

SISTEMAS DE RECOMENDACIÓN PARA LA TOMA DE DECISIONES. ESTADO DEL ARTE

AUTORES: Bárbara Bron Fonseca ¹
Omar Mar Cornelio ²



DIRECCIÓN PARA CORRESPONDENCIA: barbara.bron.fonseca@gmail.com

Fecha de recepción: 08/04/2021

Fecha de aceptación: 22/12/2021

RESUMEN

Los Sistemas de Recomendación (SR) son técnicas de filtrado de información que nacen con el objetivo de facilitar o asistir al usuario en la toma de una decisión. El principal objetivo de estos sistemas es dar solución a problemas de sobrecarga de información, brindándole al usuario información sintetizada que pueda ser utilizada en la toma de decisiones. Las técnicas utilizadas para llevar a cabo las recomendaciones difieren unas de otras significativamente, tanto en la información requerida como en los procesos necesarios para llevar a cabo estas recomendaciones. La presente investigación tiene como objetivo realizar un estudio sobre el estado del arte actual de los SR. El estudio reveló que aunque los SR más utilizados y más conocidos son los colaborativos y los basados en contenido, no en todas las situaciones son los más adecuados.

PALABRAS CLAVE: Sistemas de Recomendación; estado del arte; filtrado colaborativo; vasado en contenido; basados en conocimiento.

RECOMMENDATION SYSTEMS FOR DECISION MAKING. STATE OF THE ART**ABSTRACT**

Recommender Systems (RS) are information filtering techniques that were born with the aim of facilitating or assisting the user in making a decision. The main objective of these systems is to solve information overload problems, providing the user with synthesized information that can be used in decision making. The techniques used to carry out the recommendations differ from each other significantly, both in the information required and in the processes necessary to carry out these recommendations. This research aims to conduct a study on the current state of the art of SR.

¹ Profesor de la Carrera Ingeniería Industrial. Centro Universitario Municipal Guanajay. Universidad de Artemisa. Artemisa. Cuba. ORCID: <https://orcid.org/0000-0001-9463-8408>. Correo electrónico: barbara.bron.fonseca@gmail.com

² Centro de Estudio de Matemática Computacional, Facultad de Ciencias y Tecnologías Computacionales, Universidad de las Ciencias Informáticas. La Habana. Cuba. ORCID: <https://orcid.org/0000-0002-0689-6341>. Correo electrónico: omarmar@uci.cu

The study revealed that although the most widely used and well-known SRs are collaborative and content-based, they are not the most appropriate in all situations.

KEYWORDS: Recommender Systems; state of the art; collaborative filtering; packed in content; knowledge based.

INTRODUCCIÓN

Pedir recomendaciones ante incertidumbres es una condición humana y en los últimos años se ha convertido en una condición automática cuya exactitud depende de diversos factores. En este escenario surgen los Sistemas de Recomendación (SR) los cuales cuentan con una función de recomendación inteligente que proporciona a los usuarios información valiosa de datos masivos de internet y de grandes bases de datos (Zhang et al., 2018).

Los SR son técnicas de filtrado de información que nacen con el objetivo de facilitar o asistir al usuario en la toma de una decisión (García & Gil). Estos sistemas tienen como principal tarea seleccionar y clasificar cierta información de acuerdo con los requerimientos del usuario por lo que son muy atractivos en situaciones donde la cantidad de información que se ofrece al usuario supera ampliamente cualquier capacidad individual de exploración (Ramírez, 2018). Los SR han demostrado mejorar el proceso de toma de decisiones y la calidad de estas cuando no hay suficiente conocimiento personal o experiencia de las alternativas (Pathak et al., 2010), elemento que es comprensible ante los enormes volúmenes de información que se generan en la actualidad (Resnick & Varian, 1997).

Formalmente, puede definirse a un SR como una función que devuelve una lista de ítems ordenados por su utilidad con respecto al usuario u . Los SR se definen como un campo de la Inteligencia Artificial en donde los investigadores se centran explícitamente en evaluar lo relevante de aquellos elementos que el usuario no conoce. El principal objetivo de estos sistemas es dar solución a problemas de sobrecarga de información, brindándole al usuario información sintetizada que pueda ser utilizada en la toma de decisiones.

Las entidades principales que intervienen en un SR son los usuarios y los objetos. El usuario es la persona que utiliza el sistema de recomendación, ya sea para recibir recomendaciones sobre nuevos objetos que aún no conoce o para aportarlas sobre objetos que ya conoce. Los objetos pueden entenderse como los elementos potencialmente recomendables. Para esta investigación los objetos estarán definidos por los Indicadores identificados en (Lugo 2012) para la evaluación de proyectos y que están almacenados en una base de datos para su posterior análisis. De forma general los RS, están formados por tres componentes:

Datos de entrada: la información que el usuario debe comunicar al sistema para generar una recomendación.

Algoritmo de recomendación: proceso en el que se combinan los datos almacenados previamente y los datos de entrada proporcionados por el usuario, para generar las recomendaciones.

Base de datos: representa toda la información almacenada en el sistema antes de comenzar el proceso de recomendación.

Los datos de entrada del sistema pueden ser de varios tipos, las más comunes son:

- Valoraciones de los usuarios (conocidas como ratings). Estas valoraciones pueden ser puntuaciones numéricas o textuales como “me interesa / no me interesa”.
- Datos demográficos, que recogen los datos genéricos de los usuarios, como edad, género, educación, nacionalidad, etc. suelen introducirse por ellos mismos de forma explícita.
- Datos de contenido, basados en análisis textual de los documentos de los objetos ya valorados por el usuario o en las características descriptivas de los objetos.
- Ejemplo inicial de los objetos que le interesa analizar. Siendo este el escenario a contemplar en esta investigación.

