

# Un modelo híbrido para la recomendación de libros utilizando reconocimiento facial, filtrado colaborativo y por contenido

**Eduard Gilberto Puerto Cuadros**Facultad de Ingeniería. División de Biblioteca Eduard Cote Lamus, Universidad Francisco de Paula Santander (Colombia) <https://dx.doi.org/10.5209/rgid.94234>

Recibido: 04/01/2024 • Revisado: 29/03/2024 • Aceptado: 15/04/2024

**ES Resumen.** La continua evolución de la tecnología transforma la manera en que las bibliotecas interactúan con sus usuarios, y estos a su vez con los libros. Los sistemas de recomendación se conciben como sistemas de filtrado de información cuyo objetivo es proporcionar acceso a información personalizada (libros de interés, revistas, bases de datos, artículos científicos, salas, etc.) para mejorar la experiencia del usuario, fomentar la usabilidad de los recursos bibliográficos y optimizar los servicios. Este artículo propone un modelo híbrido de recomendación automática que ensambla tres procesos en dos fases: identificación del usuario, filtrado colaborativo y filtrado por contenido. En la primera fase, se lleva a cabo el proceso de reconocimiento de usuario con técnicas que implementan aprendizaje profundo y, en la segunda fase, se integran los procesos de recomendación mediante filtrado colaborativo y por contenido. Se elaboró un caso de estudio en un entorno bibliotecario para recomendar libros y fue evaluado mediante métricas clásicas de recuperación de información. Se compararon los resultados con otros modelos de recomendación más robustos, obteniendo resultados satisfactorios.

**Palabras clave.** Sistema de recomendación, reconocimiento facial, aprendizaje profundo, filtrado colaborativo, filtrado por contenido, biblioteca.

## ENG A hybrid book recommendation model using deep learning, collaborative, and content filtering

**ENG Abstract.** The continuous evolution of technology is transforming the way libraries interact with their users, and in turn, how users engage with books. Recommendation systems are conceived as information filtering systems whose goal is to provide access to personalized information (books of interest, magazines, databases, scientific articles, rooms, etc.) to enhance the user experience, promote the usability of bibliographic resources, and optimize services. This article proposes a hybrid model for the automatic recommendation that combines three processes in two phases: user identification, collaborative filtering, and content filtering. In the first phase, the user recognition process is carried out using techniques that implement deep learning, and in the second phase, the recommendation processes are integrated through collaborative filtering and content filtering. A case study was developed in a library environment for recommending books and was evaluated using classic information retrieval metrics. The results were compared with other more robust recommendation models, obtaining satisfactory outcomes.

**Keywords.** recommendation system, facial recognition, deep learning, collaborative filtering, content filtering, library.

**Sumario.** 1. Introducción. 2. Método. 3. Instanciación del Modelo. 4. Resultados. 5. Conclusiones. 6. Referencias bibliográficas.

**Cómo citar:** Puerto Cuadros, E. G. (2024) Un modelo híbrido para la recomendación de libros utilizando reconocimiento facial, filtrado colaborativo y por contenido, en *Revista General de Información y Documentación* 34 (1), 45-54, e(ID doi).<https://dx.doi.org/10.5209/rgid.94234>

## 1. Introducción

Los sistemas de recomendación son sistemas de filtrado de información de preferencias, intereses y comportamiento del usuario que buscan simplificar el proceso de búsqueda en un entorno complejo de información, tratando de predecir los productos como libros, películas, artículos o servicios más adecuados a las preferencias del usuario. Estos sistemas pueden ser diseñados implementando diferentes métodos como el filtrado basado en contenido o CBF, por sus siglas en inglés (Lops et al., 2011: 73-105) o el método de filtrado colaborativo o CF, por sus siglas en inglés (Ekstrand et al., 2011:81-173). Por ejemplo, en el caso del filtrado basado en contenido (CBF), si a un usuario le gusta el género de ciencia ficción, el sistema recomendará libros de ese género, como "1984" de George Orwell o "Fahrenheit 451" de Ray Bradbury, porque comparten atributos similares. Por otro lado, en el filtrado colaborativo (CF), si un usuario A tiene gustos similares a otro usuario B, y el usuario B ha leído y disfrutado de "El señor de los anillos", el sistema podría recomendarle a A también leer ese libro.

Además, los sistemas de recomendación se apoyan típicamente en la recopilación de datos, ya sea históricos o en tiempo real, que son analizados a través de técnicas de aprendizaje de máquina. Estas técnicas permiten construir la trazabilidad del usuario, perfilándolo e identificando sus necesidades con la expectativa de satisfacerlas mediante recomendaciones. De esta manera, los sistemas de recomendación no solo aprovechan la información pasada, sino que también se actualizan constantemente para proporcionar una experiencia más precisa y adaptada a las necesidades evolutivas del usuario.

