



Prototipo web de un sistema de recomendación para la compra de computadores portátiles.

Jorge Adrián Martínez Gómez

Universidad del Valle - Sede Tuluá

Facultad de Ingeniería

Ingeniería de Sistemas

Tuluá, Valle Del Cauca

2025



Prototipo web de un sistema de recomendación de compras de motocicletas)

Jorge Adrián Martínez Gómez

Código 201958616-3743

`Jorge.adrian.martinez@correounivalle.edu.co`

DIRECTOR

Ing. Miguel Ángel Askar Rodríguez

Profesor de la Escuela de Ingeniería de Sistemas y Computación

`miguel.askar@correounivalle.edu.co`

Universidad del Valle - Sede Tuluá

Facultad de Ingeniería

Ingeniería de Sistemas

Tuluá

2025

Agradecimientos

Primero que todo, agradezco a Dios por darme la fuerza y la sabiduría necesarias para llevar a cabo esta importante etapa de mi vida.

Agradezco profundamente a mis padres, Jorge Martínez y Adriana Gómez, así como a mis hermanos, Alejandro Martínez y Oriana Martínez, por su amor, apoyo incondicional y por estar siempre presentes en cada paso de este camino.

A mi director de tesis, el profesor Miguel Ángel, le expreso mi sincero agradecimiento por su constante respaldo, por compartir generosamente sus conocimientos y, sobre todo, por su paciencia y guía durante el desarrollo de este proyecto.

A mi amigo Gabriel Correa, gracias por estar allí en los momentos más importantes de mi carrera, por tu ayuda desinteresada y por tu compañía cuando más la necesité.

También quiero agradecer a todas aquellas personas que, de una u otra manera, contribuyeron a que este proyecto se culmine satisfactoriamente.

A todos, gracias por estar a mi lado y por creer en mí. Este logro es tanto mío como de ustedes.

Tabla de Contenido

1. Introducción	1
1.1. Planteamiento del Problema	2
1.1.1. Definición del problema	2
1.2. Objetivos	2
1.2.1. Objetivo general	2
1.2.2. Objetivos específicos	3
1.3. Resultados Esperados	3
1.4. Antecedentes	3
1.4.1. Filtrado colaborativo ítem a ítem:	3
1.4.2. Bart(IA):	3
1.4.3. Amazon personalize:	4
1.4.4. Sistemas basados en popularidad:	4
1.4.5. Desarrollo de un recomendador de videojuegos:	4
1.4.6. Desarrollo de un chatbot para la recomendación de eventos o lugares de interés:	4
1.4.7. Prototipo de un sistema de recomendación de libros para la Biblioteca Mario Carvajal:	5
1.4.8. Sistema de recomendación de portátiles basado en contenido y apren- dizaje automático:	5
1.4.9. Sistema de recomendación de laptops basado en contenido y aprendizaje profundo:	5
1.4.10. Sistema de recomendación de laptops basado en la web:	6
1.5. Justificación	6
1.6. Justificación de los Capítulos:	6
2. Alcance de la Propuesta	8
3. Marco de Referencia	10
3.1. Conceptos Básicos	10
3.2. Marco Teórico	10
3.2.1. Tipos de filtrados	12
3.2.1.1. Filtrado basado en reglas de asociación	12

3.2.2.	Filtrado basado en Usuario	12
3.2.3.	Filtrado colaborativo	12
3.2.4.	Filtrado basado en contenido	12
3.2.5.	Redes neuronales	13
3.2.6.	Descomposición de matrices (como SVD o NMF)	13
3.2.7.	K-Nearest Neighbors (KNN)	13
3.2.8.	Aprendizaje profundo (Deep Learning)	13
3.2.9.	Sistemas basados en grafos	13
4.	Diseño	14
4.1.	Análisis de preferencias de los usuarios	14
4.1.1.	Descripción de la metodología utilizada	14
4.2.	Encuesta	15
4.2.1.	Perfil de los encuestados	15
4.2.2.	Conclusiones	16
5.	Modelos	17
5.1.	Técnicas de recomendación	17
5.2.	Selección de modelo	17
5.3.	Sistemas de estados	19
6.	Desarrollo de la Aplicación	21
6.1.	Metodología de Desarrollo	21
6.2.	Dataset	21
6.2.1.	Aspectos Éticos	22
6.2.2.	Descripción del Dataset	22
6.2.3.	Extracción de datos	23
6.2.4.	Migración de datos en la base de datos	23
6.3.	Tecnologías Utilizadas	25
6.4.	Motor de recomendación	26
6.5.	Demostración del prototipo	27
6.5.1.	Validación del algoritmo de recomendación	32
7.	Pruebas	34
7.1.	Planteamiento de las pruebas	34
7.2.	Comparación con «Ayúdame a elegir una PC» de Microsoft	40
7.3.	Comparación con el Recomendador de Computadores de “Alkosto”	42
8.	Conclusiones del Proyecto	45
8.1.	Trabajos Futuros	47
	Bibliografía	49

Lista de tablas

1.1. Objetivos Específicos vs Entregables. Fuente: Elaboración propia.	3
1.2. Estructura de Capítulos. Fuente: Autoria Propia	7
6.1. Votación del experto. Fuente: Elaboración propia.	33

Lista de Figuras

5.1. Relación entre opciones de respuesta. Fuente: Elaboración propia.	18
5.2. flujo del modelo. Fuente: Elaboración propia.	19
6.1. Diagrama de flujo de la aplicación. Fuente: autoría propia.	24
6.2. Estado inicial del prototipo web. Fuente: Elaboración propia.	27
6.3. Estado inicial de las preguntas. Fuente: Elaboración propia.	28
6.4. Segunda fase de las preguntas. Fuente: Elaboración propia.	28
6.5. Etapa de recomendaciones. Fuente: Elaboración propia.	29
6.6. Etapa de recomendaciones. Fuente: Elaboración propia.	30
6.7. Etapa del chatbot. Fuente: Elaboración propia.	30
6.8. Diagrama de flujo prototipo web Fuente: Elaboración propia.	31
7.1. Pregunta 1 Fuente: Elaboración propia	34
7.2. Pregunta 2 Fuente: Elaboración propia	35
7.3. Pregunta 3 Fuente: Elaboración propia	35
7.4. Pregunta 4 Fuente: Elaboración propia	36
7.5. Pregunta 5 Fuente: Elaboración propia	36
7.6. Pregunta 6 Fuente: Elaboración propia	37
7.7. Pregunta 7 Fuente: Elaboración propia	37
7.8. Pregunta 8 Fuente: Elaboración propia	38
7.9. Pregunta 9 Fuente: Elaboración propia	38
7.10. Herramienta de recomendación Microsoft. Fuente: Microsoft	41
7.11. Herramienta de recomendación Microsoft.Fuente: Microsoft	42
7.12. Herramienta de recomendación MicrosAlkostooft. Fuente: Alkosto	43
7.13. Herramienta de recomendación Alkosto.Fuente: Alkosto	44

Capítulo 1

Introducción

El uso de computadoras portátiles en Colombia experimenta un incremento anual, consolidándose como el medio preeminente mediante el cual numerosas personas llevan a cabo actividades fundamentales en la sociedad contemporánea, tales como estudiar, trabajar, y participar en actividades recreativas. Este fenómeno refleja la creciente influencia de la tecnología en diversos aspectos de la vida cotidiana, evidenciando su arraigo en la estructura social.[1]

Como consecuencia del mencionado incremento en el uso de tecnología, se ha generado un desafío para la mayoría de los nuevos consumidores tecnológicos. Este reto se centra en la dificultad de seleccionar el portátil más adecuado en función de sus necesidades específicas. La raíz de esta problemática reside en la falta de conocimientos acerca del hardware de los equipos, lo que deja a muchas personas en la incertidumbre sobre qué dispositivo adquirir. La complejidad del mercado de laptops, con sus numerosos modelos, especificaciones y marcas, puede resultar abrumadora para quienes no poseen un entendimiento detallado de los aspectos técnicos.

Evidenciando esta problemática, se desarrolló un sistema de recomendación orientado a la compra de computadores portátiles. Durante este proceso, se abordan temas clave como la recolección de datos mediante técnicas de web scraping, la aplicación de reglas de asociación y el uso de inteligencia artificial dentro del proyecto. Además, se realizarán pruebas que permitirán determinar si la solución propuesta responde efectivamente a la problemática planteada. También se expondrán y argumentarán las técnicas utilizadas a lo largo del desarrollo.

1.1. Planteamiento del Problema

En la sociedad actual la informática y la tecnología son fundamentales en una amplia gama de campos, desde el uso personal de dispositivos hasta la integración industrial, aplicaciones comerciales, logística de mercancías, entre otros. En este contexto, uno de los dispositivos más ubicuos y esenciales son las computadoras portátiles. Según Silvio Hernán García, gerente de Acer en Colombia, solo en el año 2021 los portátiles tuvieron un alza de ventas en el mercado del 20 %.[2] Así como Acer muchas marcas más demostraron un aumento en sus ventas reflejando una tendencia global hacia la digitalización y la dependencia de la tecnología.

Ahora bien, existen una gran cantidad de marcas de computadores personales en el mercado colombiano, entre las que destacan según su calidad precio Acer, Asus, Lenovo, Huawei, Dell y Apple. Cada una de estas marcas teniendo en su amplia gama de computadoras destinadas para distintos propósitos, ya sea un computador para un uso normal, para jugar videojuegos, para correr programas de diseño, etc. Estas computadoras tienen características específicas que les permite desempeñarse mejor en diferentes áreas.

En la actualidad los sistemas de recomendación han evolucionado significativamente en los últimos años, esto gracias a la gran cantidad de datos que podemos encontrar actualmente sobre temas en específico. Además, herramientas como la inteligencia artificial ayudan a dar a los usuarios una recomendación más precisa e interactiva al usuario.

1.1.1. Definición del problema

El mercado de computadoras personales ofrece una amplia variedad de opciones en términos de especificaciones técnicas, marcas y modelos. Esta diversidad puede resultar abrumadora para los usuarios que buscan adquirir una computadora que se ajuste de manera óptima a sus necesidades específicas. Ante este escenario, surge la necesidad de desarrollar un sistema de recomendación eficiente que facilite el proceso de selección para los usuarios, garantizando que la computadora adquirida cumpla con sus expectativas y requisitos. Con lo cual, surge la siguiente pregunta:

¿Cómo implementar un sistema de recomendación de compra de computadoras personales según las necesidades del usuario?

1.2. Objetivos

1.2.1. Objetivo general

Desarrollar una aplicación web con un prototipo de sistema de recomendación para la compra de computadores portátiles, de acuerdo con las necesidades del usuario

1.2.2. Objetivos específicos

1. Recolectar información sobre las preferencias de los usuarios para la elección de computadores portátiles.
2. Clasificar la información sobre los computadores portátiles de acuerdo con las preferencias de los usuarios.
3. Diseñar un algoritmo de recomendación basado en las preferencias de los usuarios para ayudarlos a seleccionar el computador más adecuado a sus necesidades.
4. Implementar una aplicación web que incluya el algoritmo de recomendación diseñado.
5. Realizar un análisis de las recomendaciones a partir de pruebas funcionales del prototipo web.

