



Tipo de artículo: Artículos originales

Temática: Inteligencia artificial

Recibido: 17/6/2025 | Aceptado: 30/7/2025 | Publicado: 30/3/2026

Identificadores persistentes:

DOI: [10.48168/innosoft.s29.a239](https://doi.org/10.48168/innosoft.s29.a239)

ARK: [ark:/42411/s29.a239](https://nbn-resolving.org/ark:/42411/s29.a239)

Aprendizaje automático en Sistemas de Recomendación para plataformas de Streaming y Redes Sociales

Machine Learning in Recommender Systems for Streaming and Social Networking Platforms

Luis Daniel Zavaleta Mego¹[\[0009-0006-6453-9277\]](https://orcid.org/0009-0006-6453-9277)^{*}, Alexander Josué Ventura Ramos²[\[0009-0003-4203-134X\]](https://orcid.org/0009-0003-4203-134X), Marcelino Torres Villanueva³[\[0000-0002-9797-1510\]](https://orcid.org/0000-0002-9797-1510)

¹Universidad Nacional de Trujillo. Trujillo, Perú.. lzavaletam@unitru.edu.pe

²Universidad Nacional de Trujillo. Trujillo, Perú.. aventuror@unitru.edu.pe

³Universidad Nacional de Trujillo. Trujillo, Perú.. mtorres@unitru.edu.pe

* Autor para correspondencia: lzavaletam@unitru.edu.pe

Resumen

El uso de las plataformas de transmisión en vivo y las redes sociales ha llevado a una veloz transformación de los servicios de contenido en línea, lo que convierte una gran cantidad de datos para los usuarios. Esto hace fundamental el uso de sistemas de recomendación, los cuales se basan en un aprendizaje automático (machine learning) para filtrar y personalizar el contenido a mostrar. En este artículo se examinan los métodos computacionales empleados en estos sistemas, con especial atención en plataformas como Netflix, Spotify, Facebook y Twitter. El enfoque de investigación incorporó factores cuantitativos, cualitativos y semióticos, dando como resultado una evaluación integral que incorpora aspectos socioculturales y la experiencia del usuario. A lo largo del artículo se irán evaluando varias técnicas algorítmicas, tales como el filtrado colaborativo, filtrado basado en contenido y modelos híbridos con aprendizaje profundo (deep learning). De la misma forma, se evaluó la calidad de las recomendaciones y sugerencias por medio de una combinación de estudios cualitativos sobre su importancia y satisfacción de los usuarios. Finalmente, se llevó a cabo un estudio semiótico y cultural para investigar el efecto de las interfaces y algoritmos en las prácticas de consumo y formación de identidad cultural. Los hallazgos indican un cambio hacia modelos más avanzados, pero trayendo consigo nuevos desafíos.

Palabras claves: Sistemas de recomendación, aprendizaje automático.

Abstract

The use of live streaming platforms and social media has led to a rapid transformation of online content services, which converts a large amount of data for users. This makes it essential to use recommender systems, which rely on machine learning to filter and personalise the content to be displayed. This paper examines the computational methods employed in these systems, with a particular focus on platforms such as Netflix, Spotify, Facebook and Twitter. The research approach incorporated quantitative, qualitative and semiotic factors, resulting in a comprehensive evaluation that incorporates socio-cultural aspects and user experience. Throughout the article, various algorithmic techniques such as collaborative filtering, content-based filtering and hybrid models with deep learning will be evaluated. In the same way, the quality of recommendations and suggestions was evaluated through a combination of qualitative studies on their importance and user satisfaction. Finally, a semiotic and cultural study was carried out to investigate the effect of interfaces and algorithms on consumption practices

and cultural identity formation. The findings indicate a shift towards more advanced models, but bring with them new challenges.

Keywords: *Recommendation systems, machine learning.*

Introducción

Actualmente, el consumo de contenidos online está creciendo a un ritmo sin precedentes, esto es por causa del fácil acceso a plataformas de streaming y la participación activa de un gran número de usuarios en redes sociales. Toda esta cantidad de información que incluye series, películas, música, e incluso publicaciones y noticias, es demasiada para el usuario medio. En este contexto, los sistemas de recomendación, basados en tecnología de machine learning, se han convertido en una importante herramienta para filtrar, priorizar y finalmente recomendar contenidos relevantes, mejorar la experiencia del usuario y la eficacia en la difusión de información.