Por otra parte, el reconocimiento facial automatizado ha tenido enormes avances gracias al desarrollo de poderosas técnicas de deep learning y computación gráfica, así como la disponibilidad de extensos benchmarks con millones de imágenes anotadas (Yi et al., 2014; Cao et al., 2018: 67-74). Esto ha permitido entrenar modelos capaces de superar incluso el desempeño humano en tareas de verificación e identificación facial (Taigman et al., 2014; Schroff et al., 2015, Kortli et al., 2020:243). Asimismo, el lanzamiento de librerías de código abierto como Face\_recognition de Python (Geitgey, 2022, Amos et al., 2016,) ha facilitado el acceso a esta tecnología, al empaquetar los últimos modelos para su implementación en cualquier proyecto (Pandey & Gelin, 2022: 925-941), control de acceso inteligente (Wang et al., 2022: 138-142, Wang, et al., 2021), asistencia aumentada a discapacitados visuales (Poudel et al., 2020), entre otros.

La técnica de filtrado colaborativo necesita un número de usuarios ni muy bajo ni muy alto para ser realmente eficaz, ya que su objetivo es buscar las coincidencias entre los distintos usuarios y poder predecir cuáles son sus gustos y generar las recomendaciones personalizadas (Koren et al., 2009). Este enfoque construye el modelo basado en la opinión del usuario, en la calificación dada por otros usuarios y el comportamiento pasado del usuario hacia el sistema, que incluye por ejemplo libros leídos por el usuario previamente (Sabogal et al., 2021: 139-150).

Por otra parte, un sistema de filtrado basado en contenido selecciona elementos en función de la correlación entre el contenido de los elementos y las preferencias del usuario, a diferencia de un sistema de filtrado colaborativo que elige elementos en función de la correlación entre personas con preferencias similares (Lops et al., 2011, Widayanti et al., 2023: 289-302).

Las técnicas de filtrado colaborativo basadas en contenido y los enfoques híbridos (Burke, 2002: 331-370, Widayanti et al., 2023: 289-302) han demostrado gran valor en el filtrado inteligente; logrando un alto grado de personalización y diversidad en los elementos sugeridos. Estas técnicas se han incorporado extensivamente en investigaciones y aplicaciones comerciales de diversos dominios, incluyendo comercio electrónico (McAuley et al., 2015:43-52), educación (Salehi et al., 2015:61-75), noticias y medios (JIntema et al., 2010:1-6), salud, financiero, turismo, legal, entre otros.

Los enfoques actuales de sistemas de recomendación hacen uso de la inteligencia artificial explotando la capacidad de aprendizaje y adaptación de las redes neuronales artificial (Cheng et al., 2021:2978-2979, Qingyu et al., 2022:3549-3568, Chong et al., 2019:225-234, Chen et al., 2023: 264, Lin et al., 2023). Dentro de estos métodos de recomendación se tienen las GNN (GNN-based models), filtrado colaborativo neuronal (NCF) y máquina de factorización profunda (DeepFM) (Guo et al., 2017).

Así mismo, existen diversos escenarios de recomendación, cada uno con objetivos específicos (Gao et al., 2023: 1-51). Estos incluyen la recomendación social, que se centra en sugerir elementos basándose en las interacciones y preferencias sociales del usuario. La recomendación secuencial se enfoca en predecir el próximo ítem en función del historial de interacciones del usuario, considerando el orden temporal de las acciones. La recomendación por sesiones se concentra en ofrecer sugerencias relevantes dentro de una sesión de interacción continua del usuario. La recomendación por colecciones, también conocida como recomendación de conjuntos, tiene como objetivo sugerir combinaciones de elementos que puedan ser consumidos juntos, siendo común en plataformas como Spotify o Amazon (Zhi et al., 2021:1284-1295, Xingchen et al., 2020:159-168).

En este contexto, el problema de investigación abordado fue ¿Cómo crear un modelo de recomendación basado en el análisis multimodal del perfil del usuario y su historial de calificación en el sistema usando técnicas avanzadas de Inteligencia Artificial? Se planteó la hipótesis de que un modelo de recomendación basado en el análisis multimodal del perfil del usuario; sus credenciales externas como código de estudiante o número de identificación combinado con elementos biométricos como el aspecto facial y su historial de calificación en el sistema, utilizando técnicas de reconocimiento facial, filtrado colaborativo y filtrado basado en contenido sería efectivo. Para probar esta hipótesis, se diseñó un modelo de recomendación con la generalidad suficiente como para adaptarse a diferentes situaciones o dominios como recomendar libros, películas, música, objetos de aprendizaje, documentos, revistas, noticias, o artículos en general fue alcanzado.

Como caso de estudio se implementó el modelo en un contexto bibliotecario. En el contexto de la biblioteca y el préstamo de libros, la experiencia del usuario es esencial para garantizar que los usuarios puedan acceder fácilmente a los libros que desean. Un sistema de recomendación inteligente puede ayudar en este aspecto

al proporcionar sugerencias personalizadas basadas en los intereses individuales de cada usuario. Esto facilita el descubrimiento de nuevos títulos y temas, enriqueciendo así la experiencia de lectura y fomentando una mayor participación en la biblioteca. Además, la capacidad de ofrecer atención personalizada, utilizando tecnologías como el reconocimiento facial, permite a la biblioteca brindar un servicio más individualizado, recordando las preferencias de los usuarios habituales y ofreciendo recomendaciones pertinentes. Esta atención personalizada no solo aumenta la satisfacción del usuario, sino que también contribuye a su fidelización, ya que los usuarios que se sienten valorados son más propensos a regresar y recomendar la biblioteca a otros.