1.3. Resultados Esperados

Objetivos Específicos	Entregable	Indicador	Meta
1	Base de datos, scraping, APIs o encuestas con información recopilada.	Número de característica recopiladas.	100 %
2	Informe de análisis de factores clave.	# de factores identificados.	100 %
3	Desarrollar el algoritmo del prototipo de recomendación como aplicación Web.	Funcionalidad y efectividad del algoritmo.	90 %
4	Prototipo de app web funcional con el algoritmo del prototipo de recomendación integrado.	Facilidad en el uso de la aplicación	100 %
5	Evaluación y pruebas de resultados obtenidos.	Pruebas realizadas.	100 %

Tabla 1.1: Objetivos Específicos vs Entregables. Fuente: Elaboración propia.

1.4. Antecedentes

1.4.1. Filtrado colaborativo ítem a ítem:

Amazon dispone de un sistema de recomendación, al cual llaman filtrado colaborativo ítem a ítem. Este sistema se basa en asociar cada producto que compra un usuario con otros que son similares o están, de alguna forma, relacionados. Incluso con aquellos que compraron otros usuarios que se interesaron por el primero.[3]

1.4.2. Bart(IA):

El sistema BaRT tiene como propósito ofrecer música que seguramente va a gustar al usuario, basándose en su actividad previa. Sin embargo, el algoritmo también ofrece nuevos géneros y

cantantes para que sus oyentes no se queden estancados en un solo estilo musical.[4]

De este modo, el sistema selecciona música que está relacionada con el historial de música del usuario, las canciones que se ha saltado, las listas de reproducción que ha hecho e incluso la ubicación. Pero, además, también utiliza la información de otros usuarios que tienen un gusto similar para recomendar música nueva que no hayan escuchado.[4]

1.4.3. Amazon personalize:

Amazon Personalize permite a los desarrolladores crear y desplegar rápidamente recomendaciones curadas y segmentación de usuarios inteligente a escala mediante machine learning (ML). Dado que Amazon Personalize puede adaptarse a sus necesidades individuales, puede ofrecer la experiencia de cliente correcta en el momento y el lugar indicados. Amazon Personalize permite a los desarrolladores crear y desplegar rápidamente recomendaciones curadas y segmentación de usuarios inteligente a escala mediante machine learning (ML).[5]

1.4.4. Sistemas basados en popularidad:

El modelo basado en la popularidad se trata del sistema más común. El modelo provee recomendaciones basadas en el número de visitas, likes, valoraciones o compras. Las recomendaciones no están personalizadas para los usuarios, es decir, que los productos o servicios más populares son recomendados a todos los usuarios de la plataforma. Ejemplos de plataformas que tienen este tipo de recomendador son YouTube, Netflix, Amazon o Spotify.[3]

1.4.5. Desarrollo de un recomendador de videojuegos:

Este es un prototipo de sistema de recomendación de videojuegos basado en filtro colaborativo y utilizando Twitter como fuente de información. Recopila tweets relacionados con un juego específico (X) seleccionado por el usuario, analiza el sentimiento de los tweets y proporciona una calificación. También incluye un componente para empresas que realiza un análisis similar de sentimiento en los tweets sobre el juego X, pero devuelve una lista de partidarios y opositores, proporcionando datos valiosos para un estudio de mercado.[6]

1.4.6. Desarrollo de un chatbot para la recomendación de eventos o lugares de interés:

Este proyecto presenta el desarrollo de un chatbot para la aplicación de mensajería instantánea Telegram, con el propósito de acercar la tecnología a la ciudadanía. El Bot ofrece un servicio de geolocalización fácil de usar que permite encontrar puntos de interés cercanos al usuario en la ciudad de Valencia, España. Los datos utilizados provienen del portal de datos abiertos del

Ayuntamiento de Valencia, con las credenciales proporcionadas por la Universidad Politécnica de Valencia. Las tecnologías empleadas en el desarrollo son JavaScript como lenguaje de programación, y Telegram y NodeJS para la implementación.[7]

1.4.7. Prototipo de un sistema de recomendación de libros para la Biblioteca Mario Carvajal:

En este proyecto de trabajo de grado, se ha desarrollado un prototipo de aplicación de recomendaciones de libros para la biblioteca Mario Carvajal. La información utilizada para el desarrollo fue proporcionada por la propia biblioteca, y se incluyó una base de datos de libros externa para realizar pruebas con variables adicionales. El prototipo web incorpora dos técnicas de recomendación: el filtrado colaborativo y las recomendaciones basadas en contenido. A través de pruebas y análisis de resultados de ambas técnicas, se realiza una comparación para determinar cuál de ellas es más adecuada para una posible integración con el sistema de la biblioteca Mario Carvajal. [8]

1.4.8. Sistema de recomendación de portátiles basado en contenido y aprendizaje automático:

Este es un sistema de recomendación de portátiles que combina técnicas de recomendación basadas en contenido y aprendizaje automático. El sistema utiliza una representación vectorial de los portátiles que incluye características como el tipo de procesador, la memoria RAM, el tamaño de la pantalla, el precio, etc. La representación vectorial se utiliza para calcular la similitud entre las laptops y recomendar las más similares a las que el usuario ha visto o comprado anteriormente.

El sistema también utiliza un algoritmo de aprendizaje automático para aprender de las preferencias de los usuarios. El algoritmo se entrena con un conjunto de datos de usuarios que han calificado laptops. El algoritmo aprende a identificar las características que son más importantes para los usuarios y utiliza esta información para mejorar la precisión de las recomendaciones.[9]

1.4.9. Sistema de recomendación de laptops basado en contenido y aprendizaje profundo:

Es un sistema de recomendación de laptops que combina técnicas de recomendación basadas en contenido y aprendizaje profundo. El sistema utiliza una red neuronal convolucional para aprender a representar las laptops como vectores de características. La red neuronal se entrena con un conjunto de datos de laptops con sus características técnicas y las calificaciones de los usuarios. [10]

1.4.10. Sistema de recomendación de laptops basado en la web:

Este proyecto presenta un sistema de recomendación de laptops basado en la web que utiliza una combinación de técnicas de recomendación basadas en contenido y colaborativas. El sistema utiliza información sobre las características técnicas de las laptops, las preferencias de los usuarios y las compras de los usuarios para generar recomendaciones.[11]

1.5. Justificación

La propuesta se centra en el desarrollo de un sistema de recomendación para la compra de computadores portátiles, abordando los desafíos asociados con la selección de un equipo adecuado en un mercado caracterizado por su constante evolución tecnológica y su amplia oferta de marcas, modelos y configuraciones. A medida que la demanda de computadores portátiles ha aumentado en el país, especialmente para fines académicos, laborales y personales, la diversidad de opciones disponibles se ha multiplicado, lo que, si bien ofrece más alternativas a los usuarios, también dificulta el proceso de elección del equipo que mejor se ajuste a sus necesidades específicas.

La gran variedad de características técnicas como el procesador, la memoria RAM, el tipo de almacenamiento, la tarjeta gráfica y el sistema operativo— puede resultar abrumadora para los compradores que no poseen conocimientos técnicos profundos. Además, factores como el presupuesto, el propósito de uso (por ejemplo: diseño gráfico, programación, estudios, entretenimiento) y la portabilidad, influyen significativamente en la decisión final de compra. Las recomendaciones generales o no personalizadas rara vez satisfacen completamente las expectativas del usuario, al no considerar estas variables individuales de forma integral.

El enfoque propuesto en esta investigación busca responder a esta problemática mediante el diseño de un sistema de recomendación personalizado que toma en cuenta las necesidades particulares del usuario. A través de la recolección y análisis de datos relevantes sobre los criterios de compra y las especificaciones técnicas más valoradas, el sistema busca ofrecer sugerencias precisas y alineadas con los requerimientos específicos de cada persona. La justificación del estudio se basa en una recomendación informada, centrada en el perfil del usuario, que permite una experiencia de compra más efectiva y satisfactoria.

Desde una perspectiva más amplia, esta investigación aporta al desarrollo de soluciones tecnológicas basadas en inteligencia artificial y sistemas de recomendación en el ámbito del comercio electrónico y la toma de decisiones informadas. Al ofrecer a los usuarios una herramienta práctica y eficiente para elegir un computador portátil, se busca no solo mejorar su experiencia de compra, sino también fomentar un mercado más transparente, dinámico y adaptado a las necesidades reales de los consumidores.

1.6. Justificación de los Capítulos:

La tabla a continuación presenta un resumen conciso de los contenidos de cada capítulo del documento.

Tabla 1.2: Estructura de Capítulos. Fuente: Autoría Propia

Capítulo	Descripción
Capítulo 2: Alcance de la propuesta	En este capítulo se define el alcance de la propuesta
Capítulo 3: Marco Referencial	Se explican los conceptos fundamentales para entender el problema y su solución, se se asume que el lector tenga conocimiento básico en áreas relacionadas.
Capítulo 4: Análisis de preferencia de los usuarios	En este capítulo se recolecta información sobre las preferencias y necesidades demandadas de los usuarios.
Capítulo 5: Modelo	En este apartado se exponen las distintas alternativas de modelos planteados para el desarrollo del prototipo.
Capítulo 6: Desarrollo del Proyecto	Este capítulo detalla los criterios y consideraciones fundamentales incorporados en el diseño y desarrollo de la aplicación.
Capítulo 7: Pruebas	En este apartado se documentan los procedimientos de prueba ejecutados durante el desarrollo del proyecto, junto con el análisis de los resultados obtenidos.
Capítulo 8: Conclusiones y Trabajos Futuros	Se exponen los hallazgos finales del estudio y se proponen desarrollos posteriores necesarios para optimizar la solución tecnológica planteada.

Capítulo 2

Alcance de la Propuesta

En primera instancia, se realiza una exhaustiva revisión de literatura y documentos técnicos que contienen información relevante para respaldar la toma de decisiones durante el desarrollo del prototipo del sistema de recomendación. Esta etapa abarca aspectos clave como la identificación de las necesidades del usuario en el proceso de compra de computadores portátiles y la posible integración de interfaces conversacionales que faciliten la interacción.

Durante este análisis documental, se extrae información sobre los elementos más significativos relacionados con el comportamiento del consumidor, las características técnicas de los equipos y las estrategias utilizadas en sistemas de recomendación previos. Esto permite identificar ventajas, limitaciones y oportunidades de mejora que servirán de base para orientar el diseño del sistema.

Posteriormente, se realiza una comparación entre diferentes enfoques y modelos de recomendación aplicables al proyecto, con énfasis en cómo estos modelos abordan las preferencias individuales del usuario al seleccionar un computador portátil. La elección del modelo final considera su capacidad para comprender y adaptarse a los distintos perfiles de usuario, garantizando una experiencia fluida y satisfactoria.

Una vez seleccionado el modelo, se avanza hacia la fase de implementación, donde se diseña la arquitectura general del sistema y se desarrolla el código de la aplicación. Esta aplicación está orientada a cumplir con la propuesta inicial, ofreciendo recomendaciones de computadores portátiles que se ajusten a los requerimientos técnicos, presupuestales y de uso del usuario.

Se adopta un enfoque de desarrollo web, acompañado por la implementación de una base de datos que permita almacenar información relevante de cada laptop y personalizar la experiencia de cada usuario. Esta personalización es fundamental para mejorar la precisión del sistema. Para evaluar la usabilidad de la aplicación, se diseña y distribuye una encuesta a

través de Google Forms. Esta tiene como objetivo principal comprender cómo los usuarios perciben la utilidad, facilidad de uso y efectividad de las recomendaciones proporcionadas por el sistema.

Finalmente, se llevan a cabo pruebas con personas externas a la universidad. Los participantes completan la encuesta diseñada, aportando retroalimentación valiosa que permite validar el funcionamiento del sistema y proponer ajustes futuros basados en la experiencia real de los usuarios.