De estas entradas dependerán después los distintos tipos de algoritmos de recomendación que se puedan utilizar. Las recomendaciones constituyen las salidas del sistema. Estas salidas pueden tomar una de las siguientes formas o ambas en el mejor de los casos:

- Una recomendación, que es una lista formada por los L objetos más útiles para ser analizados el usuario.
- Una explicación (Tintarev & Masthoff, 2007), que constituye una justificación asociado a cada indicador de la lista de recomendaciones.



Figura 1. Elementos de un Sistema de recomendación.

Las técnicas utilizadas para llevar a cabo las recomendaciones difieren unas de otras significativamente, tanto en la información requerida como en los procesos necesarios para llevar a cabo estas recomendaciones. La presente investigación tiene como objetivo realizar un estudio sobre el estado del arte actual de los Sistemas de Recomendación.

DESARROLLO

Aunque esencialmente todos los SR tienen el mismo objetivo, guiar al usuario mediante recomendaciones a aquellos objetos que más le pueden interesar la técnica de recomendación varía según los procesos. Basado en estos procesos, se puede clasificar los RS en los siguientes grupos:

Basados en contenido (Chen et al., 2016; Gao et al., 2016; Gatchalee et al., 2013; Hu & Pu, 2010; Miao, 2014; Palopoli et al., 2013; Pazzani et al., 1996; Penny et al., 2017): también conocido como

filtrado cognitivo. En este grupo la recomendación de un objeto se basa en la similitud con otros objetos que el usuario ha adquirido anteriormente.

Filtrado colaborativo (Aditya et al., 2016; Castagnos et al., 2010; Chen & Pu, 2005; Gaikwad et al., 2018; Goldberg et al., 1992; Hwangbo et al., 2018; Jiang et al., 2019; Pu et al., 2008): también conocido como filtrado social. Construyen la recomendación como una agregación estadística/probabilística de las preferencias de otros usuarios.

Basado en inspección (survey-based recommender systems) (Cho & Ryu, 2008; Fan et al., 2008; Finder; Souali et al., 2011): son aquellos que solicitan explícitamente información antes de proporcionar cualquier recomendación. Son sistemas que piden que los usuarios envíen explícitamente la información y/o preferencias personales antes de proporcionar cualquier recomendación. El sistema recomendador demográfico es el más conocido de este tipo, en este tipo de sistema se utiliza el conocimiento demográfico que se tiene de los usuarios y sus opiniones sobre los productos recomendados como base para las recomendaciones.

Sistemas de filtrado económico: filtran la información teniendo en cuenta factores de costo, como pueden ser el costo de productos adquiridos, el tamaño de productos visitados u otros rasgos evidenciados en las visitas realizadas previamente por los usuarios.

Sistemas de filtrado basado en reglas: Este enfoque filtra datos e información según un conjunto de reglas que expresa la política de filtrado de la información. Estas reglas pueden ser parte del contenido del perfil del usuario. Este tipo de sistema presenta dos métodos alternativos de filtrado basados en las reglas: reglas basadas en estereotipo y reglas personales.

Sistemas basados en Actividades (Itmazi, 2005): Se basan fuertemente en las entradas que ofrecen los usuarios, ya sea a través de la navegación o las actividades que realizan en el sistema. Los usuarios dejan huellas mientras que navegan por la Web, esto es, las actividades que ellos realizaron durante su navegación, contienen mucha información oculta acerca de la relación entre los recursos Web y los usuarios. Si tales historiales de navegación de los usuarios son registrados, podemos descubrir conocimiento escondido sobre recursos interesantes y usuarios sin peticiones explícitas a ellos.

Sistemas de recomendación basados en conocimiento (Burke, 2000, 2002; Huseynov et al., 2016; Ku et al., 2014; Luo, 2012; Martín-Vicente et al., 2009; Xiaosen, 2015; Ya, 2010): realizan recomendaciones partiendo del conocimiento que da el usuario sobre sus necesidades, y del conocimiento de los objetos a recomendar, buscando los que mejor se adapten a las necesidades de los usuarios, apoyados fundamentalmente en el razonamiento basado en casos.

Sistemas de recomendación híbridos (Aprilianti et al., 2016; Basu et al., 1998; Dong et al., 2013; Lu et al., 2015; Qiu et al., 2010; Saini et al., 2017; Xue et al., 2015): Los sistemas híbridos combinan dos o más técnicas de recomendación para incrementar el rendimiento general del sistema resultante, atenuando las deficiencias de cada una de las técnicas utilizadas por separado.

En la actualidad existen situaciones en las que los modelos anteriores no son aplicables por problemas de datos o de tiempo. Para este tipo de situaciones se han presentado varias alternativas, como pueden ser los Sistemas de Recomendación híbridos o los basados en conocimiento. Estos últimos utilizan el conocimiento que proporciona el usuario sobre sus necesidades y el conocimiento que tiene el sistema sobre los objetos para desde un enfoque basado en conocimiento,

realizar recomendaciones de los objetos que mejor cubren las necesidades de los usuarios. Los tipos de SR serán descritos en detalles a continuación.

