent factor recommendation models for integrating explicit and implicit preferences in a multi-step decision-making process. *Expert Systems with Applications*, 174(227), 114772. <https://doi.org/10.1016/j.eswa.2021.114772>
- Ojagh, S., Malek, M. R., Saeedi, S., & Liang, S. (2020). A location-based orientation-aware recommender system using IoT smart devices and social networks. *Future Generation Computer Systems*, 108, 97-118. <https://doi.org/10.1016/j.future.2020.02.041>
- Pajuelo Holguera, F. (2021). *Sistemas de recomendación basados en filtrado colaborativo: Aceleración mediante computación reconfigurable y aplicaciones predictivas sensoriales* [Tesis Doctoral, Universidad de Extremadura]. https://dehesa.unex.es/flexpaper/template.html?path=https://dehesa.unex.es/bitstream/10662/12476/1/TDUEX_2021_Pajuelo_Holguera.pdf#page=1
- Pita Pérez, C. E. (2020). Proyecto de sistema de recomendación de filtrado colaborativo basado en machine learning. *Revista PGI. Investigación, Ciencia y Tecnología en Informática*, 48-51.

- Rezaeimehr, F., Moradi, P., Ahmadian, S., Qader, N. N., & Jalili, M. (2018). TCARS: Time- and community-aware recommendation system. *Future Generation Computer Systems*, 78, 419-429. <https://doi.org/10.1016/j.future.2017.04.003>
- Romero, J. G., Riveros, O. A., & Herrera, J. F. (2017). Implementación de la técnica de los k-vecinos en un algoritmo recomendador para un sistema de compras utilizando NFC y android. *Inge Cuc*, 13(1), 9-18. <https://doi.org/10.17981/ingecuc.13.1.2017.01>
- Salas-Rubio, M. I., Ábrego-Almazán, D., & Mendoza-Gómez, J. (2021). Intención, actitud y uso real del e-commerce. *Investigación Administrativa*, 50(127). <https://doi.org/10.35426/iav50n127.03>
- Sang, L., Xu, M., Qian, S., & Wu, X. (2021). Knowledge graph enhanced neural collaborative recommendation. *Expert Systems with Applications*, 164, 113992. <https://doi.org/10.1016/j.eswa.2020.113992>
- Seo, Y. D., Kim, Y. G., Lee, E., & Kim, H. (2021). Group recommender system based on genre preference focusing on reducing the clustering cost. *Expert Systems with Applications*, 183(June), 115396. <https://doi.org/10.1016/j.eswa.2021.115396>
- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104(March), 333-339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- Soler Grillo, S. F. (2021). Comercio electrónico y marketing digital en tiempos de Covid-19. Análisis en una empresa privada peruana. *Gestión en el Tercer Milenio*, 24(48), 59-66. <https://doi.org/10.15381/gtm.v24i48.21819>
- Song, Y. T., & Wu, S. (2020). Slope one recommendation algorithm based on user clustering and scoring preferences. *Procedia Computer Science*, 166, 539-545. <https://doi.org/10.1016/j.procs.2020.02.042>
- Soto-Rodríguez, C. A., & Hernández-Cervantes, J. (2019). Evaluación de tecnologías de sistemas de gestión de contenidos (CMS) para el desarrollo de modelos de negocio electrónicos e-business. *Revista de Desarrollo Económico*, (June), 24-31. <https://doi.org/10.35429/jed.2019.19.6.24.31>
- Srilakshmi, M., Chowdhury, G., & Sarkar, S. (2022). Two-stage system using item features for next-item recommendation. *Intelligent Systems with Applications*, 14, 200070. <https://doi.org/10.1016/j.iswa.2022.200070>
- Tewari, A. S. (2020). Generating items recommendations by fusing content and user-item based collaborative filtering. *Procedia Computer Science*, 167, 1934-1940. <https://doi.org/10.1016/j.procs.2020.03.215>
- Ullal, M. S., Hawaldar, I. T., Soni, R., & Nadeem, M. (2021). The role of machine learning in digital marketing. *SAGE Open*, 11(4). <https://doi.org/10.1177/21582440211050394>