Capítulo 3

Marco de Referencia

3.1. Conceptos Básicos

Los siguientes fundamentos teóricos resultan esenciales para la comprensión integral del desarrollo de un sistema de recomendación y su implementación mediante un chatbot.

3.2. Marco Teórico

- **Teoría General de los Sistemas:** La teoría concebida por Ludwig von Bertalanffy en la década de 1940 tiene como objetivo proporcionar un marco teórico y práctico a las ciencias naturales y sociales. Su impacto fue un cambio significativo en la forma de pensar y percibir la realidad, lo que influyó de manera importante en la psicología y en el desarrollo de una nueva teoría sobre la comunicación humana. Mientras que el mecanicismo veía el mundo dividido en partes cada vez más pequeñas, el enfoque de sistemas introdujo una perspectiva holística de observación que reveló fenómenos previamente desconocidos (que siempre estuvieron allí, pero se desconocían) y estructuras de complejidad inimaginable.
- **Machine learning:** Según la página web de IBM, el machine learning es una forma de la IA que permite a un sistema aprender de los datos, en lugar de aprender mediante la programación explícita. Sin embargo, el machine learning no es un proceso sencillo.

Conforme el algoritmo ingiere datos de entrenamiento, es posible producir modelos más precisos basados en dichos datos. Un modelo de machine learning es la salida de información que se genera cuando se entrena el algoritmo con datos. Después del entrenamiento, al proporcionar un modelo con una entrada, se generará una salida. Hay dos tipos principales de técnicas: aprendizaje supervisado, que comienza típicamente con un conjunto de datos establecido y una comprensión de cómo se clasifican estos datos. El aprendizaje supervisado tiene la intención de encontrar patrones en datos que se pueden aplicar

a un proceso de análisis. Estos datos tienen características etiquetadas que definen el significado de los mismos. Por otro lado, el aprendizaje no supervisado se utiliza cuando el problema requiere una cantidad masiva de datos sin etiquetar. Por ejemplo, las aplicaciones de redes sociales como Twitter, Instagram y Snapchat manejan grandes cantidades de datos sin etiquetar. La comprensión del significado detrás de estos datos requiere algoritmos que clasifican los datos basándose en los patrones o clústeres que encuentra.

- **Filtrado basado en contenido:** Según Kanetkar, es una técnica de machine learning utilizada en los sistemas de recomendación que utiliza los datos o atributos específicos de la información que se le suministre para hacer el filtro y clasificación de las recomendaciones. Puede realizar las recomendaciones basándose en la información de los productos o en la información de los usuarios. Esta técnica aprende de las preferencias e intereses de los usuarios para realizar las recomendaciones, por lo que requiere métodos de aprendizaje como Support Vector Machine (SVM) y redes neuronales.[12]
- **Filtrado colaborativo:** Según IEBS, el filtrado colaborativo es una técnica utilizada por los sistemas de recomendación para solventar los problemas derivados de la sobreinformación que los consumidores sufren en internet. Esta tendencia crece cada día más, debido a su enorme funcionalidad, por lo que cada vez más usuarios se valen de esta herramienta en sus búsquedas.
- **Minería de datos:** Según un artículo de Sinnexus, la minería de datos es un conjunto de técnicas que analizan la información contenida en grandes bases de datos para encontrar patrones, tendencias y explicar o predecir comportamientos en un contexto determinado. Trabaja de la mano con la estadística al dar razón de los datos que son estudiados y las conclusiones que se pueden obtener aplicando alguna de sus técnicas. [13]
- **Sistemas de recomendación:** son básicamente herramientas que nos ayudan a decidir qué ver, comprar o escuchar, según lo que nos gusta o lo que hemos hecho antes. Funcionan analizando nuestros gustos, el historial de lo que ya hemos visto o comprado, o lo que hacen personas parecidas a nosotros. Estos sistemas los vemos todo el tiempo en lugares como TikTok, Netflix, YouTube o Instagram. La idea principal es hacernos la vida más fácil, filtrando la cantidad enorme de información que hay, y mostrándonos solo lo que más nos podría interesar. [14]

Tipos:

- **Sistemas de popularidad:** Los sistemas basados en la popularidad son implementados principalmente en las ventas de productos o sugerencias concretas. Estos toman como referencia la popularidad del objeto de estudio por una variable principal que puede ser el número de ventas, una característica especial o inclusive una oferta y se muestra de forma general a todos los usuarios que investiguen el área a la que pertenece el objeto. Estos sistemas suelen ser fáciles de implementar y gozan de cierto nivel de efectividad. Su desventaja principal es la imposibilidad de personalizar los criterios de sugerencia para el usuario.

- **Basados en conocimiento:** Este tipo utiliza información explícita sobre los usuarios y los productos. A diferencia de los anteriores, no necesita grandes cantidades de datos históricos, sino que opera a partir de reglas definidas o lógicas de inferencia.
- **Basados en demografía:** Ofrecen recomendaciones tomando en cuenta atributos demográficos del usuario, como edad, género, localización, etc.
- **Sistemas de recomendación híbridos:** Los sistemas de recomendación híbridos combinan diversas técnicas para mejorar las recomendaciones y abordar los problemas específicos presentes en cada una de ellas. La premisa fundamental de este enfoque es fusionar distintas técnicas de SR de manera que se mantengan las ventajas individuales de cada una, mientras que las desventajas de una técnica particular puedan ser atenuadas por las propiedades de las otras técnicas. [15]

3.2.1. Tipos de filtrados

3.2.1.1. Filtrado basado en reglas de asociación

Descripción e Implementación: Es una técnica de recomendación que identifica patrones de coocurrencia entre ítems. Su meta es descubrir reglas "si A, entonces B" (por ejemplo: "quien compra café, también compra azúcar") a partir de historiales de transacciones. Usa algoritmos como Apriori para encontrar conjuntos de ítems que aparecen juntos a menudo.[16]

3.2.2. Filtrado basado en Usuario

Este método funciona bajo la premisa de que si dos usuarios han mostrado intereses o calificaciones similares en el pasado (por ejemplo, les gustaron las mismas películas), es probable que tengan gustos futuros compartidos. Para determinar esta similitud, se utilizan métricas como la distancia euclidiana (que mide la proximidad en un espacio multidimensional de preferencias) o la similitud coseno (que evalúa el ángulo entre vectores de calificaciones).[17]

3.2.3. Filtrado colaborativo

El filtrado colaborativo filtra la información utilizando las interacciones y los datos que el sistema recopila de otros usuarios. Se basa en la idea de que quienes coincidieron en su evaluación de ciertos elementos probablemente volverán a coincidir en el futuro. [18]

3.2.4. Filtrado basado en contenido

El filtrado basado en contenido es una técnica de recomendación que se enfoca en las características o atributos intrínsecos de los ítems que un usuario ha mostrado interés en el pasado. La idea central es que, si a un usuario le ha gustado un ítem con ciertas características, también le gustarán otros ítems que compartan atributos similares. Por ejemplo, si un usuario disfruta de películas de acción y ciencia ficción protagonizadas por un actor específico, el

sistema de contenido buscará y recomendará otras películas que cumplan con esas mismas características.

3.2.5. Redes neuronales

Se usan cuando el sistema necesita entender patrones más complejos, sobre todo si se trabaja con muchos datos. Es muy común en plataformas grandes.

3.2.6. Descomposición de matrices (como SVD o NMF)

Sirven para encontrar relaciones ocultas entre usuarios y productos, especialmente en los sistemas que usan filtrado colaborativo.

3.2.7. K-Nearest Neighbors (KNN)

Esta técnica busca los usuarios o productos más parecidos para hacer recomendaciones. Es una de las más usadas por lo simple y efectiva que es.

3.2.8. Aprendizaje profundo (Deep Learning)

Se usa en sistemas más avanzados, donde hay muchos tipos de contenido y se necesita entender mejor la relación entre usuario y producto.

3.2.9. Sistemas basados en grafos

Aquí los usuarios y los productos se ven como puntos conectados por líneas. Así se pueden encontrar rutas o relaciones entre ellos que ayudan a recomendar cosas más acertadas.

Capítulo 4

Investigación previa para el desarrollo del proyecto

4.1. Análisis de preferencias de los usuarios

En esta sección se presenta un análisis detallado de las preferencias de los usuarios en relación con la compra de computadores portátiles. Para recopilar información relevante, se diseñó y aplicó una serie de preguntas dirigidas a dos asesores tecnológicos de almacenes éxito y de Homecenter.

4.1.1. Descripción de la metodología utilizada

Se llevo a cabo una serie preguntas las cuales se grabaron con un dispositivo móvil para obtener una comprensión profunda de las preferencias, experiencias y necesidades de los usuarios al momento de adquirir un computador portátil. Se abordaron aspectos clave como las marcas favoritas, usos principales del equipo (por ejemplo: estudio, trabajo, diseño gráfico o videojuegos), presupuesto disponible, características técnicas preferidas (como procesador, memoria RAM, almacenamiento, entre otras), y otros criterios relevantes que influyen en el proceso de toma de decisiones.

Este enfoque metodológico asegura una recolección de datos y un análisis gracias a la información proporcionada por los participantes, y se centra en analizar los datos recopilados a través de la entrevista. Esto permite extraer conclusiones significativas que orienten el desarrollo de una aplicación web de recomendación de **computadores portátiles**, adaptada a las necesidades y preferencias identificadas en este estudio.

4.2. Encuesta

Con el objetivo de conocer de primera mano el comportamiento y nivel de conocimiento de los usuarios al momento de adquirir un computador portátil, se realizaron entrevistas a asesores especializados en ventas tecnológicas de reconocidos almacenes de cadena en la ciudad de Tuluá, Valle del Cauca. Estos profesionales cuentan con experiencia directa en la atención al cliente y poseen una visión clara sobre las necesidades, dudas y criterios más comunes que expresan los compradores durante el proceso de selección.

4.2.1. Perfil de los encuestados

A continuación, se presenta el perfil de los encuestados y un resumen de sus respuestas más relevantes.

José Javier (*Asesor de compras tecnológicas en éxito de la 14 de la ciudad de Tuluá valle*)

Jhon Quintero (*Asesor de compras tecnológicas en Homecenter de la 14 de la ciudad de Tuluá valle*)

Cuando las personas van a comprar un computador portátil, ¿suelen preguntarte por aspectos técnicos específicos, como la memoria RAM o el procesador?

R: La mayoría de los clientes no tiene conocimientos técnicos previos sobre los equipos. Generalmente, solo mencionan para qué lo van a usar, como por ejemplo para la universidad o el trabajo. Aproximadamente el 90 % de quienes piden una recomendación no cuentan con un conocimiento técnico detallado.

A la hora de determinar qué computador es ideal para cada persona, ¿qué criterios tomas en cuenta?

R// La recomendación se basa principalmente en la necesidad del cliente. Por ejemplo, si es un estudiante, se le pregunta qué carrera estudia. Si necesita el equipo para diseño gráfico, se sugiere uno con tarjeta gráfica y un procesador potente. Es un enfoque estándar que seguimos todos los asesores para asegurar que el computador se ajuste a las exigencias de uso del cliente.

¿Cuáles son las marcas más comunes que los clientes eligen al momento de comprar un portátil?