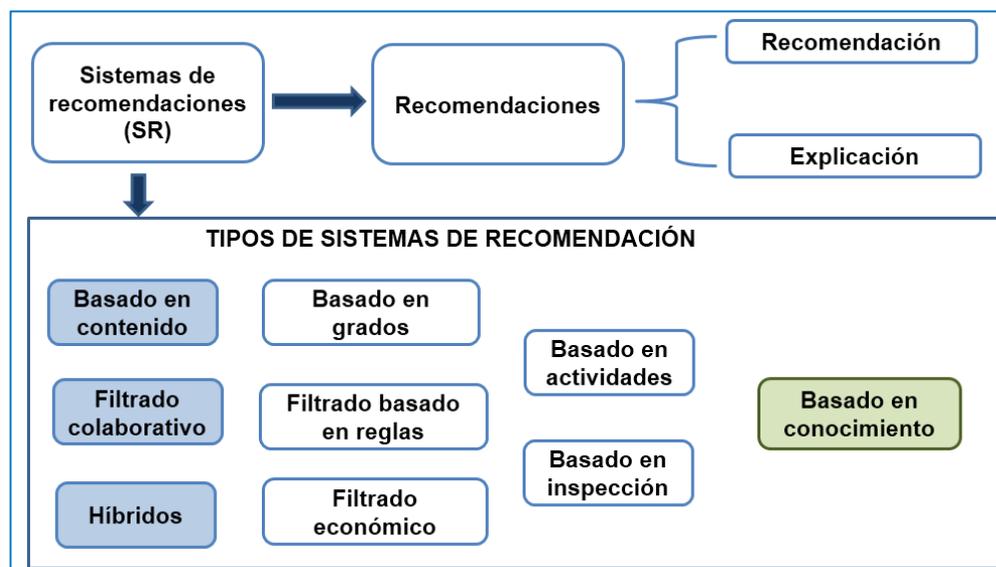


Figura 2. Tipos de Sistemas de recomendación.

Sistema de recomendación basado en conocimiento

Los sistemas de recomendación basados en conocimiento realizan sugerencias haciendo inferencias sobre las necesidades del usuario y sus preferencias (Freire et al., 2016; Jannach & Friedrich, 2013). El enfoque basado en conocimiento se distingue por la utilización de conocimiento sobre cómo un objeto en particular puede satisfacer las necesidades del usuario, y por lo tanto tiene la capacidad de razonar sobre la relación entre una necesidad y la posible recomendación que se mostrará (Barranco et al., 2006; Maridueña-Arroyave & Febles-Estrada, 2016; Padilla et al., 2018). Se basan en la construcción de perfiles de usuarios como una estructura de conocimiento que apoye la inferencia la cual puede ser enriquecida con la utilización de expresiones que emplea lenguaje natural (Herrera, 2000).



Figura 3. Sistema de recomendación basado en conocimiento.

Existen múltiples técnicas para explotar el conocimiento que el usuario aporta sobre sus necesidades y sobre los objetos que se pueden recomendar. Una de las técnicas de recomendación utilizada en estos sistemas es la técnica de razonamiento basado en casos (Hammond, 2012). El razonamiento basado en casos recupera casos pasados similares ya resueltos y los reutiliza para la solución del problema actual. En los SR puede traducirse como la búsqueda de objetos similares a los que resultaron más satisfactorios al usuario en el pasado (Lorenzi & Ricci, 2005).

En estos sistemas los usuarios dan un ejemplo del tipo de objetos que están buscando, y el sistema buscará y recomendará objetos similares al ejemplo dado. Estos sistemas deben permitir que los usuarios refinen sus búsquedas declarando o modificando algunas de los atributos del ejemplo dado. Existen dos técnicas fundamentales de recomendación basada en el conocimiento que son Basado en restricciones (*Constraint-based*) y Basado en casos (*Case-based*).

En el caso de la búsqueda de similitudes, el usuario debe seleccionar un elemento determinado del catálogo (llamado ejemplo inicial) y se deben mostrar como respuesta otros elementos similares (Mar Cornelio et al., 2020). Para realizar esta recomendación, se recupera inicialmente un gran conjunto de entidades candidatas de la base de datos. Este conjunto se ordena según la similitud con la fuente y los candidatos principales son devueltos al usuario (Burke, 2000). Para este enfoque se utiliza la implicación lógica del tipo:

“Si el usuario requiere X , el ítem a recomendar debe tener la característica X' ”.

Sistemas de recomendación basado en contenido

Tienen como base de la predicción el objeto y sus características. Para un usuario concreto se analizan sus gustos o interés mostrando objetos de características similares. De esta manera, las predicciones son del tipo: *“Te han gustado estos L productos, por lo que te puede gustar éste producto X que se parece mucho.”*. La figura 2, muestra un esquema de su aplicación.



Figura 4. Sistema de recomendación basado en contenido.

Sistemas de recomendación Filtrado colaborativo

Basan su funcionamiento en la información que se tiene acerca de los usuarios. El sistema analiza las compras, gustos o calificaciones de todos los usuarios y los agrupa, empleando dicha información en conjuntos de usuarios similares o con las mismas preferencias. Para un usuario dado, se recomiendan productos que han gustado a usuarios similares pero que éste aún no ha consumido.



Figura 5. Sistema de recomendación filtrado colaborativo.

Minería de datos en los sistemas de recomendación

La Minería de Datos (Data Mining, DM) forma parte del proceso de Descubrimiento de conocimiento en bases de datos (Knowledge Discovery in Databases, KDD) con la cual se realiza una búsqueda sobre grandes juegos de datos, los cuales mayoritariamente están almacenados en bases de datos relacionales o no. Esta búsqueda se lleva a cabo utilizando métodos matemáticos, estadísticos o algorítmicos para extraer información y/o patrones. El objetivo principal de la DM es crear un proceso automatizado que toma como punto de partida los datos y cuya meta es la ayuda a la toma de decisiones.