Estos sistemas no sólo simplifican la búsqueda de recursos relevantes, sino que también fomentan la exploración de nuevos intereses y optimizan el aprovechamiento de los recursos bibliotecarios disponibles. (Tian, Y., Zheng, B., Wang, Y., Zhang, Y., & Wu, Q.)

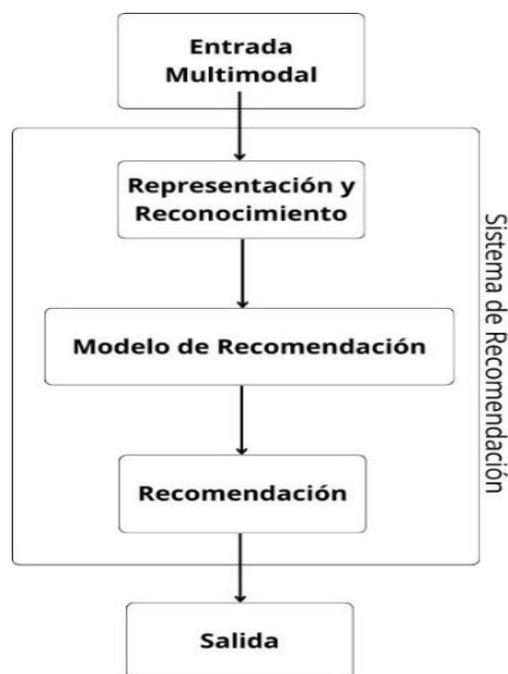
El artículo establece los siguientes aportes:

- Una arquitectura general para recomendación.
- La especificación de los algoritmos que constituyen la arquitectura usable en la biblioteca Eduardo Cote Lamus, demostrando aplicabilidad real del modelo.
- La propuesta incorpora elementos contextuales clave, como la identidad y el historial de préstamos de cada usuario, asegurando recomendaciones de lectura altamente personalizadas y contextualmente enriquecidas.

El artículo continúa con una sección 2 donde se describe el método general de recomendación propuesto. La sigue la sección 3, donde se instancia el modelo (Figura 2) en un ambiente bibliotecario y se especifican los mecanismos para el reconocimiento facial (Figura 4) junto con el formalismo matemático pertinente (sección 3.1.1 y 3.1.2) de los métodos usados. La sección 4 analiza los resultados y se compara con otro modelo de recomendación (sección 4.1). Finalmente, la sección 5 y 5.1 se presentan conclusiones, discusiones y trabajos futuros.

## 2.Método

El sistema de recomendación propuesto cuenta con una arquitectura robusta y versátil, diseñada para manejar una entrada multimodal proveniente de diversas fuentes para caracterizar al usuario. Esta entrada puede ser desde un número de identificación, código o ID, hasta datos biométricos como su cara o el histórico o trazabilidad de su actividad en redes sociales. Toda esta información es procesada para reconocer el tipo de usuario.



(fig.1) Arquitectura general de Recomendación.

Una vez identificado el usuario, la información se convierte en entrada para los mecanismos de recomendación. Estos mecanismos utilizan modelos del mundo o conocimiento propio, como bases bibliográficas con etiquetas de votación o fichas resúmenes. Luego, se mapea el modelo del usuario con el modelo interno del agente para generar recomendaciones según los criterios establecidos.

Finalmente, las recomendaciones son procesadas y formateadas para su presentación al usuario. Este proceso se repite para cada usuario, lo que permite ofrecer recomendaciones personalizadas en tiempo real. La arquitectura del sistema busca una gestión eficiente y precisa de la información, así como una experiencia de usuario óptima.

A continuación, se detalla el paso a paso de los mecanismos que constituyen cada fase:

#### Fase entrada multimodal

1. Registro de información exógena como código del estudiante, número de cédula, etc.
2. Adquisición de imágenes faciales: Una cámara captura imágenes faciales de los usuarios en tiempo real y las envía al sistema.

#### Fase representación y reconocimiento

3. Reconocimiento facial: Un modelo de inteligencia artificial entrenado en reconocimiento facial procesa cada imagen para extraer características biométricas faciales únicas y relacionarlas con el código de identificación del usuario.