R// Las marcas más comunes que eligen los clientes son Asus y HP, ya que son reconocidas y tienen una larga trayectoria en el mercado. Los clientes suelen sentirse más confiados al comprarlas. Aunque existen otras marcas con excelente calidad, muchas veces no son conside-

radas porque no tienen el mismo nivel de respaldo o reconocimiento por parte del consumidor.

En la mayoría de los casos, ¿cuál es el factor más importante al momento de hacer una recomendación?

R// El factor más importante suele ser el presupuesto. Muchos clientes llegan con un presupuesto limitado, por lo que lo ideal es encontrar un equilibrio: recomendar un equipo que se ajuste a sus necesidades sin exceder el monto que pueden invertir. La prioridad es cubrir lo esencial para el uso que le van a dar, respetando su capacidad económica.

4.2.2. Conclusiones

Después de analizar detalladamente las respuestas recopiladas a través de las entrevistas sobre preferencias de computadores portátiles, usos previstos y sugerencias para la aplicación web de recomendación, se han identificado hallazgos relevantes que influyen directamente en el diseño y desarrollo del sistema. A continuación, se resumen los puntos clave:

Relación entre preferencias y comportamientos:

Las preferencias en cuanto a características como el tipo de procesador, la memoria RAM, el almacenamiento y la marca tienen una fuerte incidencia en los comportamientos de búsqueda de los usuarios. Se observa una inclinación significativa hacia computadores portátiles con buen rendimiento para tareas específicas (como programación, diseño gráfico o estudio), destacándose la importancia del precio, la duración de la batería y la portabilidad en el proceso de decisión de compra.

Hallazgos significativos: Los usuarios priorizan precio como un factor determinante a la hora de buscar un computador portátil. Existe una necesidad clara por contar con una aplicación web que facilite la comparación entre distintos modelos, brinde recomendaciones personalizadas y ofrezca una experiencia de navegación intuitiva. Implicaciones para el desarrollo de la aplicación web:

- Es esencial diseñar una interfaz amigable, clara y accesible, que incluya funcionalidades como la comparación de características técnicas, recomendaciones ajustadas al perfil del usuario y un sistema de filtrado basado en criterios como el uso principal, el presupuesto y las especificaciones deseadas.
- La aplicación debe ser capaz de equilibrar factores clave como el precio, el rendimiento, la capacidad de almacenamiento y la autonomía, en función de las preferencias identificadas, con el fin de brindar una experiencia útil, personalizada y eficiente al usuario final.

Capítulo 5

Modelos

En este capítulo se establece el algoritmo de recomendación, así como los sistemas de estados y de navegación necesarios para el desarrollo de la aplicación web. Se detallan los componentes funcionales que permitirán personalizar las recomendaciones de computadores portátiles según las necesidades del usuario. Es importante mencionar que el desarrollo de esta aplicación web se llevo a cabo en un computador con las siguientes características:

- Procesador: AMD Ryzen 7 4700U con Radeon Graphics 2.00 GHz
- Memoria: 16 GB 3.200 MHz
- HDD: 1TB

5.1. Técnicas de recomendación

En el campo de la sugerencia de contenido, se utilizan diversas metodologías para ofrecer recomendaciones personalizadas a los usuarios. Entre estas se distinguen múltiples clases de filtrado. Asimismo, hay estrategias combinadas que fusionan estas técnicas para optimizar la exactitud y la variedad de las propuestas.

5.2. Selección de modelo

La decisión fue utilizar un filtrado basado en reglas de asociación como método principal en el sistema de recomendación de computadores portátiles. A raíz de ofrecer sugerencias más acertadas y personalizadas, mejorando al mismo tiempo la experiencia del usuario dentro de la aplicación web. Esta técnica resulta particularmente eficaz cuando no se cuenta con conocimientos técnicos detallados por parte del usuario, ya que permite detectar patrones relevantes a partir de las respuestas generales.

Mediante el análisis de la relación entre diferentes atributos, como el presupuesto disponible,

el uso previsto del dispositivo (por ejemplo: estudio, trabajo, diseño gráfico, videojuegos), las marcas preferidas o características técnicas generales, el sistema puede ofrecer recomendaciones adecuadas sin necesidad de depender de datos cuantitativos precisos. Por ejemplo, a través de la API de Gemini, se generan preguntas limitadas por medio de un Prompt, el cual contiene instrucciones específicas para formular interrogantes dirigidas a un usuario sin conocimientos técnicos avanzados. Las respuestas obtenidas se recopilan y, gracias a la integración de esta inteligencia artificial en el sistema, se genera una recomendación personalizada.

Además de integrar la inteligencia artificial para generar automáticamente las preguntas y analizar las respuestas con el fin de obtener una recomendación final, también se desarrolló un chatbot que permite al usuario recibir las sugerencias de una forma más accesible y comprensible. A través de este chatbot, el usuario puede realizar preguntas, comparar las recomendaciones que más le interesen y mantener una conversación fluida y natural, lo que mejora significativamente la experiencia de interacción con el sistema.

A continuación, se presenta un diagrama que permite comprender con mayor claridad por qué se determinó que el filtrado basado en reglas de asociación era la opción más adecuada para el desarrollo de este proyecto.




Figura 5.1: Relación entre opciones de respuesta. Fuente: Elaboración propia.

En este diagrama se representa la relación entre opciones de respuesta de una pregunta que realiza el sistema de recomendación. Se evidencia que, a partir de preguntas generales relacionadas con la usabilidad del dispositivo como, por ejemplo, para qué se necesita el computador, es posible obtener recomendaciones concretas, tales como un equipo para trabajo de oficina,

un PC orientado al gaming, uno enfocado en diseño, entre otras opciones. No es necesario formular preguntas técnicas o específicas desde el inicio, ya que este prototipo está orientado a asistir a usuarios sin conocimientos técnicos.

Adicionalmente, se observan flechas de doble sentido que indican que, a medida que el usuario responde, el sistema es capaz de adaptar sus preguntas y generar otras más técnicas. Esto se logra mediante la implementación de un sistema de filtrado basado en reglas de asociación, el cual permite que la inteligencia artificial relacione las respuestas previas con nuevas preguntas. De este modo, se mejora progresivamente la precisión de la recomendación final, ajustándola a las necesidades reales del usuario.

El filtrado basado en reglas de asociación es una técnica eficaz para los sistemas de recomendación, ya que permite identificar patrones entre las características del producto. Al no depender de datos históricos de usuarios, resulta especialmente útil en contextos donde la información previa sobre el comportamiento del usuario es limitada o inexistente. Esta técnica se basa en las relaciones entre atributos como el rango de precios, el propósito de uso (estudio, trabajo, diseño, videojuegos) y las especificaciones técnicas clave.

A continuación, se evidenciara a mostrar el flujo del modelo basado en el filtrado basado en reglas de asociación.




Figura 5.2: flujo del modelo. Fuente: Elaboración propia.

5.3. Sistemas de estados

El flujo de la aplicación se define por los siguientes estados:

1. Estado de Inicio

- La plataforma está preparada y en espera para comenzar la interacción con el usuario.

2. Estado de Preguntas

- Se realizan preguntas al usuario en base a sus preferencias y necesidades con respecto a características de los computadores portátiles. (marca, presupuesto, tipo de uso, etc.)

3. Estado de Recomendación

- Una vez que el usuario ha completado todas las preguntas, la aplicación analiza los datos recopilados y ofrece sugerencias en función de los portátiles disponibles mediante la API.
- El sistema ofrece al usuario un total de cinco recomendaciones personalizadas según las respuestas proporcionadas, y este puede interactuar con el chatbot para recibir información complementaria sobre dichas sugerencias.
- Además, el usuario tiene la posibilidad de comparar las recomendaciones en función de una necesidad específica adicional, y el chatbot está capacitado para ofrecer una nueva recomendación basada en ese criterio.

4. Estado Final

- Una vez que el usuario ha revisado las recomendaciones y interactuado con el chatbot, la aplicación entra en un estado de espera, permitiendo que el usuario decida si desea realizar alguna acción adicional, como consultar más detalles, iniciar una nueva recomendación, entre otras opciones.

Capítulo 6

Desarrollo de la Aplicación

6.1. Metodología de Desarrollo

Para el desarrollo del proyecto se utilizó una metodología ágil, adaptada al contexto académico, basada en iteraciones semanales. Cada semana se realizaban reuniones de seguimiento con el profesor guía, donde se presentaban avances, se recibía retroalimentación y se definían los objetivos para el siguiente ciclo. Esta dinámica permitió una mejora continua y un enfoque flexible orientado a resultados.

6.2. Dataset

Para obtener información actualizada sobre los portátiles disponibles en Colombia, se recurrió a diversas aplicaciones web con el fin de diversificar las fuentes y ofrecer la mejor recomendación posible al usuario. En particular, se utilizaron las plataformas de Mercado Libre, Alkosto y Éxito, de las cuales se extrajo información detallada sobre los computadores actualmente disponibles en el mercado. A través de estas fuentes fue posible recopilar datos relevantes como el tipo de procesador, precio, capacidad de almacenamiento, entre otros aspectos fundamentales para el desarrollo del proyecto.[19] [20] [21]

Para extraer la información de las páginas anteriormente mencionadas, se empleó una técnica conocida como web scraping [22], la cual permitió recopilar de manera eficiente los datos relevantes de los computadores. Esta técnica facilitó la agrupación de la información en un archivo JSON estructurado y ordenado, lo que resultó fundamental para el análisis y procesamiento posterior dentro del proyecto.

Al utilizar esta técnica, se garantiza que la información recopilada esté actualizada y contenga datos detallados sobre los portátiles disponibles en el mercado. Esto proporciona una base sólida y estructurada para llevar a cabo el análisis y la evaluación de cada recomendación

generada por el sistema.

6.2.1. Aspectos Éticos

- Para obtener información actualizada sobre laptops disponibles en Colombia, se utilizó web scraping de sitios comerciales como Alkosto, Éxito y MercadoLibre. Sin embargo, se reconoce que:
- Alkosto prohíbe expresamente el uso de herramientas automatizadas como “spiders” o “site copiers” en sus términos de uso [alkosto.com](https://www.alkosto.com).
- Éxito, aunque no especifica directamente el scraping, prohíbe usos ilícitos o negligentes de su plataforma Aliado Surtimax — Aliado Super Inter.
- MercadoLibre potencia un uso regulado de sus datos mediante APIs oficiales para desarrolladores developers.mercadolibre.cl.

Además, autoridades de protección de datos han advertido que, incluso los datos públicos están sujetos a regulaciones y que el scraping masivo sin consentimiento puede vulnerar derechos fundamentales. Por lo que, se recomienda que en futuras versiones del proyecto:

1. Respeten los términos y limitaciones técnicas de cada plataforma (intervalos entre solicitudes, exclusión de repetición excesiva).
2. Se comunica explícitamente que estos métodos fueron usados exclusivamente con fines académicos y sin fines comerciales.

6.2.2. Descripción del Dataset

El conjunto de datos(dataset) está compuesto por información obtenida mediante web scraping de las plataformas web de Mercado Libre, Alkosto y Éxito. Estos datos servirán como base para el desarrollo de un sistema de recomendación orientado a la compra de portátiles, lo cual permitirá ofrecer recomendaciones personalizadas a los usuarios según sus necesidades y preferencias.