En función del problema que se pretenda resolver, la extracción de patrones se puede abordar desde dos perspectivas distintas: desde el punto de vista predictivo, en el que se intenta pronosticar el comportamiento del modelo según los datos disponibles, o desde el punto de vista descriptivo, donde se intenta descubrir patrones que describan los datos (Fonseca et al., 2020).

En esta investigación se tomará como referente los procesos orientados al problema de la sumarización, donde se realiza el proceso de análisis de datos desde diferentes perspectivas para encontrar patrones ocultos que los describan y resumirlos para obtener información útil.

La DM surge como una tecnología capaz de resolver los conflictos surgidos con el crecimiento exponencial de los datos almacenados, dentro de los problemas de mayor incidencia se destaca (Vázquez Y. et al., 2018):

- **Escalabilidad:** los algoritmos de minería de datos deben de ser escalables para manejar conjuntos de datos con tamaños de gigabytes, terabytes o incluso petabytes. En este sentido, muchos algoritmos de minería de datos utilizan estrategias de búsqueda especiales para manejar problemas de búsqueda exponenciales.
- **Alta dimensionalidad:** en los procesos actuales se almacenan conjuntos de datos con cientos o incluso miles de atributos. Los conjuntos de datos que tienen componentes espaciales o temporales también tienden a presentar una alta dimensionalidad. Las técnicas tradicionales de análisis de datos no siempre trabajan correctamente con datos con alta dimensionalidad. Además, en algunos algoritmos de análisis de datos, la complejidad computacional crece rápidamente a medida que aumenta la dimensionalidad.
- **Datos complejos y heterogéneos:** en los últimos años han surgido tipos de datos cada vez más complejos. Las técnicas de minería de datos desarrolladas para abordar tales tipos complejos de datos deben tener en cuenta las relaciones existentes en los datos.
- **Distribución y propiedad de los datos:** en algunas ocasiones, los datos que necesitan ser analizados no se encuentran almacenados en una única localización o no pertenecen a una única organización, sino que están geográficamente distribuidos entre los recursos de diferentes entidades. Esto hace que sea necesario el desarrollo de técnicas de minería de datos distribuidas que incluyan la reducción de la cantidad de comunicación y el tratamiento de la seguridad de los datos.

Un concepto que se puede aplicar al campo de la minería de datos, es el de soft computing que agrupa a un conjunto de técnicas, como la Lógica Difusa o la Sumarización lingüística, cuya

característica principal es la tolerancia a imprecisión e incertidumbre, lo que ayuda a expresar el conocimiento extraído de forma fácilmente interpretable por el experto (Batyrrshin & Sheremetov, 2006). Con el objetivo de elevar el grado de utilidad de los resúmenes, muchos sistemas de recomendación asumen como imprescindible el uso de la soft computing, ya que es utilizado para construir las explicaciones de las recomendaciones.

Sumarización Lingüística de Datos para agregar explicaciones a las recomendaciones

La extracción de información de un conjunto de datos sin procesar suele ser muy engorroso para aquellas personas que tienen la responsabilidad de tomar decisiones basadas en ese conocimiento. Los expertos en el área de toma de decisiones insisten en la necesidad de integrar técnicas de sintetización del conocimiento almacenado, de manera más interpretable, ya que no siempre la información almacenada atendiendo a criterios numéricos ayuda a facilitar la interpretación de los resultados (Fonseca et al., 2019).

Una manera muy utilizada para resolver los problemas de análisis e interpretación de la información es implementando funciones de descubrimiento de conocimiento a través de la Sumarización Lingüística de Datos (SLD), ya que favorece la presentación de información al usuario, y que por tanto facilita el manejo y la interpretabilidad de dicha información por parte de este (Bello & Verdegay, 2010). La acción de resumir consiste en reducir una cierta cantidad de información a términos breves y precisos. No sólo es posible realizar resumen lingüístico de información representada textualmente, sino que también puede hacerse de información con otras representaciones como las numéricas (Smits et al., 2017).

La SLD es una de las poderosas técnicas de descubrimiento de conocimiento descriptivo de un gran conjunto de datos, capaz de extraer conocimiento potencial, útil y abstracto de datos tanto numéricos como categóricos (Boran et al., 2016). El resumen lingüístico de un conjunto de datos es un proceso cuya complejidad depende linealmente del tamaño del conjunto de datos y exponencialmente del tamaño del vocabulario difuso (Smits et al., 2019).

Interpretabilidad de las recomendaciones

Uno de los elementos de importancia en la minería de datos, además de la precisión predictiva y el interés, es la comprensibilidad de los resultados del proceso para el usuario. En este aspecto, la introducción de métodos para modelar la incertidumbre e imprecisión de una forma sencilla y directamente interpretable por el usuario.

La interpretabilidad de los datos es una propiedad particularmente importante en áreas y/o procesos donde los humanos deben tomar decisiones apoyados en sistemas computacionales donde el conocimiento previo es utilizado en procesos de análisis de datos y la modificación de este conocimiento por los mecanismos de aprendizaje debe ser chequeado y finalmente en casos donde las soluciones deben ser explicadas o justificadas a personas no experta (Cornelio et al.).