#### Fase Recomendación

4. Búsqueda de perfil de usuario: El código de usuario se utiliza para consultar la base de datos de perfiles de usuario y recuperar el historial del usuario identificado.
5. Determinación de estrategia de recomendación: Si es un usuario existente, se emplea el modo de filtrado híbrido: colaborativo y basado en contenido, de lo contrario, si es un nuevo usuario, se inicia el modo de arranque desde cero, donde se recomiendan los elementos más populares para construir un perfil inicial.
6. Filtrado colaborativo: Se identifican usuarios con historiales e intereses similares para generar recomendaciones basadas los elementos que les gustaron a usuarios similares.
7. Filtrado basado en contenido: Se analizan las características de los elementos previamente accedidos y se recomiendan elementos con características de contenido similares.
8. Agregación de resultados: Los resultados de los dos filtros se combinan y se ordenan para producir una lista personalizada de recomendaciones de los artículos para el usuario.
9. Presentación al usuario: La lista de elementos recomendados se muestra al usuario junto con información relevante como etiquetas de información. para facilitar la selección.
10. Retroalimentación: El usuario interactúa con las recomendaciones, lo cual se incorpora a su perfil para refinar recomendaciones futuras

### 3. Instanciación del Modelo

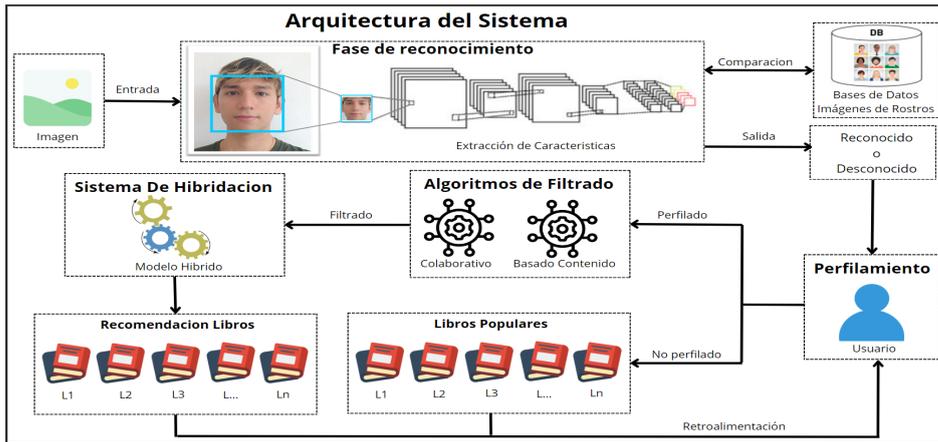
Para el caso de prueba del sistema híbrido de recomendación se tomó en cuenta los siguientes posibles escenarios en el contexto de la biblioteca Educado Cote Lamus de la Universidad Francisco de Paula Santander Cúcuta-Colombia:

- Recomendación Secuencial: Ya que la biblioteca cuenta con un sistema que permite seguir el orden en el que los usuarios han interactuado con los libros, así el modelo puede predecir el siguiente libro que un usuario podría encontrar interesante basándose en su historial de préstamos.
- Recomendación de Conjuntos: Ya que la biblioteca tiene colecciones temáticas con lo cual el modelo puede sugerir listas de libros que se complementen entre sí, como series relacionadas o temas similares.
- Recomendación de Múltiple Comportamiento: La biblioteca podría tener acceso a información detallada sobre el comportamiento del usuario, como su carrera, semestre, materias matriculadas, historial de préstamos y búsquedas, así el sistema puede hacer uso de este escenario para comprender mejor las preferencias del usuario.

La biblioteca Eduardo Cote Lamus ha funcionado tradicionalmente con sistemas open source como Koha para la gestión de préstamos y material bibliográfico, donde el estudiante solo puede acceder al catálogo para realizar consultas específicas del material con el que se cuenta, pero no existen mecanismos de recomendación personalizados que guíen la selección de lecturas en base a las consultas que el usuario realiza. Derivado de esto, los usuarios desconocen los recursos disponibles al no contar con sugerencias afines a sus necesidades e intereses, por lo cual no es accesible para el lector, explorar y encontrar contenidos útiles o a la mano desde su ingreso a la biblioteca. Por tal razón, el modelo propuesto de recomendación busca ofrecer un servicio más personalizado al usuario, al poder, directamente, darle información valiosa que con gran seguridad le complementa su estudio y que muy posiblemente utilizará.

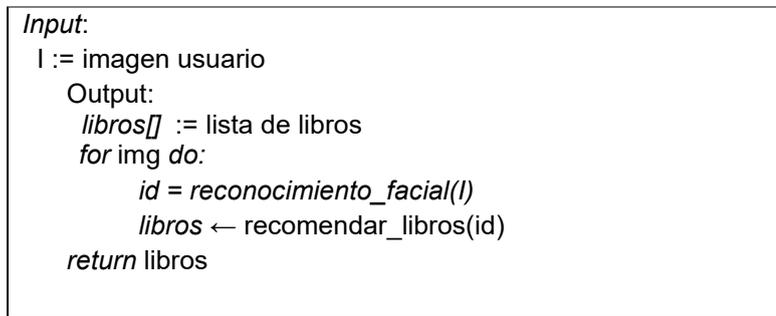
A continuación, se adapta el modelo general de recomendación (Figura 1) para esta particular situación bajo una arquitectura a dos fases: fase de reconocimiento de usuario y fase de recomendación, como se muestra en la siguiente Figura 2.

A continuación, se especifica el modelo computacional del modelo híbrido de recomendación de libros (Figura 3) y los sub-algoritmos que lo constituyen.