- Uribe, C. I., & Sabogal Neira, D. F. (2021). Marketing digital en micro y pequeñas empresas de publicidad de Bogotá. *Revista Universidad y Empresa*, 23(40), 1-22. <https://doi.org/10.12804/revistas.urosario.edu.co/empresa/a.8730>
- Valcarce, D., Landin, A., Parapar, J., & Barreiro, Á. (2019). Collaborative filtering embeddings for memory-based recommender systems. *Engineering Applications of Artificial Intelligence*, 85(1), 347-356. <https://doi.org/10.1016/j.engappai.2019.06.020>
- Valdiviezo Díaz, P. M. (2019). *Sistema recomendador híbrido basado en modelos probabilísticos* [Tesis de Doctorado, Universidad Politécnica de Madrid]. https://oa.upm.es/57250/1/PRISCILA_MARISELA_VALDIVIEZO_DIAZ_2.pdf
- Valecillos, O. (2019). *Desarrollo de un sistema de recomendaciones para un sitio de comercio electrónico* [Tesis de Licenciatura, Universidad Central de Venezuela]. <http://saber.ucv.ve/bitstream/10872/20508/1/Tesis%20-%20Oscar%20Valecillos%20-%20Final.pdf>
- Vanessa, R., Sarmiento, F., Carolina, D., & Ricaurte, G. (2022). Roxana Vanessa Flores Sarmiento. *Polo Del Conocimiento*, 7(8), 625-640. <https://doi.org/10.23857/pc.v7i8>
- Vega Moreno, B. D., & Ismael Hurtado Ortiz, R. (2021). *Diseño y desarrollo de un sistema de recomendación basado en filtrado colaborativo utilizando datos secuenciales mediante redes neuronales recurrentes*. <http://dspace.ups.edu.ec/handle/123456789/21209>.
- Vences Nava, R., Menéndez Domínguez, V. H., & Medina Peralta, S. (2019). Evaluación de un sistema de recomendación híbrido de trabajos de titulación. *Ingeniería, Investigación y Tecnología*, 20(3), 1-12. <https://doi.org/10.22201/fi.25940732e.2019.20n3.025>
- Vera, J., Villalba-Condori, K., & Castro Cuba-Sayco, S. (2018). Modelo de sistema de recomendación basado en el contexto a partir del análisis de código estático para el desarrollo del pensamiento computacional: caso de programación web. *Education in the Knowledge Society (EKS)*, 19(2), 103-126. <https://doi.org/10.14201/eks2018192103126>
- Vera, P., & Ulloa, M. (2018). *Diseño y desarrollo de un sistema recomendador de contenidos accesibles basados en perfiles de usuarios para ambientes virtuales y objetos de aprendizaje a partir de metadatos de accesibilidad haciendo uso de ontologías* [Tesis de titulación, Universidad Politécnica Salesiana]. <https://dspace.ups.edu.ec/bitstream/123456789/16350/1/UPS-CT007962.pdf>
- Walid, E. (2017). *Un sistema de recomendación basado en perfiles generados por agrupamiento y asociaciones*. 74. <https://riunet.upv.es/bitstream/handle/10251/94049/WALID>

- Wang, H., Hong, Z., & Hong, M. (2022). Research on product recommendation based on matrix factorization models fusing user reviews. *Applied Soft Computing*, 123, 108971. <https://doi.org/10.1016/J.ASOC.2022.108971>
- Wang, J., & Liu, L. (2020). A multi-attention deep neural network model base on embedding and matrix factorization for recommendation. *International Journal of Cognitive Computing in Engineering*, 1, 70-77. <https://doi.org/10.1016/j.ijcce.2020.11.002>
- Xu, L., Zeng, J., Peng, W., Wu, H., Yue, K., Ding, H., Zhang, L., & Wang, X. (2023). Modeling and predicting user preferences with multiple item attributes for sequential recommendations. *Knowledge-Based Systems*, 260, 110174. <https://doi.org/10.1016/J.KNOSYS.2022.110174>
- Yadav, S., Vikesh, Shreyam, & Nagpal, S. (2018). An improved collaborative filtering Based recommender system using bat algorithm. *Procedia Computer Science*, 132, 1795-1803. <https://doi.org/10.1016/j.procs.2018.05.155>
- Yassine, A., Mohamed, L., & Al Achhab, M. (2021). Intelligent recommender system based on unsupervised machine learning and demographic attributes. *Simulation Modelling Practice and Theory*, 107, 102198. <https://doi.org/10.1016/j.simpat.2020.102198>
- Zhang, C., Yang, M., Lv, J., & Yang, W. (2018). An improved hybrid collaborative filtering algorithm based on tags and time factor. *Big Data Mining and Analytics*, 1(2), 128-136. <https://doi.org/10.26599/BDMA.2018.9020012>
- Zhang, F., Qi, S., Liu, Q., Mao, M., & Zeng, A. (2020). Alleviating the data sparsity problem of recommender systems by clustering nodes in bipartite networks. *Expert Systems with Applications*, 149, 113346. <https://doi.org/10.1016/j.eswa.2020.113346>
- Zhang, J., Ma, C., Mu, X., Zhao, P., Zhong, C., & Ruhan, A. (2021). Recurrent convolutional neural network for session-based recommendation. *Neurocomputing*, 437, 157-167. <https://doi.org/10.1016/j.neucom.2021.01.041>
- Zhang, K., Liu, X., Wang, W., & Li, J. (2021). Multi-criteria recommender system based on social relationships and criteria preferences. *Expert Systems with Applications*, 176, 114868. <https://doi.org/10.1016/j.eswa.2021.114868>
- Zhang, Y., & Liu, X. (2021). Learning attention embeddings based on memory networks for neural collaborative recommendation[Formula presented]. *Expert Systems with Applications*, 183, 115439. <https://doi.org/10.1016/j.eswa.2021.115439>
- Ziarani, R. J., & Ravanmehr, R. (2021). Deep neural network approach for a serendipity-oriented recommendation system. *Expert Systems with Applications*, 185, 115660. <https://doi.org/10.1016/j.eswa.2021.115660>