La capacidad de predicción de un algoritmo de extracción de conocimiento debe estar equilibrada con la interpretabilidad de los resultados que son arrojados para el usuario. Si se ajusta arbitrariamente el sistema, para garantizar capacidad de predicción, se puede perder

significativamente en interpretabilidad. En este escenario la softcomputing se muestra como la estrategia adecuada para crear sistemas que garanticen la claridad e interpretación de los resultados.

A pesar de la popularidad y el constante crecimiento de los Sistemas de Recomendación, aún existe desconfianza en los usuarios, los cuales no se sienten seguros de usar y confiar en las recomendaciones recibidas. Su aceptación en diversos dominios no ha sido muy amplia, dado que los usuarios al desconocen su funcionamiento y limitan su utilización en la toma de decisiones en procesos reales.

La revisión de trabajos recientes reportan un gran número de investigaciones destinadas a disminuir dichas limitaciones. Las respuestas académicas se enfocan en mostrar razones por las que se obtienen las recomendaciones y fundamentar las mismas. Una forma de incrementar la aceptación de dichos sistemas, ha sido dotándolos de mecanismos de explicación de las sugerencias ofrecidas. En esta investigación las explicaciones se realizan a partir de los resúmenes lingüísticos.

La explicación en los SR cuenta con múltiples objetivos, desde lograr inspirar confianza al usuario hasta ayudarlo a tomar una adecuada decisión. Todo depende de lo que se persiga. En (Alshammari et al., 2019; Gkika & Lekakos, 2014; Narayanan & McGuinness, 2008; Tintarev & Masthoff, 2007; Yang et al., 2018) se encuentran estudios acerca de los objetivos potenciales de la explicación en las recomendaciones emitidas por los SR, dentro de las cuales se destacan:

- **Transparencia:** explicar cómo funciona el SR.
- **Escrutabilidad:** permitir al usuario decir si el SR funciona bien o mal.
- **Confianza:** incrementar la confianza de los usuarios en el SR.
- **Eficacia:** ayudar a los usuarios a tomar buenas decisiones.
- **Persuasión:** convencer a los usuarios para que prueben o compren las recomendaciones.
- **Eficiencia:** ayudar a los usuarios a tomar decisiones rápidas.
- **Satisfacción:** incrementar la facilidad de uso o disfrute del SR.

Métricas de evaluación de las recomendaciones

La elección de una métrica específica para evaluar el rendimiento de las recomendaciones depende de los objetivos que el sistema debe cumplir. Teniendo siempre como premisa que la evaluación final de cualquier sistema de recomendación está dada por el juicio de sus usuarios.

En la bibliografía científica se reconocen varias métricas para evaluar las recomendaciones emitidas por un SR. En (Lü et al., 2012) se realiza un resumen de las más utilizadas tal como se muestra en la tabla 1.

Tabla 1. Resumen de las métricas de recomendación.

Nombre	Símbolo	Pf.	Ámbito	Cf.	L
<i>Mean Absolute Error</i>	MAE	P	Precisión de la calificación	No	No
<i>Root Mean Squared Error</i>	RMSE	P	Precisión de la calificación	No	No
<i>Precision</i>	$P(L)$	G	Precisión de la clasificación	No	Sí
<i>Recall</i>	$R(L)$	G	Precisión de la clasificación	No	Sí
<i>F₁-score</i>	$F_1(L)$	G	Precisión de la clasificación	No	Sí
<i>Spearman</i>	ρ	G	Correlación de la calificación	Sí	No

<i>Kendall</i>	τ	G	Correlación de la calificación	Sí	No
<i>Pearson</i>	PCC	G	Correlación de la calificación	No	No
<i>Discounted Cumulative Gain</i>	$DCG(b,L)$	G	Satisfacción y precisión	Sí	Sí
<i>Rank-biased Precision</i>	$RBP(p,L)$	G	Satisfacción y precisión	Sí	Sí
<i>Half-life utility</i>	$HL(L)$	G	Satisfacción	Sí	Sí
<i>Popularidad</i>	$N(L)$	P	Novedad	No	Sí
<i>Información propia</i>	$U(L)$	G	Inesperado	No	Sí
<i>Intra-similarity</i>	$I(L)$	P	Intra-diversidad	No	Sí
<i>Hamming distance</i>	$H(L)$	G	Inter-diversidad	No	Sí
<i>Cobertura</i>	$COV(L)$	G	Cobertura y diversidad	No	Sí

Donde:

Pf: indica si es preferible obtener un valor pequeño (P) o grande (G) en la métrica.

Ámbito: especifica qué es lo que mide la métrica.

Cf: indica si la evaluación de la métrica depende de la clasificación, es decir, del orden de preferencia que el sistema ha predicho sobre los objetos para el usuario.

L: especifica si la métrica es dependiente del tamaño de la lista de recomendaciones.

A continuación se describen las métricas más utilizadas para evaluar la calidad de las recomendaciones emitidas. Las métricas son presentadas según su ámbito:

Precisión de la calificación

Para medir la proximidad de las predicciones a las calificaciones reales se propone el uso de las métricas *Mean Absolute Error* (MAE) y *Root Mean Squared Error* (RMSE) las cuales se definen según las ecuaciones 1 y 2 respectivamente. En estas métricas mientras menores resulten los valores, mayor será la precisión de las predicciones.

$$MAE = \frac{1}{|E^P|} \sum_{(i,\alpha) \in E^P} |r_{i\alpha} - \hat{r}_{i\alpha}| \quad (1)$$

$$RMSE = \sqrt{\frac{1}{|E^P|} \sum_{(i,\alpha) \in E^P} (r_{i\alpha} - \hat{r}_{i\alpha})^2} \quad (2)$$

Donde:

$r_{i\alpha}$: es el valor de la calificación real del usuario i sobre el ítem α ,

$\hat{r}_{i\alpha}$: es el valor predicho por el sistema para esa calificación,

E^P : subconjunto que se comparará con las correspondientes predicciones para evaluar la eficacia de las recomendaciones.