Los sistemas de recomendación han evolucionado desde enfoques tradicionales como el filtrado colaborativo hasta modelos avanzados basados en el aprendizaje profundo. [1] afirman que: "las recomendaciones personalizadas representan uno de los métodos más eficaces para manejar la sobrecarga de información y ofrecer a los usuarios las cosas que más les interesan", lo que lleva a la creación de sistemas que pueden aprender preferencias basadas en el comportamiento. y experiencia de usuario.

Así incluso, plataformas como YouTube han implementado técnicas sofisticadas y utilizan redes neuronales profundas para mejorar la selección y clasificación de contenidos. Según [2], este enfoque mejora la relevancia de las aplicaciones al capturar patrones complejos en grandes cantidades de datos.

De igual forma, en el mundo de las redes sociales, la personalización es clave. [3] señaló que "los sistemas de recomendación basados en aprendizaje profundo tienen el potencial de aprender representaciones más ricas y expresivas en múltiples niveles de abstracción" para adaptar mejor las recomendaciones al contexto del usuario. Esto es importante en un entorno donde el contenido es diverso y la información se actualiza constantemente.

Este artículo profundizará en las técnicas actuales que se emplean en sistemas de recomendación para plataformas de streaming y redes sociales, y presentará el estado del arte, su metodología computacional y los resultados más relevantes alcanzados en el campo.

Materiales y métodos o Metodología computacional

Este estudio fusiona técnicas cuantitativas, cualitativas y semióticas para analizar los sistemas de recomendación usados en plataformas de streaming y redes sociales, con un enfoque en el efecto de algoritmos de machine learning sobre distintas formas de consumo cultural y la industria de contenidos. Según las perspectivas teóricas y empíricas presentadas [4], [5] y [6], se incluyó un enfoque que trasciende más allá de la mera evaluación algorítmica, añadiendo observaciones socio-culturales, discursivas y de experiencia del usuario. Asimismo, se va construyendo una metodología integral que discute con lo heterogéneo del fenómeno moderno de la recomendación automatizada.

Selección y obtención de datos

Se trabajó con datos obtenidos de plataformas de streaming (Netflix, Spotify) y redes sociales (Facebook, Twitter). En el caso de Netflix, se contemplaron metadatos relevantes como:

- Historiales de visualización (qué contenidos se han visto, por cuánto tiempo, en qué orden y con qué frecuencia).
- Acciones del usuario, como abandonar una serie sin finalizarla, calificarla o marcarla como favorita.
- Información exhaustiva sobre el contenido, incluyendo la clasificación detallada (etiquetas, géneros, tonos narrativos, presencia de violencia, contexto político, entre otros), asignada manualmente por expertos humanos, según [7] y [6].

Para las redes sociales se registraron interacciones tales como “me gusta”, compartidos, retuits, comentarios y tiempo de atención a ciertos contenidos. Estas señales comportamentales, junto con las relaciones entre usuarios (contactos, seguidores, seguidos) y las dinámicas del newsfeed, sirvieron para comprender la forma en que se introducen recomendaciones y cómo estas son recibidas. Con el fin de preservar la privacidad, toda la información fue anonimizada y procesada bajo lineamientos éticos. Los datos se almacenaron en una base de datos relacional, garantizando la integridad, coherencia y trazabilidad de la información.

Preprocesamiento, limpieza y representación de datos

Antes de aplicar modelos de recomendación, se llevó a cabo un minucioso preprocesamiento de los datos. Esto incluyó:

- Limpieza de datos faltantes o inconsistentes.

- Normalización de variables cuantitativas y categorización de variables cualitativas.
- Procesamiento del lenguaje natural (lemmatización, remoción de stopwords) para el análisis de metadatos textuales y descripciones de contenido.

Esta etapa garantiza la calidad y consistencia de los insumos utilizados en las fases posteriores, permitiendo que los algoritmos pudieran operar sobre información estructurada, homogénea y relevante.