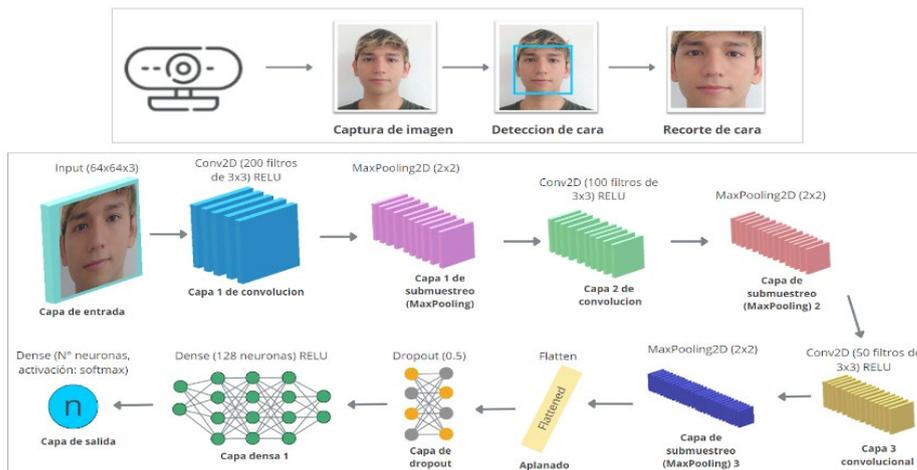
(fig.2) Instanciación del modelo híbrido de recomendación propuesto.

### 3.1. Modelo Computacional



(fig.3) Macro-algoritmo del sistema de recomendación de libros.

Recibida la imagen del usuario (I) se hace la búsqueda de su identidad utilizando el modelo de red neuronal convolucional creado (Figura 4) que hace el reconocimiento facial, luego se obtiene el código del usuario identificado y se procede hacer la recomendación.



(fig.4) Red neuronal para el reconocimiento facial.

La red neuronal convolucional tiene las siguientes características: 10 capas de procesamiento; una de entrada, tres de convolución para la extracción de características faciales, tres de max-pooling para selección de características claves y reducción de la dimensional de los datos, una capa para evitar el sobreajuste del modelo y una capa final densa con 128 neuronas.

Una vez se ha identificado el usuario se procede a recomendar los libros usando los algoritmos de recomendación de libros y los filtros colaborativos y por contenido (Figura 5).

<p><i>RecomendaciónLibros</i> (id) input: id (código) del usuario output: libros</p>
<pre> start process   user := obtener_perfilamineto(U)   If user is nuevo then     recomendaciones := recomendaciones_populares()   else     candidatos := recomendacion_colaborativa(user)     recomendaciones := (candidatos , user)   end If   return recomendaciones end </pre>

(fig.5) Algoritmo de reconocimiento facial.

### 3.1.1. Formalización del filtrado colaborativo (CF)

Una vez se tiene el código del estudiantes se calcula las similitudes entre el usuario dado y otros a través de la ec(1). En función de la similitud de usuarios se hace la predicción por calificación a través de la ec(2), y retorna la recomendación de libros.

Similitud de Usuarios (User-User CF): Una medida común para calcular la similitud entre dos usuarios se basa en el coeficiente de correlación de Pearson. La fórmula para calcular la similitud entre dos usuarios 'x' y 'y' se vería así:

1. Calculando la similitud entre usuarios utilizando el coeficiente de correlación de Pearson.

$$P_{x,y} = \frac{\sigma_{xy}}{\sigma_x \sigma_y} = \frac{Cov(x,y)}{\sqrt{Var(x)Var(y)}} \quad (1)$$

Donde:

cov(x,y): covarianza de las calificaciones de los usuarios x y y  
 $\sigma_x$ : desviación estándar de las calificaciones del usuario x  
 $\sigma_y$ : desviación estándar de las calificaciones del usuario y

2. Obtener el interés de los usuarios en los libros en función de la similitud entre los usuarios.

$$\rho(u, i) = \frac{\sum_{v \in N(u)} sim(u,v) \cdot r(v,i)}{\sum_{v \in N(u)} |sim(u,v)|} \quad (2)$$

Donde:

$\rho(u,i)$ : predicción de calificación de usuario u para ítem i  
 $N(u)$ : conjunto de k vecinos más cercanos "similares" al usuario u  
 $r(v,i)$ : calificación del usuario v para el ítem i  
 $sim(u,v)$ : similitud entre usuarios u y v

### 3.1.2. Formalización del filtrado Basado en Contenido (CB)

Para este caso se recibe el código del usuario, se calcula la similitud de libros por la ec(3) en función de la similitud de libro se hace la predicción con la ec(4) y se retorna los libros según sea el caso.

Similitud de Items (Item-Item CB) La similitud entre dos elementos 'i' y 'j' se puede calcular utilizando diversas métricas, como la similitud coseno o la similitud Jaccard. Aquí, se utiliza la similitud coseno como ejemplo:

$$Sim(i, j) = \frac{X_i \cdot X_j}{|X_i| \cdot |X_j|} \quad (3)$$

Donde:

- $X_i$  y  $X_j$  son vectores de características de los elementos 'i' y 'j'.