Para identificar las recomendaciones más relevantes para el usuario final del SR, asumiendo que le interesan los indicadores en los L primeros puestos, se considera adecuado utilizar las métricas *Precision* (P) y *Recall* (R). Para un usuario i , se definen las siguientes ecuaciones.

$$P_i(L) = \frac{d_i(L)}{L} \quad (3)$$

$$R_i(L) = \frac{d_i(L)}{D_i} \quad (4)$$

Donde:

$d_i(L)$: indica el número de indicadores relevantes entre los L primeros de la lista de recomendación,
 D_i : es el número total de indicadores relevantes para el usuario i .

De esta manera, si se promedian todos los valores de *Precision* y *Recall* para todos los usuarios, se obtienen los valores medios $P(L)$ y $R(L)$.

Métrica de Satisfacción

Con el objetivo de evaluar la utilidad de una lista de recomendación para un usuario, se utiliza la métrica *Half-life Utility* (HL(L)), la cual se basa en la suposición de que la probabilidad de que un usuario examine un indicador recomendado decrece exponencialmente con la clasificación de los indicadores. La utilidad esperada para las recomendaciones dadas a un usuario i se define según la ecuación (5).

$$HL_i = \sum_{\alpha=1}^N \frac{\max(r_{i\alpha} - d, 0)}{2^{(0_{i,\alpha}-1)/(h-1)}} \quad (5)$$

Donde:

$0_{i,\alpha}$: representa la posición en la clasificación predicha para el indicador α en la lista de recomendación del usuario i ,

d : es la calificación por defecto (por ejemplo se puede situar en la calificación media de entre las posibles),

h : es la posición del indicador de la lista con un 50% de probabilidades de que el usuario finalmente lo examine.

En esta métrica los objetos se ordenan por su predicción $\hat{r}_{i\alpha}$ en orden descendente. Cuando HL_i se promedia para todos los usuarios, se obtiene una utilidad para todo el sistema.

CONCLUSIONES

Aunque los Sistemas de Recomendación más utilizados y más conocidos son los colaborativos y los basados en contenido, no en todas las situaciones son los más adecuados. Por ejemplo, los Sistemas de Recomendación colaborativos necesitan partir de una base de datos de valoraciones de los usuarios sobre los objetos almacenados para poder realizar recomendaciones precisas y acertadas a cualquiera de estos usuarios. Los basados en contenido buscan nuevos objetos a recomendar basándose en los valorados por el usuario en el pasado. Por tanto, estos sistemas

requieren que el usuario haya valorado un mínimo número de objetos para realizar las recomendaciones adecuadas a su proceso de búsqueda de nuevos objetos. Siendo el arranque en frío una de sus principales desventajas.

El estudio sobre las diferentes técnicas y herramientas para la construcción de SR permitió identificar el resumen lingüístico como una solución viable para agregar explicaciones a las recomendaciones a partir de la Sumarización Lingüística de Datos.

REFERENCIAS BIBLIOGRÁFICAS

- Aditya, P., Budi, I., & Munajat, Q. (2016). A comparative analysis of memory-based and model-based collaborative filtering on the implementation of recommender system for E-commerce in Indonesia: A case study PT X. 2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS),
- Alshammari, M., Nasraoui, O., & Sanders, S. (2019). Mining Semantic Knowledge Graphs to Add Explainability to Black Box Recommender Systems. *IEEE Access*, 7, 110563-110579. <https://doi.org/10.1109/ACCESS.2019.2934633>
- Aprilianti, M., Mahendra, R., & Budi, I. (2016). Implementation of weighted parallel hybrid recommender systems for e-commerce in indonesia. 2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS),
- Barranco, M., Pérez, L., & Martínez, L. (2006). Un sistema de recomendación basado en conocimiento con información lingüística multigranular. In *Proceedings of the SIGEF XIII: Optimization techniques: Fuzziness and nonlinearity for management and economy*.
- Basu, C., Hirsh, H., & Cohen, W. (1998). Recommendation as classification: Using social and content-based information in recommendation. Aaai/iaai,
- Batyrshin, I. Z., & Sheremetov, L. B. (2006, 3-6 June 2006). Perception Based Associations in Time Series Data Bases. NAFIPS 2006 - 2006 Annual Meeting of the North American Fuzzy Information Processing Society,
- Bello, R., & Verdegay, J. L. (2010). Los conjuntos aproximados en el contexto de la Soft Computing. *Revista Cubana de Ciencias Informáticas*, 4 pp. 5-24. .
- Boran, F. E., Akay, D., & Yager, R. R. (2016). An overview of methods for linguistic summarization with fuzzy sets. *Expert Systems with Applications*, 61, 356-377.
- Burke, R. (2000). Knowledge-based recommender systems. *Encyclopedia of library and information systems*, 69(Supplement 32), 175-186.
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, 12(4), 331-370.
- Castagnos, S., Jones, N., & Pu, P. (2010). Eye-tracking product recommenders' usage. Proceedings of the fourth ACM conference on Recommender systems,
- Cornelio, O. M., Gulín, J. G., Fonseca, B. B., & Ching, I. S. Experiencia en la evaluación de competencias en un sistema de laboratorios a distancia. Anais do Encontro Virtual de Documentação em Software Livre e Congresso Internacional de Linguagem e Tecnologia Online,
- Chen, C., Wang, D., & Ding, Y. (2016). User actions and timestamp based personalized recommendation for e-commerce system. 2016 IEEE International Conference on Computer and Information Technology (CIT),