La base de datos contiene atributos que recogen la información más relevante de los computadores portátiles, tales como:

La base de datos cuenta con información relevante como:

1. Nombre
2. Marca
3. Precio
4. Imagen
5. Procesador

6. Memoria RAM
7. Almacenamiento
8. Sistema Operativo
9. Tamaño de pantalla
10. Tarjeta Gráfica
11. URL

6.2.3. Extracción de datos

Con el objetivo de contar con información lo más actualizada posible, y dado que no se encontró una base de datos centralizada sobre el mercado de portátiles, se optó por llevar a cabo un proceso de web scraping en diversos sitios web, desde los cuales se extrajeron datos relevantes para el sistema.

- El scraping se realizó utilizando Python, permitiendo extraer información relevante sobre los portátiles, como la marca, el precio, el procesador, entre otros atributos. Los datos obtenidos se almacenan dentro de un script para su posterior uso.
- Para almacenar los datos obtenidos a través del web scraping, se decidió utilizar Supabase como sistema de base de datos relacional.

6.2.4. Migración de datos en la base de datos

La estructura de la base de datos se diseñó a través de la plataforma visual de Supabase. La recolección de los datos se realizó aplicando técnicas de extracción web (scraping) sobre los sitios previamente mencionados, y estos se guardaron inicialmente en un archivo con formato JSON. Más adelante, dicha información fue convertida a un archivo CSV, el cual se incorporó a la base de datos con el objetivo de asegurar una inserción de datos precisa y eficiente.




Figura 6.1: Diagrama de flujo de la aplicación. Fuente: autoría propia.

Este diagrama representa el flujo general de funcionamiento de la aplicación. se describe cómo el sistema guía al usuario desde el inicio hasta la presentación de recomendaciones personalizadas de computadores portátiles, basadas en sus intereses y necesidades:

1. **Inicio:** El proceso comienza con la ejecución del sistema, marcando el punto de partida de la interacción con el usuario.
2. **Obtener preguntas de la API (Gemini):** En esta etapa, el sistema consulta a la API de Gemini para obtener un conjunto de preguntas. Estas preguntas están diseñadas por medio de un prompt para recopilar información relevante del usuario sin requerir conocimientos técnicos.

3. **Entrada de información sobre los intereses o necesidades del usuario:** El usuario responde las preguntas proporcionadas, las cuales tiene como fin identificar aspectos como el uso que le dará al computador (trabajo, diseño, gaming, etc.), presupuesto, entre otros factores clave para una recomendación adecuada.
4. **Obtener información de la API (Supabase):** Con base en las respuestas del usuario, el sistema consulta una base de datos alojada en Supabase. Esta base contiene información detallada de diversos modelos de computadores disponibles, incluyendo características técnicas, rangos de precio, etc.
5. **Recomendador:** En esta fase, el motor de recomendación analiza la información ingresada por el usuario y la cruza con los datos obtenidos desde Supabase. Aplica una lógica de filtrado que prioriza el cumplimiento de las necesidades del usuario, comenzando por los criterios más restrictivos como el presupuesto.
6. **Mostrar las recomendaciones:** Finalmente, el sistema presenta al usuario una lista de 5 computadores sugeridos que se ajustan a su perfil. Estas recomendaciones son claras, personalizadas y comprensibles, permitiendo que incluso usuarios sin experiencia técnica puedan tomar decisiones informadas.

6.3. Tecnologías Utilizadas

- Se eligió **Node.js** por su eficiencia en el manejo de múltiples solicitudes simultáneas gracias a su modelo asíncrono y no bloqueante, ideal para aplicaciones interactivas como el sistema de recomendación. Su amplio ecosistema de librerías también facilitó la integración con APIs externas, bases de datos y servicios de inteligencia artificial.[23]
- Se utilizó **React** por su capacidad para construir interfaces de usuario dinámicas, reutilizables y de alto rendimiento. Gracias a su enfoque basado en componentes, React permite desarrollar una interfaz modular y escalable, facilitando la gestión del estado de la aplicación y mejorando la experiencia del usuario. Además, su integración fluida con tecnologías modernas como Node.js y su gran comunidad de soporte lo convierten en una herramienta ideal para aplicaciones web interactivas como Odyssey. [24]
- Se eligió **Supabase** como sistema de base de datos por ser una alternativa moderna, de código abierto y basada en PostgreSQL, que permite una gestión eficiente de datos relacionales. Su integración nativa con autenticación, almacenamiento y APIs en tiempo real facilita el desarrollo rápido y seguro del backend. Además, su interfaz visual simplifica la administración de la base de datos y agiliza la conexión con la aplicación, lo cual fue clave para manejar dinámicamente la información de los portátiles [25]
- Se utilizó **TypeScript** por su capacidad para mejorar la calidad y la mantenibilidad del código mediante tipado estático. Esta característica permite detectar errores en tiempo de desarrollo, lo que reduce fallos en tiempo de ejecución y facilita el trabajo en equipos o proyectos a largo plazo. Gracias a su compatibilidad con bibliotecas modernas y su

integración nativa con herramientas como React y Node.js, TypeScript aporta robustez, escalabilidad y claridad en el desarrollo del sistema.[26]

- Se utilizó **AI SDK** por ser un conjunto de herramientas moderno y optimizado, desarrollado por Vercel, que facilita la integración de modelos de lenguaje en aplicaciones web. Gracias a su compatibilidad nativa con frameworks como Next.js y React, permite construir interfaces inteligentes como chatbots, asistentes virtuales o sistemas de recomendación con una experiencia fluida para el usuario. AI SDK simplifica el consumo de APIs de modelos avanzados como OpenAI, Google Gemini o Cerebras, permitiendo desarrollar funcionalidades de inteligencia artificial de forma eficiente y con menos complejidad técnica. Esta herramienta resulta especialmente útil en proyectos como Odyssey, donde se busca incorporar capacidades conversacionales o de recomendación inteligente de manera rápida, escalable y mantenible.[27]
- Se utilizó **Python** como lenguaje de programación principal para el desarrollo del script de scraping, debido a su simplicidad sintáctica, su amplia comunidad y su gran ecosistema de librerías especializadas. Herramientas como BeautifulSoup, Requests y Selenium permiten extraer información de sitios web de forma eficiente y estructurada.
- Selenium: Biblioteca que permite controlar un navegador web (Chrome en este caso) de forma automatizada, simulando la interacción de un usuario real. [28]
- **WebDriver Manager** Utilidad que gestiona automáticamente la instalación y actualización del driver de Chrome (ChromeDriver), evitando configuraciones manuales. [29]
- **ChromeDriver** fue un Componente necesario para que Selenium pueda controlar el navegador Google Chrome. [30]

6.4. Motor de recomendación

Para el motor de recomendación se utiliza un segundo modelo de inteligencia artificial llamado Gemini 2.5 Flash, caracterizado por su alta velocidad de procesamiento y baja latencia. Este modelo, a partir de las respuestas proporcionadas por el cliente y una lista de computadores disponibles, genera un array con los IDs de los equipos recomendados. Gracias a su capacidad para interpretar las necesidades del usuario a partir de sus respuestas, ofrece recomendaciones precisas y acorde con los requerimientos del usuario.[31]

Esta implementación de inteligencia artificial para generar las recomendaciones finales resulta más viable que utilizar algoritmos tradicionales que requieren actualizaciones futuras, ya que los modelos de inteligencia artificial evolucionan de forma continua y se adaptan automáticamente a nuevos contextos. En caso de que la calidad de las recomendaciones disminuya, se puede recurrir a un modelo más robusto que implemente el enfoque Thinking, el cual analiza en profundidad las sugerencias antes de presentarlas al usuario. Esto garantiza recomendaciones aún más precisas, personalizadas y confiables.

Se llega a la conclusión de que el modelo de inteligencia artificial implementa o utiliza reglas de asociación para generar las recomendaciones finales. Esto gracias a que el modelo analiza las respuestas del usuario (por ejemplo, “quiero un equipo para diseño gráfico” o “para videojuegos”) y detecta patrones que lo llevan a asociar ciertas características con ciertos computadores. Esta relación es similar a una regla de asociación, donde si se cumplen ciertas condiciones (X), entonces se recomienda un conjunto de elementos (Y):

Ejemplo:

Si el usuario necesita el computador para edición de video, entonces recomendar computadores con GPU dedicada y procesador de alto rendimiento.

6.5. Demostración del prototipo



Figura 6.2: Estado inicial del prototipo web. Fuente: Elaboración propia.

En esta parte del prototipo, que corresponde al inicio del desarrollo web, se presenta el nombre de la aplicación: Odyssey. Este nombre fue elegido porque, para muchas personas que no tienen conocimientos técnicos, comprar un computador puede convertirse en una verdadera odisea. Buscar una opción adecuada a sus necesidades puede resultar confuso y frustrante. Por ello, este sistema fue creado con el objetivo de solucionar ese problema, y en consecuencia, se tomó la decisión de nombrarlo Odyssey.

Luego, se observa la presencia de un personaje que representa a un ingeniero en sistemas, identificado por sus gafas características, quien acompañará durante todo este proceso. Tam-

bién se encuentran dos botones: uno de Inicio, que permite regresar a esta pantalla inicial de la aplicación, y otro de Empezar, que da inicio al segundo apartado de la aplicación.



Figura 6.3: Estado inicial de las preguntas. Fuente: Elaboración propia.

En la segunda parte de la aplicación, siempre se va a preguntar por el presupuesto del usuario, ya que llegamos a la conclusión de que este es el factor más importante para realizar el filtrado. Básicamente, el presupuesto es el criterio que más influye para segmentar gran parte de la información en la base de datos. Esto permite mostrar al usuario solo las opciones que realmente están dentro de su rango económico, facilitando la búsqueda y evitando sobrecostos al usar los tokens que nos proporciona el servicio de la API.



Figura 6.4: Segunda fase de las preguntas. Fuente: Elaboración propia.

A partir de esta sección, las preguntas se generan a través de la API de Google, específicamente utilizando el modelo Gemini 2.0 Flash Lite Preview (02-05). Este modelo es gratuito, pero presenta ciertas limitaciones tanto en capacidad de procesamiento como en la cantidad de tokens que se pueden enviar a la API.

Las preguntas están guiadas mediante un prompt, donde se le indica a la inteligencia artificial cómo debe generar cada pregunta y con qué objetivo. En total, la IA genera 10 preguntas, las cuales se procesan posteriormente para ofrecer al usuario un conjunto de 5 recomendaciones personalizadas, basadas en sus respuestas.



Figura 6.5: Etapa de recomendaciones. Fuente: Elaboración propia.

Esta sección corresponde al momento en el que se le presentan al cliente las 5 recomendaciones basadas en sus necesidades puntuales. En cada una de estas recomendaciones se muestra información relevante como el precio, el procesador, la memoria RAM, el tipo y tamaño de pantalla, y si el equipo cuenta con tarjeta gráfica, se especifica cuál es. Además, se incluye una imagen del computador tomada directamente del sitio web y un enlace directo para realizar la compra, ya sea en Mercado Libre, Éxito o Alkosto.



Figura 6.6: Etapa de recomendaciones. Fuente: Elaboración propia.

Luego de presentar todas las recomendaciones, el sistema muestra un mensaje final indicando que el usuario puede realizar cualquier pregunta adicional relacionada con las opciones sugeridas. Esto se hace pensando en que muchas personas no tienen conocimientos técnicos sobre las características de los computadores y prefieren hacer consultas más generales, como por ejemplo: Estudio diseño gráfico, ¿cuál de estas opciones es mejor y por qué?. Ante este tipo de preguntas, el sistema está preparado para dar una respuesta personalizada y explicativa, ayudando así al usuario a tomar una decisión informada.



Figura 6.7: Etapa del chatbot. Fuente: Elaboración propia.