Predicción de Calificación: La predicción de calificación para un usuario 'u' en un elemento 'i' se basa en las calificaciones anteriores del usuario para elementos similares. La fórmula podría ser:

$$\hat{r}_{ui} = \frac{\sum_{j \in S(i)} Sim(i,j) \cdot r_{uj}}{\sum_{j \in S(i)} |Sim(i,j)|} \quad (4)$$

- $\hat{r}_{ui}$  es la predicción de calificación para el usuario 'u' en el elemento 'i'.
- $S(i)$  es el conjunto de elementos similares al elemento 'i' basados en contenido.

## 4. Resultados

Para medir la precisión de las predicciones de las valoraciones de preferencia se utilizaron métricas clásicas de recuperación de información como la raíz del error cuadrático medio o RMSE (Root Mean Squared Error) a nivel de precisión y otros parámetros como velocidad, facilidad de uso, personalización, diversidad de recomendaciones, explicabilidad, portabilidad, conjunto de datos y técnicas utilizadas.

### 4.1. Comparación y análisis

A continuación, se compara nuestro modelo con un modelo de recomendación más robusto como Netflix Price en función de estos parámetros.

Tabla 1 Comparativa cualitativa con Netflix vs Modelo Híbrido.

CARACTERÍSTICA	NETFLIX PRIZE	MODELO HÍBRIDO
Precisión (RMSE)	0.9514	2.2148
Velocidad	Procesamiento por lotes	Tiempo real con reconocimiento facial
Usabilidad	Calificación Manual	Automatizado
Personalización	Alta, basada en historias de usuario	Alta, basada en reconocimiento facial e historias de usuario
Diversidad de recomendaciones	Alta	Moderada
Explicabilidad	Modelo de caja negra	Híbrido de fácil seguimiento
Portabilidad	Web y móvil	web
Datos	Millones	Miles
Técnicas usadas	Filtrado Colaborativo	Filtrado híbrido

Tabla de elaboración propia.

El modelo da un RMSE de 2.2148 muy superior al 0.9514 logrado por Cinematch en Netflix Prize, lo cual es consistente con la gran diferencia entre el tamaño de la data de entrenamiento de ambos modelos. Si bien esto indica menor precisión en las predicciones de calificaciones, nuestro enfoque ofrece beneficios significativos en otros aspectos:

- Captura múltiples señales del usuario (materias vistas, semestre actual, entre otros) que permiten sugerencias de lectura acordes a sus necesidades académicas.
- Capacidad de integrar múltiples señales de contexto educativo para filtrado de contenidos. El modelo híbrido facilita entender la lógica de libros son recomendados.
- Logra recomendaciones personalizadas en tiempo real mediante reconocimiento
- facial, sin necesidad de que el usuario califique contenidos manualmente.

El modelo, aunque posee un RMSE más alto, puede ser valioso según el contexto de uso y los requisitos específicos. Su eficacia dependerá de las necesidades particulares y el alcance de aplicación. Lorem ipsum putent intellegat intellegebat pro no. Prima eligendi mea ne, sed hinc posse graeci ei. Duo animal interesset te, reformidans dissentiunt ad sea, facer tollit percipit in sit. Ludico percipit mei ex, laudem adolescens no has.

## 5. Conclusiones

En este artículo se diseñó e implementó un sistema híbrido de recomendación de libros basado en técnicas de aprendizaje profundo y aplicando las técnicas de recomendación por filtrado colaborativo y por contenido. Se especifican los algoritmos del modelo híbrido de recomendación de libros propuesto: el algoritmo de reconocimiento de imagen del usuario, y los algoritmos para el filtrado colaborativo y por contenido, cuyo objetivo es ofrecer recomendación de los libros al usuario. Una vez identificados, los usuarios, se recupera sus perfiles y se generan sugerencias compatibles con sus preferencias de lectura individuales (rating a libros), gracias a la aplicación de modelos híbridos de recomendación.

El modelo trata con las limitaciones de las técnicas tradicionales de recomendación, como búsquedas basadas en palabras clave y navegación por categorías, al incorporar técnicas de visión artificial, aprendizaje profundo y recomendación por contenido y filtrado colaborativo.

Los resultados experimentales muestran la utilidad del modelo aun con baja precisión para la Biblioteca Eduardo Cote Lamus, puesto que no solo mejora la experiencia de los usuarios al interactuar con el catálogo Koha de la biblioteca, sino que también ofrece posibilidades de aplicación en otros dominios de recomendación. La identificación precisa de usuarios a través del reconocimiento facial ha demostrado ser crucial para la vinculación efectiva con perfiles de préstamos, y la combinación de los filtros ha permitido ofrecer recomendaciones de lectura altamente personalizadas y contextualmente enriquecidas.

### 5.1. Trabajos futuros

Las bibliotecas que se encuentren en procesos de análisis o adaptación, es decir que tiene una experiencia de usuario deficiente, que no conocen los intereses de sus usuarios o que no aprovechan la data generada por sus usuarios podrían aplicar este nuevo modelo de recomendación como una estrategia encaminada hacia una evolución del modelo de servicio dado que las respuestas que piden los usuarios son con mayor celeridad.