- Chen, L., & Pu, P. (2005). Trust building in recommender agents. Proceedings of the Workshop on Web Personalization, Recommender Systems and Intelligent User Interfaces at the 2nd International Conference on E-Business and Telecommunication Networks,
- Cho, Y. S., & Ryu, K. H. (2008). Implementation of personalized recommendation system using demographic data and RFM method in e-commerce. 2008 4th IEEE International Conference on Management of Innovation and Technology,
- Dong, F., Luo, J., Zhu, X., Wang, Y., & Shen, J. (2013). A personalized hybrid recommendation system oriented to e-commerce mass data in the cloud. 2013 IEEE International Conference on Systems, Man, and Cybernetics,
- Fan, Y., Shen, Y., & Mai, J. (2008). Study of the model of e-commerce personalized recommendation system based on data mining. 2008 International Symposium on Electronic Commerce and Security,
- Finder, L. Intelligent user profiling using large-scale demographic data. *Artificial Intelligence Magazine*, *v18 i2*, 37-45.
- Fonseca, B. B., Benítez, L. C. M., & Oliva, Á. M. H. (2019). La estructura de desglose del trabajo como mecanismo viable para la generación de proyectos exitosos. *Serie Científica de la Universidad de las Ciencias Informáticas*, *12(5)*, 63-75.
- Fonseca, B. B., Cornelio, O. M., & Marzo, F. R. R. (2020). Tratamiento de la incertidumbre en la evaluación del desempeño de los Recursos Humanos de un proyecto basado en conjuntos borrosos. *Serie Científica de la Universidad de las Ciencias Informáticas*, *13(6)*, 84-93.
- Freire, J. B., Villagomez, M. M., Delgado, M. A. S., & González, M. P. (2016). Modelo de recomendación de productos basado en computación con palabras y operadores OWA [A product recommendation model based on computing with word and OWA operators]. *International Journal of Innovation and Applied Studies*, *16(1)*, 78.
- Gaikwad, R. S., Udmale, S. S., & Sambhe, V. K. (2018). E-commerce recommendation system using improved probabilistic model. In *Information and Communication Technology for Sustainable Development* (pp. 277-284). Springer.
- Gao, Z., Li, Z., & Niu, K. (2016). Solutions for problems of existing E-commerce recommendation system. 2016 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW),
- García, F. J., & Gil, A. B. Personalización de Sistemas de Recomendación. *Universidad de Salamanca*.
- Gatchalee, P., Li, Z., & Supnithi, T. (2013). Ontology development for SMEs E-commerce website based on content analysis and its recommendation system. 2013 International Computer Science and Engineering Conference (ICSEC),
- Gkika, S., & Lekakos, G. (2014, 6-7 Nov. 2014). Investigating the Effectiveness of Persuasion Strategies on Recommender Systems. 2014 9th International Workshop on Semantic and Social Media Adaptation and Personalization,
- Goldberg, D., Nichols, D., Oki, B. M., & Terry, D. (1992). Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, *35(12)*, 61-70.
- Hammond, K. J. (2012). *Case-based planning: Viewing planning as a memory task*. Elsevier.
- Herrera, F. (2000). A 2-tuple fuzzy linguistic representation model for computing with words. *8(6)*, 746-752. <https://doi.org/10.1109/91.890332>
- Hu, R., & Pu, P. (2010). A study on user perception of personality-based recommender systems. International Conference on User Modeling, Adaptation, and Personalization,
- Huseynov, F., Huseynov, S. Y., & Özkan, S. (2016). The influence of knowledge-based e-commerce product recommender agents on online consumer decision-making. *Information Development*, *32(1)*, 81-90.
- Hwangbo, H., Kim, Y. S., & Cha, K. J. (2018). Recommendation system development for fashion retail e-commerce. *Electronic Commerce Research and Applications*, *28*, 94-101.