Al realizar cualquier consulta, el chatbot es capaz de responder tanto preguntas específicas como generales formuladas por el usuario. Esto se logra gracias a la integración con modelos de

lenguaje avanzados, los cuales permiten interpretar el contexto y la intención detrás de cada mensaje. Como resultado, el sistema ofrece respuestas coherentes, relevantes y adaptadas a las necesidades del usuario, mejorando significativamente la experiencia de interacción y asistencia dentro de la aplicación.




Figura 6.8: Diagrama de flujo prototipo web Fuente: Elaboración propia.

Tal como lo representa el diagrama, en la parte inicial del prototipo el usuario solamente tiene dos opciones: quedarse en el apartado de inicio o hacer clic en el botón que da comienzo al cuestionario. Si el usuario decide iniciar, el sistema automáticamente pasa a preguntar por el presupuesto, convirtiéndose este en un proceso predefinido, lo cual se refleja en el tipo de figura utilizada en el diagrama.

Este paso está definido de forma obligatoria porque el presupuesto es uno de los factores clave (por no decir el más importante) para realizar un pre-filtrado inicial de todas las computadoras disponibles. Este filtro permite reducir de manera significativa la cantidad de opciones y

agiliza la posterior generación de recomendaciones más acertadas.

Una vez establecido el presupuesto, la inteligencia artificial genera una serie de preguntas personalizadas para el usuario. Estas preguntas buscan identificar las necesidades específicas del comprador, y además ofrecen opciones de respuesta como “No tengo preferencia”, para aquellos usuarios que no tienen conocimientos técnicos o no saben cómo responder a ciertos aspectos.

El siguiente paso, también predefinido, es la generación de recomendaciones personalizadas. En esta etapa, la IA utiliza tanto el conjunto de respuestas del usuario como la lista de computadoras ya filtradas por precio para entregar una recomendación final de cinco equipos que se ajustan al perfil del comprador.

En la parte final del flujo, el sistema le da al usuario la posibilidad de interactuar con un chatbot. Este chatbot permite hacer preguntas adicionales sobre las recomendaciones generadas, aclarar dudas o resolver inquietudes. Esta funcionalidad busca complementar el proceso y asegurar que el usuario obtenga la mejor recomendación posible de acuerdo con sus necesidades.

6.5.1. Validación del algoritmo de recomendación

Con el fin de evaluar la validez metodológica del sistema de recomendación desarrollado, se llevó a cabo un proceso de validación externa con un usuario experto, encargado habitualmente de orientar procesos de compra de computadores portátiles en un entorno comercial real.

Perfil del Experto

La validación fue realizada por Juan Pablo Zamora Toro, Técnico y Tecnólogo en Sistemas, actualmente trabajador de la cadena de almacenes Éxito. Su función principal consiste en guiar a los clientes en la selección de computadores portátiles adecuados a sus necesidades, lo que le otorga un criterio especializado para evaluar la pertinencia de las recomendaciones generadas por el sistema.

Metodología de validación

Se seleccionaron 20 casos reales de usuarios que utilizaron la aplicación web. Cada usuario completó el cuestionario del sistema, y la aplicación generó una recomendación personalizada.

Para cada caso, el experto evaluó la recomendación entregada, clasificándola en tres categorías:

- Correcta: La recomendación se ajusta plenamente a las necesidades del usuario.
- Parcialmente correcta: La recomendación cubre parte de las necesidades, pero presenta algún aspecto técnico o de precio que podría mejorarse.
- Incorrecta: La recomendación no satisface los requerimientos principales del usuario.

Resultados obtenidos

Los resultados de la evaluación fueron los siguientes:

Clasificación	Cantidad	Porcentaje
Correcta	17	85 %
Parcialmente Correcta	3	15 %
Incorrecta	0	0 %
Total	20	100 %

Tabla 6.1: Votación del experto. Fuente: Elaboración propia.

Interpretación de resultados

Los resultados muestran que el sistema de recomendación tiene una alta capacidad para generar sugerencias pertinentes: el 85 % de los casos fueron totalmente correctos y el 15 % restante fueron parcialmente correctos, sin que se presentaran recomendaciones completamente erróneas.

Esto sugiere que el motor de recomendación, basado en inteligencia artificial y asistido por un filtrado de reglas de asociación, logra identificar de forma efectiva los portátiles adecuados para los perfiles de usuario evaluados. Las recomendaciones parcialmente correctas se atribuyen a variaciones en características específicas (por ejemplo, capacidad de almacenamiento o modelo exacto de procesador) que podrían optimizarse en futuras iteraciones del sistema.

Capítulo 7

Pruebas

En esta sección se presenta el proceso de pruebas del prototipo, así como un análisis de los resultados obtenidos.

7.1. Planteamiento de las pruebas

La encuesta aplicada incluyó una sección de preguntas cerradas diseñadas para obtener información cuantitativa sobre la percepción de los usuarios respecto al prototipo web. Las preguntas se presentaron en formato de opción múltiple con escalas predefinidas, permitiendo así una fácil clasificación de las respuestas.

La segunda sección del formulario consistió en una pregunta abierta, con el propósito de obtener información adicional sobre la opinión de los usuarios, permitiendo así una retroalimentación más libre y detallada.

¿Cuál es tu nivel de conocimiento sobre computadores?
21 respuestas




Figura 7.1: Pregunta 1 Fuente: Elaboración propia

La primera pregunta buscó conocer el nivel de conocimiento sobre computadores de los participantes, categorizándolos en cuatro niveles: básico, intermedio, avanzado y experto. Esta clasificación permitió contextualizar la experiencia de cada usuario con el sistema. Los resultados mostraron una distribución diversa, siendo predominante el nivel intermedio, lo cual sugiere que la mayoría de los usuarios tienen una comprensión funcional de los equipos, sin llegar a conocimientos técnicos profundos.




Figura 7.2: Pregunta 2 Fuente: Elaboración propia

En esta pregunta se evaluó la facilidad de uso del prototipo, permitiendo a los participantes calificar su experiencia desde "muy difícil de usar" hasta "muy fácil de usar". Esta escala permitió medir la accesibilidad del sistema, destacándose que más del 90 % de los usuarios consideraron el prototipo fácil o muy fácil de utilizar, lo cual refleja una interfaz amigable e intuitiva.



Figura 7.3: Pregunta 3 Fuente: Elaboración propia

En esta pregunta se evaluó la relevancia de las recomendaciones ofrecidas con respecto a las necesidades del usuario. Los datos muestran que un 71.4 % de los participantes consideraron

que la recomendación fue totalmente acorde a sus requerimientos, mientras que un 28.6 % la percibió como bastante adecuada. Esta alta aceptación refleja un adecuado ajuste del algoritmo de recomendación respecto a los criterios ingresados, validando su capacidad de personalización y contextualización según el perfil del usuario.




Figura 7.4: Pregunta 4 Fuente: Elaboración propia

Esta pregunta examinó el grado de dificultad percibido al momento de responder el cuestionario inicial del sistema. Un 90.5 % de los usuarios reportaron no haber tenido ninguna dificultad, lo que sugiere que la interfaz del formulario fue desarrollada con una arquitectura de interacción clara, con flujos bien definidos y comprensibles incluso para usuarios con niveles técnicos diversos. Solo un 9.5 % indicó haber tenido algunas dificultades, lo cual representa una tasa baja de fricción en la obtención de los datos.



Figura 7.5: Pregunta 5 Fuente: Elaboración propia

En esta pregunta se consultó si los pasos para obtener las recomendaciones fueron comprendidos con claridad. El 71.4 % manifestó estar totalmente de acuerdo con esta afirmación y un 28.6 % declaró estar de acuerdo. Esto confirma que la lógica de navegación y el diseño de

la experiencia de usuario (UX) fueron efectivos en guiar al usuario a través del proceso de obtención de recomendaciones, sin ambigüedades ni barreras de comprensión.



Figura 7.6: Pregunta 6 Fuente: Elaboración propia

En esta pregunta se consultó si las recomendaciones generadas por el sistema coincidían con el presupuesto del usuario. El 47.6 % indicó que coincidió bastante y el 42.9 % afirmó que coincidió totalmente. Solo un 9.5 % manifestó que coincidió parcialmente o poco, y ningún usuario declaró que no coincidiera en absoluto. Estos resultados evidencian que el sistema logró adaptar adecuadamente las recomendaciones al criterio económico de los usuarios, lo cual confirma que la lógica de filtrado basada en reglas de asociación fue efectiva al considerar rangos de precios realistas y personalizados.




Figura 7.7: Pregunta 7 Fuente: Elaboración propia

En esta pregunta se evaluó la capacidad del chatbot para resolver las dudas de los usuarios respecto a las recomendaciones presentadas. El 61.9 % expresó que se resolvieron todas sus dudas y el 33.3 % señaló que se resolvieron la mayoría. Solo un 4.8 % indicó que se resolvieron algunas dudas, y ningún usuario mencionó que no se resolviera ninguna. Este resultado

confirma que el componente conversacional fue percibido como útil y funcional, proporcionando una experiencia de asistencia personalizada que complementa y fortalece el sistema de recomendación.




Figura 7.8: Pregunta 8 Fuente: Elaboración propia

En esta pregunta se evaluó el nivel de comodidad experimentado por los usuarios al interactuar con el sistema. El 90.5 % respondió afirmativamente, mientras que un 4.8 % indicó sentirse “más o menos” y otro 4.8 % manifestó no haberse sentido cómodo. Este resultado demuestra que la interfaz, la navegación y la interacción general con el sistema fueron percibidas como accesibles y amigables para la mayoría de los usuarios, lo cual respalda la efectividad del diseño centrado en la experiencia del usuario implementado en el desarrollo de la solución.




Figura 7.9: Pregunta 9 Fuente: Elaboración propia

En esta pregunta se indagó si el sistema logró satisfacer las expectativas generales de los usuarios. El 66.7 % indicó que se cumplieron totalmente, mientras que el 33.3 % manifestó que se cumplieron bastante. No se registraron respuestas negativas. Esto evidencia que la propuesta tecnológica no solo cumplió con los objetivos funcionales planteados, sino que también generó

un alto grado de aceptación y satisfacción en los usuarios, consolidando así que se utilizó un método eficaz para generar recomendaciones personalizadas en el contexto de compra de computadoras portátiles.

Pregunta 10:

¿Qué mejorarías del sistema? (Opcional)

Opciones de respuesta obtenidas:

- muy buen proyecto
- Sería espléndido poder contar con una adaptación para dispositivos móviles, le daría mucha más visibilidad, practicidad y atractivo para las personas.
- Siento que es fácil de usar, intuitivo y bonito a la vista, ¡para mi está muy bien!
- Que pueda decir a cuantos FPS las pc corren ciertos juegos específicos debido a que muchas personas no dimensionan la potencia o rendimiento de la pc, sino que se quedan con valores numéricos en hz los cuales no significa que entre más alto sea, va a ser mejor que otro.
- Me fue mas o menos cómodo, ya que hubiera sido más fácil desde mi celular
- Excelente programa y con muy buena accesibilidad para una búsqueda de equipo y optimización de tiempo.
- Que se pueda utilizar en el celular
- no se le puede mejorar más lo tiene todo
- Se podrían hacer un poco más de preguntas, para que se procese aún mejor la información, pero en mi opinión el sistema cumple con lo necesario
- todo bien
- próximamente adecuarlo para teléfonos
- Debería de servir para celulares también

Esta pregunta abierta sirvió para recoger sugerencias directas de los usuarios sobre que mejora futura podría obtener el sistema de recomendación. Al revisar las respuestas anteriores se puede llevar a las siguientes conclusiones:

Desarrollo web responsive, pensado para funcionar correctamente en celulares y otros dispositivos móviles: Muchos usuarios mencionaron que les gustaría poder usar el sistema desde el celular sin problemas. Comentarios como “que se pueda usar en el celular”, “adecuarlo para teléfonos” o “hubiera sido más fácil desde mi celular” muestran claramente que hay interés en una versión móvil o, al menos, en un diseño responsive que se vea bien en cualquier pantalla. Esto indica que mejorar la accesibilidad desde distintos dispositivos podría hacer que la

experiencia sea aún mejor.