Los investigadores pueden beneficiarse del modelo de recomendación per se dónde podrán aprender la estrategia de fusión multimodal para la caracterización del usuario así como también el modelo híbrido de los algoritmos utilizados para comprender mejor los diferentes tipos de usuarios. Esto puede lograrse a través de algoritmos de procesamiento de imágenes y reconocimiento de patrones, así como técnicas de análisis de datos y aprendizaje automático aplicadas a datos multimodales.

También el modelo propuesto y probado les proporcionaría ideas sobre cómo adaptar y generalizar el modelo para diferentes contextos y dominios como artículos, películas o música. Los investigadores pueden aprender y aplicar este modelo mediante la comprensión de sus fundamentos técnicos, el estudio de casos similares y la experimentación práctica en otros entornos bibliotecarios reales. Así como también considerar múltiples modalidades de datos para mejorar la precisión de las recomendaciones, la cual aplica a otros tipos de datos como preferencias explícitas e implícitas, historial de comportamiento, etc. Esto muestra la versatilidad y la aplicabilidad del modelo en diferentes contextos.

La incorporación del reconocimiento facial puede discutirse en el contexto de cómo la personalización mejora la experiencia del usuario y aumenta la relevancia de las recomendaciones. Incluir esta nueva enfoque busca extender o enriquecer los mecanismos convencionales de identificación vía texto como códigos, números etc., con el objetivo de lograr una identificación muy personalizada y precisa de los usuarios ya que en escenarios como las bibliotecas es muy frecuente la suplantación de carnet o códigos. Adicionalmente, el reconocimiento facial ofrece ventajas clave, tales como conveniencia y precisión, al basarse en características biométricas únicas e intransferibles.

Es posible que el reconocimiento facial se realice en otro lugar (por ejemplo, en un punto de entrada a la Universidad) y que la información se utilice posteriormente en la biblioteca para asociar los datos de uso con la identidad de los usuarios. Sin embargo, para el caso de estudio, los usuarios serán identificados mediante reconocimiento facial sólo al ingresar a la biblioteca, y esta información se utilizaría para integrar sus datos de uso en el sistema interno de la biblioteca.

No obstante, se reconocen las preocupaciones legítimas sobre privacidad y protección de datos biométricos que puede suscitar esta tecnología. Para abordar estos aspectos, se proponen salvaguardas y enfoques, como la obtención de consentimiento informado de los usuarios, el cumplimiento estricto de la legislación vigente en materia de protección de datos personales y biométricos y la capacitación del personal en buenas prácticas de gestión de datos biométricos.

Se recomienda aumentar la data y reentrenar el modelo incluyendo variables más del contexto del estudiante como incorporar syllabus estudiantiles para un filtrado más preciso. La expansión del conjunto de datos y ajustes adicionales pueden contribuir a una mayor precisión de las recomendaciones y que sean más estrechas con necesidades académicas de cada estudiante. Por ejemplo, se podrían priorizar lecturas introductorias o de fundamentos para estudiantes viendo temas básicos, o enfoque en tópicos avanzados y especializados acordes a los syllabus de materias superiores. Esto requeriría ampliar el perfil de usuario con los campos de las materias y contenidos de sus syllabus actuales, para filtrar y ordenar adecuadamente los resultados. Al incorporar este nuevo factor contextual en el modelado de usuarios, se espera que la relevancia y utilidad de las recomendaciones de lectura mejore significativamente.

## 6. Referencias bibliográficas

- Amos, B., Ludwiczuk, B., & Satyanarayanan, M. [2016]. *Openface: A general-purpose face recognition library with mobile applications*. CMU School of Computer Science.
- Burke, R. D. [2002]. "Hybrid recommender systems: Survey and experiments". *User modeling and user-adapted interaction*, 12(4), 331-370.
- Cao, Q., Shen, L., Xie, W., Parkhi, O. M., & Zisserman, A. [2018, May]. "Vggface2: A dataset for recognising faces across pose and age". In 2018 13th *IEEE international conference on automatic face & gesture recognition*, 67-74. IEEE.
- Chen, X., Yao, L., McAuley, J., Zhou, G., & Wang, X. [2023]. "Deep reinforcement learning in recommender systems: A survey and new perspectives". *Knowledge-Based Systems*, 264, 110335.
- Cheng, H. and Cheng-Te L. [2021]. "RetaGNN: Relational temporal attentive graph neural networks for holistic sequential recommendation". In *Proceedings of the Web Conference*. 2968–2979.
- Chong Chen, Min Zhang, Chenyang Wang, Weizhi Ma, Minming Li, Yiqun Liu, and Shaoping [Ma. 2019]. "An efficient adaptive transfer neural network for social-aware recommendation". In *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*. 225–234.
- Ekstrand, M. D., Riedl, J. T., & Konstan, J. A. [2011]. "Collaborative filtering recommender Systems". *Foundations and Trends in Human-Computer Interaction*, 4(2), 81-173.
- Geitgey, A. [2022]. Face Recognition. *GitHub repository*. [https://github.com/ageitgey/face\\_recognition](https://github.com/ageitgey/face_recognition)
- Guo, H., Tang, R., Ye, Y., Li, Z., & He, X. [2017]. "DeepFM: a factorization-machine based neural network for CTR prediction". *arXiv preprint arXiv:1703.04247*.
- Gao, C., Zheng, Y., Li, N., Li, Y., Qin, Y., Piao, J., ... & Li, Y. [2023]. "A survey of graph neural networks for recommender systems: Challenges, methods, and directions". *ACM Transactions on Recommender Systems*, 1(1), 1-51.