- Itmazi, J. (2005). Sistema flexible de Gestión del eLearning para soportar el aprendizaje en las Universidades tradicionales y abiertas.
- Jannach, D., & Friedrich, G. (2013). Tutorial: recommender systems. International Joint Conference on Artificial Intelligence Beijing,
- Jiang, L., Cheng, Y., Yang, L., Li, J., Yan, H., & Wang, X. (2019). A trust-based collaborative filtering algorithm for E-commerce recommendation system. *Journal of Ambient Intelligence and Humanized Computing*, 10(8), 3023-3034.
- Ku, Y.-C., Peng, C.-H., & Yang, Y.-C. (2014). Consumer preferences for the interface of e-commerce product recommendation system. International Conference on HCI in Business,
- Lorenzi, F., & Ricci, F. (2005). Case-based recommender systems. In *Encyclopedia of Data Warehousing and Mining* (pp. 124-128). IGI Global.
- Lu, J., Wu, D., Mao, M., Wang, W., & Zhang, G. (2015). Recommender system application developments: a survey. *Decision Support Systems*, 74, 12-32.
- Lü, L., Medo, M., Yeung, C. H., Zhang, Y.-C., Zhang, Z.-K., & Zhou, T. (2012). Recommender systems. *Physics reports*, 519(1), 1-49.
- Lugo, J. A. (2012). Modelo para el control de la ejecución de proyectos basado en indicadores y lógica borrosa.
- Luo, Y. (2012). An analysis of Web mining-based recommender systems for e-commerce. Proceedings of the 2012 International Conference on Computer Application and System Modeling,
- Mar Cornelio, O., Bron Fonseca, B., & Gulín González, J. (2020). Sistema de Laboratorios Remoto para el estudio de la Microbiología y Parasitología Médica. *Revista Cubana de Informática Médica*, 12(2).
- Maridueña-Arroyave, M. R., & Febles-Estrada, A. (2016). A college degree recommendation model. *DYNA*, 83, 29-34. http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0012-73532016000500003&nrm=iso
- Martín-Vicente, M. I., Gil-Solla, A., Ramos-Cabrer, M., Blanco-Fernández, Y., & López-Nores, M. (2009). Avoiding fake neighborhoods in e-commerce collaborative recommender systems: A semantic approach. 2009 Fourth International Workshop on Semantic Media Adaptation and Personalization,
- Miao, J. F. (2014). Design and implementation of personalization recommendation system in mobile e-commerce. *Advanced Materials Research*,
- Narayanan, T., & McGuinness, D. L. (2008, 10-15 Feb. 2008). Towards Leveraging Inference Web to Support Intuitive Explanations in Recommender Systems for Automated Career Counseling. First International Conference on Advances in Computer-Human Interaction,
- Padilla, R. C., Ruiz, J. G., Alava, M. V., & Vázquez, M. L. (2018). *Modelo de recomendación basado en conocimiento empleando números SVN*. Infinite Study.
- Palopoli, L., Rosaci, D., & Sarnè, G. M. (2013). Introducing specialization in e-commerce recommender systems. *Concurrent Engineering*, 21(3), 187-196.
- Pathak, B., Garfinkel, R., Gopal, R., Venkatesan, R., & Yin, F. (2010). Empirical Analysis of the Impact of Recommender Systems on Sales. *Management Information Systems*, 27, 159-188.
- Pazzani, M. J., Muramatsu, J., & Billsus, D. (1996). Syskill & Webert: Identifying interesting web sites. *AAAI/IAAI*, Vol. 1,
- Penny, S. G., Akella, S., Buehner, M., Chevallier, M., Counillon, F., Draper, C., Frolov, S., Fujii, Y., Karspeck, A., & Kumar, A. (2017). Coupled Data Assimilation for Integrated Earth System Analysis and Prediction: Goals, Challenges, and Recommendations. (201801), 45.
- Pu, P., Chen, L., & Kumar, P. (2008). Evaluating product search and recommender systems for E-commerce environments. *Electronic Commerce Research*, 8(1-2), 1-27.

- Qiu, Z., Chen, M., & Huang, J. (2010). Design of multi-mode e-commerce recommendation system. 2010 Third International Symposium on Intelligent Information Technology and Security Informatics,
- Ramírez, C. (2018). Algoritmo SVD aplicado a los sistemas de recomendación en el comercio. *Tecnología, Investigación y Academia (TIA)*, 6 (1), 18-27.
- Resnick, P., & Varian, H. R. (1997). Recommender systems. *Communications of the ACM*, 4(3), 56 - 59. <https://doi.org/ACM 0002-0782/97/0300>
- Saini, S., Saumya, S., & Singh, J. P. (2017). Sequential purchase recommendation system for e-commerce sites. IFIP International Conference on Computer Information Systems and Industrial Management,
- Smits, G., Nerzic, P., Lesot, M., & Pivert, O. (2019, 23-26 June 2019). FRELS: Fast and Reliable Estimated Linguistic Summaries. 2019 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE),
- Smits, G., Yager, R. R., & Pivert, O. (2017, 9-12 July 2017). Interactive data exploration on top of linguistic summaries. 2017 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE),
- Souali, K., El Afia, A., & Faizi, R. (2011). An automatic ethical-based recommender system for e-commerce. 2011 International Conference on Multimedia Computing and Systems,
- Tintarev, N., & Masthoff, J. (2007). A survey of explanations in recommender systems. 2007 IEEE 23rd international conference on data engineering workshop,
- Vázquez Y., Machín A., Velasteguí E., & V., P. (2018). Genetic algorithm for the generation of prediction rules in moodle courses. *Revista electrónica Ciencia Digital*, 2(1), 7-17. <https://doi.org/https://doi.org/10.33262/cienciadigital.v2i1>.
- Xiaosen, W. (2015). The design and realization of personalized e-commerce recommendation system. 2015 International Conference on Social Science and Technology Education,
- Xue, W., Xiao, B., & Mu, L. (2015). Intelligent mining on purchase information and recommendation system for e-commerce. 2015 IEEE international conference on industrial engineering and engineering management (IEEM),
- Ya, L. (2010). E-commerce personalized recommendation technology based on expert system. 6th International Conference on Digital Content, Multimedia Technology and its Applications,
- Yang, F., Liu, N., Wang, S., & Hu, X. (2018, 17-20 Nov. 2018). Towards Interpretation of Recommender Systems with Sorted Explanation Paths. 2018 IEEE International Conference on Data Mining (ICDM),
- Zhang, L., Luo, T., Zhanga, F., & Wu, Y. (2018). A Recommendation Model Based on Deep Neural Network. *IEEE Access*(99), 1-10. <https://doi.org/10.1109/ACCESS.2018.2789866>