Detalles técnicos y mejoras en la funcionalidad: Algunos usuarios propusieron incluir información más precisa sobre el rendimiento de los equipos recomendados, por ejemplo, cuántos FPS dan en juegos específicos. También hubo quienes sugirieron agregar más preguntas para afinar aún más las recomendaciones. Cabe aclarar que, posiblemente, lo que hace falta es una mejor guía sobre el tipo de información que el chatbot puede ofrecer. En realidad, el chatbot tiene la capacidad de darte detalles adicionales sobre cualquier recomendación, como los FPS en juegos específicos u otros temas de interés, siempre que el usuario sepa cómo preguntarlo.

Reconocimiento del sistema: Por otro lado, varios comentarios destacaron que el sistema les pareció fácil de usar, bien diseñado y útil en general. Frases como “muy buen proyecto”, “todo bien” y “no se le puede mejorar, lo tiene todo” muestran que hubo una valoración positiva y que la propuesta está bien encaminada.

En resumen, las sugerencias apuntan principalmente a hacer el prototipo responsable y a afinar las recomendaciones, pero también dejan en claro que el sistema ya cuenta con varios puntos fuertes en cuanto a funcionalidad, usabilidad y utilidad práctica.

A pesar de los desafíos, considero que este proyecto fue una experiencia gratificante y significativa, ya que aborda un problema común entre los consumidores de este mercado. Me permitió explorar nuevas áreas y desarrollar habilidades que antes no había trabajado, y me siento motivado a seguir mejorando y puliendo la aplicación en el futuro.

7.2. Comparación con «Ayúdame a elegir una PC» de Microsoft

1. Personalización vs. filtros estáticos

- **Microsoft** La herramienta permite seleccionar hasta dos usos principales (como trabajo, entretenimiento, juegos, creación, familia) y luego filtrar productos técnicos (marca, características, precio).
- **Odyssey** Genera preguntas adaptativas a partir de las respuestas del usuario, utilizando un modelo de IA que permite interacciones dinámicas y personalizadas, incluso con usuarios sin conocimientos técnicos.

2. Interactividad y experiencia conversacional

- **Microsoft** Se basa en formularios estáticos con opciones predefinidas, sin capacidad para diálogo o ajuste progresivo de preguntas.
- **Odyssey** Integra un chatbot basado en IA (Gemini 2.5 Flash), que adapta sus preguntas y permite al usuario interactuar de forma fluida, solicitar comparaciones,

resolver dudas y hacer preguntas técnicas explicadas de forma sencilla.

3. Enfoque en necesidades reales del usuario

- **Microsoft** Orienta la elección mediante categorías generales (como "multitarea", "creación", "juegos").
- **Odyssey** Indaga sobre factores como presupuesto, tipo de uso específico (estudio, diseño gráfico, videojuegos), y adapta la recomendación a estos criterios mediante reglas de asociación e IA, logrando una personalización.

Además de todo lo anterior, Odyssey va mucho más allá de simplemente recomendar un tipo de computador. Mi sistema no solo sugiere qué equipo elegir, sino que también te proporciona el enlace directo para comprarlo, lo cual representa una ventaja significativa. En cambio, la herramienta de Microsoft únicamente indica las características que "deberías buscar", sin ofrecer opciones concretas ni accesos directos a productos reales. Esto puede resultar limitado para el público objetivo, especialmente para personas sin conocimientos técnicos, ya que no necesitan solo una guía general, sino una recomendación clara, personalizada y con posibilidad de compra inmediata, y eso es precisamente lo que ofrece Odyssey.

The image shows a screenshot of a Microsoft Windows interface for PC recommendations. At the top, it says "Microsoft | Windows". Below that, the main heading is "¿Para qué usarás tu PC principalmente?" (For what will you use your PC mainly?). Underneath, it says "Sabemos que haces muchas cosas en tu PC, pero elige hasta dos actividades principales." (We know you do many things on your PC, but choose up to two main activities). There are six categories, each with a checkbox and a description:

- ☐ **Solo lo básico**
Quiero usar mi PC para tareas cotidianas, como navegar por Internet y comprar el como electrónico.
- ☐ **Entretimiento**
Quiero almacenar y hacer streaming de mi música y películas favoritas en mi PC.
- ☐ **Juegos**
Necesito una PC lo suficientemente potente como para admitir mis hábitos de videojuegos, gráficos sofisticados y multitarea.
- ☐ **Trabajo o escuela**
Usaré esta PC para el trabajo o escuela, por lo que debo poder hacer videollamadas confiables y facilitar el uso compartido de documentos.
- ☐ **Creación**
Quiero hacer que mis creaciones cobren vida en mi PC, por lo que necesito una pantalla de gran tamaño, manetas flexibles para trabajar y almacenamiento.
- ☐ **Familia**
Mi familia usará esta PC, por lo que debo poder administrar varios usuarios que juegan, navegan y hacen streaming.

At the bottom, there is a "Progreso" (Progress) bar and a "Siguiente" (Next) button.

Figura 7.10: Herramienta de recomendación Microsoft. Fuente: Microsoft



Figura 7.11: Herramienta de recomendación Microsoft. Fuente: Microsoft

7.3. Comparación con el Recomendador de Computadores de “Alkosto”

1. Tipo de recomendación

- **Alkosto** El sistema ofrece una selección guiada por filtros básicos, como el tipo de uso (hogar, oficina, estudiante, gamer), pero no hay interacción real. Es un flujo estático que simplemente muestra productos asociados a la categoría elegida.
- **Odyssey** En cambio, mi sistema va más allá al usar inteligencia artificial para hacer preguntas adaptativas. Eso permite conocer mejor al usuario y ofrecerle una recomendación mucho más específica según sus respuestas.

2. Interactividad y experiencia conversacional

- **Alkosto** No permite interacción más allá de los clics en filtros. No hay ningún tipo de personalización más allá de seleccionar una categoría y ver productos.
- **Odyssey** Usa un chatbot con IA (Gemini 2.5 Flash) que conversa con el usuario, se adapta a lo que responde y puede profundizar en sus necesidades reales. Además, puede responder dudas, comparar equipos y explicar por qué una opción es mejor que otra, todo en lenguaje sencillo.

3. Nivel de personalización

- **Alkosto** Las sugerencias se hacen en base a filtros generales. No tiene en cuenta el presupuesto ni el contexto del usuario, por lo que muchas veces muestra demasiadas opciones sin justificación clara.
- **Odyssey** Mi sistema considera el presupuesto, el tipo de uso, las preferencias personales y hasta el nivel de conocimiento técnico del usuario. Gracias a eso, entrega recomendaciones muy precisas, incluso para personas que no saben nada de computadores.

4. Resultado final de la recomendación

- **Alkosto** El resultado es solo un listado general de productos, sin explicar por qué esos modelos son adecuados.
- **Odyssey** Además de recomendar equipos que realmente se ajustan al usuario, también le doy el enlace directo para comprarlos. Así no tiene que seguir buscando ni comparando por su cuenta. Y si tiene preguntas, el sistema puede responderlas de inmediato a través del chatbot.

En resumen, Odyssey no se limita a mostrar computadores por categoría: acompaña al usuario durante todo el proceso de elección.

Mi sistema entiende mejor lo que necesita cada persona, le da opciones reales, enlaces directos de compra y respuestas claras a sus dudas. A diferencia de Alkosto, que se queda en una guía básica con filtros, Odyssey asesora de verdad, incluso si el usuario no tiene conocimientos técnicos. Esa es la diferencia principal y lo que lo hace realmente útil.

¿Cómo elegir el mejor computador?



Figura 7.12: Herramienta de recomendación MicrosAlkostooft. Fuente: Alkosto

Te recomendamos según tus necesidades:

Product image of Computador Portátil Asus Zenbook Oled 14" Pulgadas Ux3402za - Intel Core i5 - RAM 8GB - Disco SSD 512 GB - Azul

Computador Portátil Asus Zenbook Oled 14" Pulgadas Ux3402za - Intel Core i5 - RAM 8GB - Disco SSD 512 GB - Azul

\$ 3.349.000

[Ir al producto](#)

- ✓ Marca: ASUS
- ✓ Memoria RAM: 8 GB
- ✓ Pantalla: 14,00 pulgadas
- ✓ Disco duro: 512GB



Computador Portátil Asus Vivobook 16" Pulgadas K3605zf - Intel Core i7 - RAM 16gb - Disco SSD 512 GB SSD - Negro

\$ 3.999.000

[Ir al producto](#)

- ✓ Marca: ASUS

Figura 7.13: Herramienta de recomendación Alkosto.Fuente: Alkosto

Capítulo 8

Conclusiones del Proyecto

El desarrollo del sistema de recomendación Odyssey permitió comprobar que la combinación de filtrado basado en reglas de asociación e inteligencia artificial (IA) mediante la API Gemini de Google puede generar una herramienta funcional y eficiente. Este enfoque híbrido logró cumplir el objetivo del proyecto el cual era ayudar a personas sin conocimientos técnicos en la elección de un computador portátil acorde a sus necesidades, presupuesto y gusto.

La decisión de implementar un modelo basado en reglas de asociación resultó acertada, ya que este enfoque permite establecer relaciones lógicas del tipo “si A, entonces B”, sin necesidad de contar con una base de usuarios históricos. Este tipo de filtrado es particularmente útil cuando se parte de datos estructurados sobre productos como marcas, especificaciones, precios o categorías de uso y de preferencias expresadas por los usuarios a través de preguntas no técnicas.

Una de las principales fortalezas de Odyssey fue su capacidad para interactuar con usuarios no expertos mediante preguntas simples, generadas de forma dinámica por una IA. Esta estrategia redujo la barrera técnica, evitando que los usuarios se vieran obligados a saber sobre componentes técnicos como los núcleos de un procesador, cantidad de RAM y la relación entre los mismos. En su lugar, el sistema guiara la conversación desde preguntas generales como el uso deseado del equipo o el rango de presupuesto. Puede que en alguna ocasión el sistema genere alguna pregunta un poco puntual o técnica, pero si el usuario no sabe que responder, puede escoger una opción que siempre está presente la cual es “no tengo preferencia” y esta no afectara las recomendaciones finales.

La integración con la API de Gemini de Google fue un elemento diferenciador clave. Esta inteligencia artificial generó las preguntas del sistema, interpretó las respuestas y facilitó un proceso de recomendación conversacional adaptado al usuario. Además, permitió introducir un componente de lenguaje natural en el chatbot, ofreciendo al usuario una experiencia fluida, cercana y comprensible, muy superior a un formulario estático o a un algoritmo rígido y

silencioso.