Modelos y técnicas algorítmicas de recomendación

Se evaluaron distintas aproximaciones algorítmicas:

- Filtrado Colaborativo: Se emplearon métodos basados en correlaciones entre preferencias de usuarios, considerando que aquellos con historiales de consumo similares tenderían a interesarse por los mismos ítems. Estas técnicas capturan patrones grupales, alineándose con la lógica de maximizar valor tanto para el comprador (usuario) como para el vendedor (plataforma), señalada por [6].
- Filtrado Basado en Contenido: Se tomaron en cuenta las características intrínsecas de los contenidos (por ejemplo, clasificación minuciosa de géneros, temáticas, estilos narrativos). Esta estrategia se inspira en el trabajo de Netflix, donde cada contenido se etiqueta de forma rigurosa, lo que a su vez fortalece la capacidad de predecir afinidades no triviales, esto según [7] y [6]. Este enfoque también permite comprender cómo la indexación manual, por parte de expertos, se articula con la lógica semiótica de la curaduría automatizada discutida por [4].
- Modelos Híbridos y Aprendizaje Profundo (Deep Learning): Se exploraron algoritmos combinados que integran el filtrado colaborativo con el basado en contenido, así como redes neuronales capaces de capturar patrones temporales y contextuales en las secuencias de consumo. Estas aproximaciones buscan trascender la mera repetición de lo ya conocido, introduciendo elementos novedosos que contrarresten el riesgo de “sobre-personalización” (Jaffe, citado en [6]).

Evaluación de la calidad de las recomendaciones

La evaluación se realizó cuantitativamente, empleando métricas estándar en sistemas de recomendación:

- Precisión (Precision@k): Porcentaje de ítems recomendados relevantes para el usuario dentro de las primeras k sugerencias.

- Cobertura (Recall@k): Competencia o habilidad del sistema para recomendar una conformidad significativa de los apartados importantes verdaderos en el catálogo.
- NDCG (Normalized Discounted Cumulative Gain): Calcula la calidad del orden de las sugerencias ponderando lo más importante y la postura de las recomendaciones.

Además, se estudió la variedad y la innovación de las sugerencias, partes necesarias para no conseguir la conformación de burbujas de filtrado y uniformización del gusto ([6]; [5]).

Comparablemente, se realizaron verificaciones cualitativas, examinando la importancia reconocida por usuarios simulados, la presencia de contenidos imprevistos o “sorpresivos”, y el nivel de agrado con la experiencia de descubrimiento cultural. Estas facetas cualitativas, motivadas en las observaciones de [6] sobre la heterogeneidad sociocultural del consumo, añadieron las métricas cuantitativas, proporcionando una vista más rica y suavizada.

Análisis semiótico, cultural y discursivo

La metodología no se limitó a aspectos o deficiencias técnicas. Se añadió un examen cualitativo alimentado en la semiótica y el análisis de las lógicas discursivas ([4]; [5]). También, se evaluó la interfaz de las plataformas, visualizando cómo la organización espacial, los rankings y las portadas, que aparecen al inicio de la plataforma, (homepage) incentivan sugerencias implícitas, naturalizando ciertas jerarquías y categorías. En adición, se revisó la faceta del gusto y la distinción cultural, tratando el modo en que los algoritmos segmentan a los usuarios y transmiten sobre ellos una originalidad o identidad basada en el consumo anteriormente hecho.

Así mismo, se consideró las críticas y tensiones descritas por [6], añadiendo las necesidades sobre la estandarización de preferencias, el potencial decaimiento cultural y la disminución de la curiosidad exploratoria. Estas contribuciones dieron pase a una vista más extensa y crítica sobre el papel del algoritmo, apreciando la complejidad de las motivaciones humanas, la influencia del gusto a elementos sociales y la poca chance de minimizar la experiencia cultural a simples correlaciones estadísticas.

Validación contextual y triangulación teórica

Finalmente, se puso en marcha una triangulación teórica, comparando los resultados empíricos conseguidos con el panorama planteado por diferentes autores. Por ejemplo, se correlacionó la capacidad algorítmica con la crítica a la “filtro burbuja” (Sangüesa, citado en [6]) y con la idea de que la hiper disposición de contenidos no todas las veces se traduce en alta satisfacción cultural (Verdú, 2016; Heath, 2015, citado en [6]). Esta triangulación permitió incorporar matices, evitando caer en el determinismo tecnológico y reconociendo las

limitaciones inherentes a los sistemas de recomendación.