- IJntema, W., Goossen, F., Frasinca, F., & Hogenboom, F. [2010]. "Ontology-based news recommendation". *Proceedings of the International Workshop on Business Intelligence and the Web (BEWEB)*, 1-6.
- Koren, Y., Bell, R., & Volinsky, C. [2009]. "Matrix factorization techniques for recommender systems". *Computer*, 42(8), 30-37.
- Kortli, Y., Jridi, M., Al Falou, A., & Atri, M. [2020]. "Face recognition systems: A survey". *Sensors*, 20(2), 342.
- Lin, Y., Liu, Y., Lin, F., Zou, L., Wu, P., Zeng, W., ... & Miao, C. [2023]. *A survey on reinforcement learning for recommender systems*. *IEEE Transactions on Neural Networks and Learning Systems*.
- Lops, P., De Gemmis, M., & Semeraro, G. [2011]. "Content-based recommender systems: State of the art and trends". In *Recommender systems handbook*, 73-105). Springer, Boston, MA.
- McAuley, J., Targett, C., Shi, Q., & van den Hengel, A. [2015]. "Image-based recommendations on styles and substitutes". In *Proceedings of the 38th international ACM SIGIR conference on research and development in information retrieval*, 43-52).
- Pandey, S. K., & Gelin, R. [2022]. "Real-time deep learning based facial emotion recognition system using optimized convolutional neural network and OpenCV". *Information Systems Frontiers*, 24(4), 925-941.
- Poudel, R. P. K., Liwicki, S., & Cipolla, R. [2020]. *Frast: Face Recognition Assisted System for the Blind Using Synthetic Data*. arXiv preprint arXiv:2006.01987.
- Qingyu Guo, Fuzhen Zhuang, Chuan Qin, Hengshu Zhu, Xing Xie, Hui Xiong, and Qing He. [2022]. "A survey on knowledge graph-based recommender systems". *IEEE Trans. Knowl. Data Eng.* 34, 8 (2022), 3549–3568.
- Sabogal, G. M. V., Correa, Y. S. C., & Rendón, C. D. D. [2021]. "Desarrollo de una aplicación web progresiva para la recomendación de películas y libros mediante la técnica de filtrado colaborativo". *Revista CIES Escolme*, 12(1), 139-150.
- Salehi, M., Kamalabadi, I. N., & Ghaznavi Ghouschi, M. B. [2015]. "Personalized recommendation of learning material using sequential pattern mining and attribute based collaborative filtering". *Education and Information Technologies*, 20(1), 61-75.
- Schroff, F., Kalenichenko, D., & Philbin, J. [2015]. Facenet: A unified embedding for face recognition and clustering. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 815-823.
- Taijman, Y., Yang, M., Ranzato, M. A., & Wolf, L. [2014]. "Deepface: Closing the gap to human-level performance in face verification". In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1701-1708).
- Wang, C., Sun, L., Hou, X., & Xie, Y. [2022]. "Design of intelligent book sorting system based on PLC control". In *International Symposium on Control Engineering and Robotics (ISCER)*, Changsha, China, 138-142. doi:10.1109/ISCER55570.2022.00030. <https://ieeexplore.ieee.org/document/9894475>
- Wang, Z., Yu, Z., Zheng, D., Zhang, Y., & Zheng, D. [2021]. *An Access Control System Based on Face Recognition and Web Technology*. *Computational Intelligence and Neuroscience*.
- Widayanti, R., Chakim, M. H. R., Lukita, C., Rahardja, U., & Lutfiani, N. [2023]. "Improving Recommender Systems using Hybrid Techniques of Collaborative Filtering and Content-Based Filtering". *Journal of Applied Data Sciences*, 4(3), 289-302.
- Wang, Y., Ma, W., Zhang, M., Liu, Y., & Ma, S. [2023]. "A survey on the fairness of recommender systems". *ACM Transactions on Information Systems*, 41(3), 1-43.
- Xingchen Li, Xiang Wang, Xiangnan He, Long Chen, Jun Xiao, and Tat-Seng Chua. [2020]. "Hierarchical fashion graph network for personalized outfit recommendation". In *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. 159–168.
- Yi, D., Lei, Z., Liao, S., & Li, S. Z. [2014]. *Learning face representation from scratch*. arXiv preprint arXiv:1411.7923.
- Zhi Zheng, Chao Wang, Tong Xu, Dazhong Shen, Penggang Qin, Baoxing Huai, Tongzhu Liu, and Enhong Chen. [2021]. "Drug package recommendation via interaction-aware graph induction". In *Proceedings of the Web Conference*. 1284-1295.