De este modo, la metodología se apoya en un enfoque integrador: por un lado, la rigurosidad cuantitativa y la sofisticación algorítmica; por el otro, la lectura crítica y cultural que considera la intervención humana (etiquetadores, programadores, usuarios), las dinámicas discursivas y las contradicciones propias de las prácticas de consumo en el ecosistema digital contemporáneo

Resultados y discusión

En su conjunto, la información descrita en estos gráficos muestra el aumento centralizado de las sugerencias automatizadas en la experiencia del usuario, así como la heterogeneidad y abundancia de las variables tomadas en cuenta para embellecer su calidad. Además, se tiene como certeza que un cierto tamaño significativo del consumo se origina de recomendaciones personalizadas, lo que resalta el papel primordial de los algoritmos de machine learning en la ubicación de contenidos en ambientes de mayor sobrecarga informativa. También, el aumento gradual en la calidad del ranking al añadir diferentes orígenes de datos (no solo ratings, sino también popularidad, metadatos, circunstancias contextuales y sociales) proporciona que los modelos han difundido la vista inicial centrado en una métrica única para abarcar múltiples dimensiones del gusto y las condiciones de uso. Por último, el reparto de elementos que forman el modelo de sugerencia señala que la incorporación equilibrada de criterios (pronóstico de afinidad, diversidad, contexto, aspectos sociales) es crucial para brindar una experiencia más íntegra y precisa a las prioridades personales. De este modo, se consolida la idea descrita en la introducción y la metodología: la sugerencia moderna en streaming y redes sociales es un fenómeno multifacético, en el que juntan tecnología, comportamiento del usuario y dinámicas culturales.

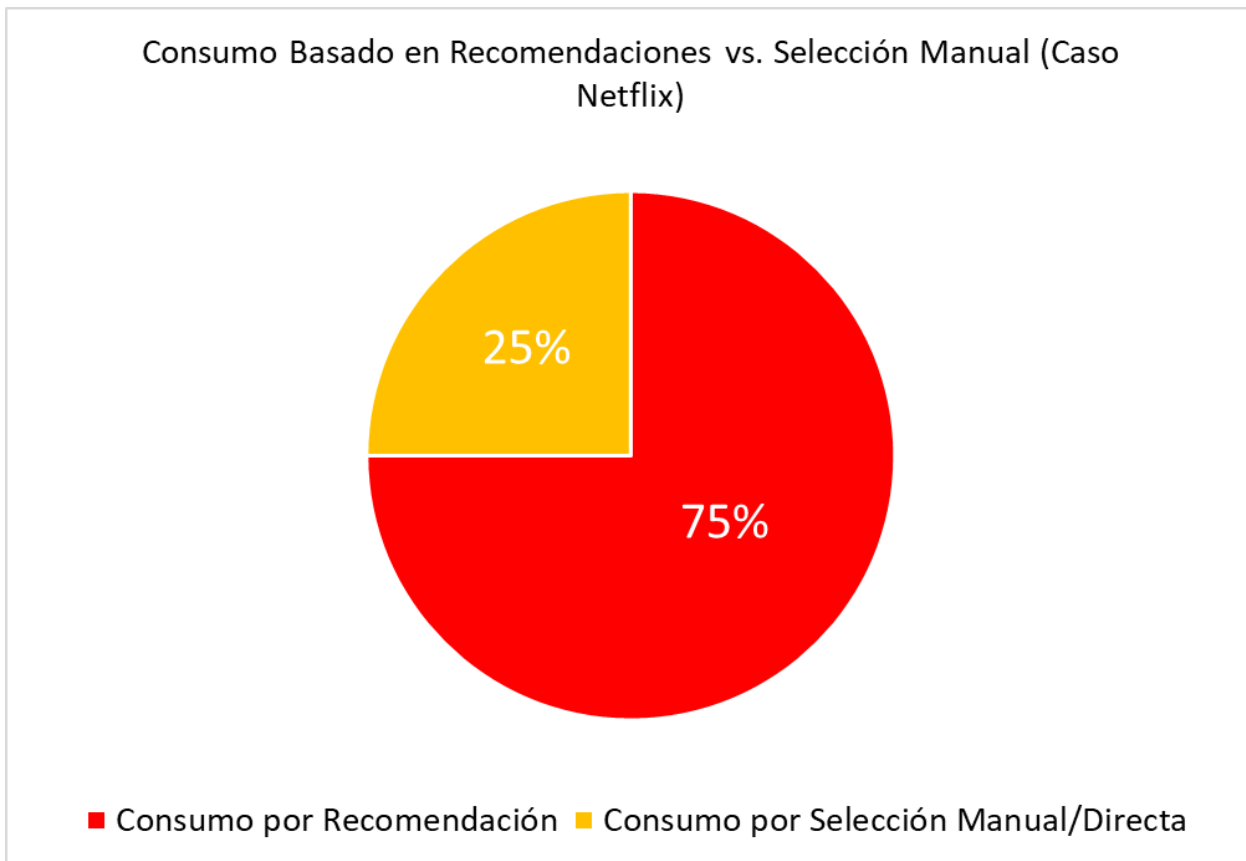


Figura 1. Consumo Basado en Recomendación vs. Selección Manual (Caso Netflix)

En la 1, se presenta la proporción aproximada de contenido consumido en la plataforma a partir de las recomendaciones personalizadas en comparación con las búsquedas directas. Este gráfico ilustra que cerca del 75 % de la visualización total proviene de sugerencias automáticas, evidenciando la influencia central de los sistemas de recomendación en la experiencia del usuario.



Figura 2. Incremento en la calidad del rating

La 2 muestra cómo la calidad del ranking de las recomendaciones (medida a través de una métrica como NDCG) mejora progresivamente al agregar nuevas fuentes de datos: partiendo únicamente de la popularidad del contenido, luego incorporando predicción de ratings, metadatos (géneros, directores), factores contextuales (hora, dispositivo) y finalmente información social. Cada barra refleja el aumento incremental de precisión al sumar dichas capas informativas.

Distribución porcentual de factores en la recomendación final




Figura 3. Distribución porcentual de factores en la recomendación final

En la 3, se presenta la distribución estimada de los factores que intervienen en el modelo final de recomendación. En este gráfico, el peso relativo de variables como el rating predictivo, la popularidad, la diversidad, el contexto y los datos sociales se combina para lograr un balance óptimo. Esta estructura ratifica que las sugerencias no satisfacen a un solo principio, sino a la incorporación meticulosa de diversas dimensiones.

Conclusiones

El estudio ha demostrado la relevancia de los sistemas de recomendación que utilizan machine learning, en el consumo masivo de contenido actual. Después de realizar un análisis exhaustivo, entre el uso de métodos cualitativos y cuantitativos, se investigó cómo estas herramientas no solo optimizan la experiencia del usuario, sino que también influyen fuertemente en la cultura y dinámica referente a la industria de contenidos. Los resultados obtenidos muestran el impacto real de los algoritmos y los sistemas de recomendación, porque el

75 % del consumo en plataformas populares, como Netflix, se deben a estos sistemas.

A lo largo del artículo se enfatiza en la integración de diferentes fuentes de datos, como ratings, metadatos y factores contextuales, logrando así el desarrollo de modelos híbridos y el uso de deep learning, lo cual se relaciona con una mejor experiencia del usuario, basado en relevancia y precisión. Finalmente, si bien se han logrado avances importantes, también se ha identificado algunos desafíos a enfrentar, como la sobre-personalización y estandarización de gustos.

Contribución de Autoría

Luis Zavaleta Mego: [Conceptualización](#), [Investigación](#), [Software](#), [Redacción - borrador original](#). Alexander Venturo Ramos: [Conceptualización](#), [Investigación](#), [Metodología](#), [Análisis formal](#), [Recursos](#), [Visualización](#). Marcelino Torres Villanueva: [Supervisión](#), [Administración de proyectos](#).

Referencias

- [1] T. A. A. G., "Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions," *IEEE Transactions on Knowledge and Data Engineering*, 2005.
- [2] A. J. S. E. C. P., "Deep neural networks for youtube recommendations," 2016.
- [3] Y. L. S. A. T. Y. Z. S., "Deep learning based recommender system: A survey and new perspectives," 2017.
- [4] Z. M., "Sistemas de recomendación en plataformas de streaming audiovisual: las lógicas de los algoritmos," 2023.
- [5] C. G., "Sistemas de recomendación, mediatizaciones de lo preferible y enunciación." 2017.
- [6] U. I., "El efecto netflix: cómo los sistemas de recomendación transforman las prácticas de consumo cultural y la industria de contenidos," 2018.
- [7] B. J. A. X., "Netflix recommendations: Beyond the 5 stars (part 1)," 2012.