El chatbot implementado no solo presentó las recomendaciones finales, sino que también sirvió como asistente digital, resolviendo dudas adicionales y proporcionando comparaciones entre las opciones sugeridas. Esta funcionalidad fue bien valorada por los usuarios, especialmente porque permite profundizar en temas específicos como el rendimiento en videojuegos (FPS), duración de la batería, calidad de la pantalla, entre otros.

Las pruebas de usabilidad, aplicadas a 21 usuarios con niveles técnicos variados, arrojaron resultados ampliamente positivos. La mayoría de los participantes calificó el sistema como fácil o muy fácil de usar, y consideraron que la experiencia fue clara, rápida y útil. Este resultado valida que tanto el diseño de la interfaz como el flujo de navegación y la presentación de resultados cumplieron con los principios fundamentales de usabilidad y experiencia del usuario.

Otro hallazgo importante fue la coherencia entre las recomendaciones generadas y las expectativas presupuestales de los usuarios. Más del 90 % expresó que el sistema ofreció opciones dentro de su rango de precio, lo cual demuestra la efectividad del filtrado por asociación al priorizar criterios económicos como primera variable segmentadora. Esta lógica fue acertada, ya que el presupuesto es uno de los factores más restrictivos y relevantes al momento de realizar una compra tecnológica. Además, al utilizar el presupuesto como criterio inicial en el proceso de recomendación, se logra una segmentación efectiva de la información enviada a la inteligencia artificial encargada de generar las sugerencias finales. Este filtro temprano permite descartar una gran cantidad de equipos que no se ajustan al rango económico del usuario, lo cual no solo optimiza la precisión de las recomendaciones, sino que también mejora la eficiencia del sistema. Al reducir la cantidad de opciones que deben ser procesadas por la API, se minimiza el riesgo de exceder los límites de tokens o solicitudes establecidos por el servicio, garantizando un análisis más ágil y sostenible dentro de las restricciones técnicas de la plataforma.

Además, se evidenció que el sistema tiene un alto nivel de flexibilidad y adaptabilidad, ya que la arquitectura web y el modelo de recomendación son fácilmente escalables. Se podrían agregar más variables al modelo, ampliar el dataset de portátiles o incluso adaptar la lógica de recomendación a otros mercados (como celulares, tablets o incluso electrodomésticos), con mínimas modificaciones en la estructura general del sistema.

Pese a los resultados positivos, también se identificaron aspectos por mejorar. Uno de los comentarios más frecuentes fue la necesidad de una versión responsable del sistema. Varios usuarios expresaron que les hubiera resultado más cómodo utilizar la aplicación desde sus celulares. Este es un punto clave para próximas iteraciones, especialmente considerando que gran parte de la navegación actual se realiza desde dispositivos móviles.

También se detectó que el sistema podría beneficiarse de una mejor guía o introducción sobre

las capacidades del chatbot. Aunque la IA puede responder preguntas complejas, no todos los usuarios sabían qué tipo de información podían solicitar. Incluir una sección de ayuda, ejemplos de preguntas o sugerencias de comandos podría potenciar aún más la utilidad del componente conversacional.

En términos académicos y técnicos, este trabajo demuestra que es posible construir sistemas de recomendación eficientes con herramientas de código abierto y servicios de IA disponibles públicamente. La elección de tecnologías modernas como React, Supabase y la API de Gemini permite no solo reducir los tiempos de desarrollo, sino también garantizar escalabilidad, mantenibilidad y facilidad de integración con otros servicios futuros.

En definitiva, Odyssey representa una solución práctica, realista y útil para un problema cotidiano que enfrentan muchos consumidores. Su enfoque centrado en el usuario, su capacidad de personalización y su interacción conversacional marcan un camino innovador en el desarrollo de sistemas de recomendación accesibles. Este proyecto sienta las bases para futuras mejoras y aplicaciones más amplias en el ámbito de la asistencia inteligente en decisiones de compra tecnológicas.

8.1. Trabajos Futuros

Durante el desarrollo del sistema de recomendación, se identificaron varias áreas de mejora que no fueron abordadas en su totalidad por salirse del alcance planteado. A continuación, se presentan mejoras futuras:

- **Desarrollo de una aplicación móvil nativa o versión web responsive:** Se sugiere el diseño e implementación de una aplicación móvil (Android/iOS) o una versión web adaptable a dispositivos móviles. Esto permitiría una experiencia más accesible y fluida para los usuarios, quienes en su mayoría navegan desde teléfonos inteligentes, mejorando significativamente la portabilidad y el alcance del sistema.
- **Expansión del sistema a otras categorías tecnológicas:** Se propone ampliar el sistema de recomendación a otros productos tecnológicos, como teléfonos móviles, tablets, periféricos o incluso electrodomésticos. Esto aprovecharía la arquitectura escalable de la plataforma y permitiría reutilizar gran parte del modelo actual con ajustes mínimos en los datos y reglas de asociación.
- **Inclusión de un modelo de personalidad:** Investigar y desarrollar un modelo de personalidad que permita personalizar aún más las recomendaciones en función de los rasgos y preferencias psicológicas individuales de los usuarios, lo que aumentaría la relevancia y la satisfacción del usuario.
- **Integración de un sistema de retroalimentación activa:** Incorporar un mecanismo mediante el cual los usuarios puedan calificar la calidad de las recomendaciones y brindar

comentarios directos. Esta información serviría para reentrenar o refinar las reglas de asociación, mejorando así la precisión y personalización del sistema a lo largo del tiempo.

- Implementación de técnicas híbridas de recomendación: Se recomienda explorar la combinación del filtrado por reglas de asociación con técnicas de aprendizaje automático supervisado (como redes neuronales o árboles de decisión) para ofrecer recomendaciones más sofisticadas. Un sistema híbrido podría adaptar las recomendaciones en tiempo real con base en patrones de comportamiento y preferencias aprendidas.
- Enriquecimiento del análisis del rendimiento de los equipos recomendados: Se sugiere incorporar datos técnicos complementarios como benchmarks, resultados de rendimiento (por ejemplo, FPS en videojuegos específicos) o análisis de batería, con el fin de ofrecer al usuario información más tangible y comprensible al tomar decisiones.
- Optimización de la interacción conversacional del chatbot: Mejorar la interfaz del chatbot mediante el uso de modelos más avanzados de lenguaje natural, así como proporcionar una guía visual o menú de ayuda con ejemplos de preguntas frecuentes. Esto reduciría la curva de aprendizaje y facilitaría el acceso a funcionalidades más profundas del sistema.

Bibliografía

- [1] N. M. ARÉVALO, ““de cada 10 ventas, siete son portátiles, por lo que vemos crecimiento en la categoría”,” <https://www.larepublica.co/empresas/de-cada-10-ventas-siete-son-portatiles-por-lo-que-vemos-crecimiento-en-la-categoria-3212623>, [Internet; Consultado 06/02/2024].
- [2] J. LORDUY, “Mercado de portátiles llegó a más de 940.000 unidades, tras un alza de 20
- [3] EducaLAB, “Sistema basado en filtrado colaborativo,” https://descargas.intef.es/recursos_educativos/ODES_SGOA/Bachillerato/TeI/7B6_SA_Recomendacion_a_tu_servicio/sistema_basado_en_filtrado_colaborativo.html#:~:text=Un%20filtrado%20colaborativo%20es%20el,%2C%20fuentes%20de%20datos%2C%20etc., [Internet; Consultado 24/10/2023].
- [4] Y. Fernández, “Google bard: qué es, cómo funciona y qué puedes hacer con la inteligencia artificial que competirá con chatgpt,” <https://www.xataka.com/basics/google-bard-que-como-funciona-que-puedes-hacer-inteligencia-artificial-buscador>, [Internet; Consultado 24/10/2023].
- [5] Amazon, “Amazon personalize — ¿qué es amazon personalize?” https://aws.amazon.com/es/pm/personalize/?trk=c67bb694-2b14-45c7-916c-c22903bd53f0&sc_channel=ps&ef_id=CjwKCAiAmsurBhBvEiwA6e-WPOMWCib8iz1n3iKgmuJqvYhhSzzxashFkm4L7-42ebwwAsEI-TGkBwE:G:s&s_kwid=AL!4422!3!652868436238!p!!g!!amazon%20personalize!19910624386!149219123922&gclid=CjwKCAiAmsurBhBvEiwA6e-WPOMWCib8iz1n3iKgmuJqvYhhSzzxashFkm4L7-42ebwwAsEI-TGkBwE, [Internet; Consultado 23/10/2023].
- [6] A. B. Vialás, “Desarrollo de un recomendador de videojuegos,” https://e-archivo.uc3m.es/bitstream/handle/10016/29297/TFG_Alejandro_Bermejo_Vialas.2018.pdf?sequence=1&isAllowed=y, [Internet; Consultado 04/11/2023].
- [7] H. J. Ibáñez, “Desarrollo de un chatbot para la recomendación de eventos o lugares de interés,” <https://riunet.upv.es/bitstream/handle/10251/133836/Jover%20-%20Desarrollo%20de%20un%20chatbot%20para%20la%20recomendacin%20de%20eventos%20o%20lugares%20de%20inters.pdf?sequence=1>, [Internet; Consultado 04/11/2023].

- [8] S. C. Ramírez, “Prototipo de un sistema de recomendación de libros para la biblioteca mario carvajal,” <https://bibliotecadigital.univalle.edu.co/server/api/core/bitstreams/5bf3049a-c58b-447f-b830-a5cc279fb12c/content>, [Internet; Consultado 04/11/2023].
- [9] E. B.V., “A flexible electronic commerce recommendation system,” <https://www.larepublica.co/empresas/de-cada-10-ventas-siete-son-portatiles-por-lo-que-vemos-crecimiento-en-la-categoria-3212623>, [Internet; Consultado 06/02/2024].
- [10] —, “A flexible electronic commerce recommendation system,” <https://www.larepublica.co/empresas/de-cada-10-ventas-siete-son-portatiles-por-lo-que-vemos-crecimiento-en-la-categoria-3212623>, [Internet; Consultado 06/02/2024].
- [11] E. Ltd., “I know what you need to buy”: context-aware multimedia-based recommendation system,” <https://www.sciencedirect.com/science/article/abs/pii/S0957417403000630>, [Internet; Consultado 06/02/2024].
- [12] S. Kanetkar, A. Nayak, S. Swamy, and G. Bhatia, “Web-based personalized hybrid book recommendation system,” *International Conference On Advances In Engineering Technology Research*, 2014.
- [13] “Datamining (minería de datos).” [Online]. Available: https://www.sinnexus.com/business_intelligence/datamining.aspx
- [14] “sistemas de recomendación — qué son, tipos y ejemplos.” [Online]. Available: https://www.grapheverywhere.com/sistemas-de-recomendacion-que-son-tipos-y-ejemplos/?utm_source=chatgpt.com
- [15] O. E. González and S. M. Jacques, “Estado del arte en los sistemas de recomendación state of the art of recommendation systems,” *Research in Computing Science*, vol. 135, 2017.
- [16] Wikipedia., “Filtro basado en reglas de asociación,” https://es.wikipedia.org/wiki/Reglas_de_asociaci%C3%B3n, [Internet; Consultado 19/06/2025].
- [17] P. J. Murel, “¿qué es el filtrado basado en contenido?” <https://www.ibm.com/es-es/think/topics/content-based-filtering>, [Internet; Consultado 19/06/2025].
- [18] V. Kurama, “What is collaborative filtering: A simple introduction,” <https://builtin.com/data-science/collaborative-filtering-recommender-system>, [Internet; Consultado 19/06/2025].
- [19] Wikipedia., “Mercadolibre,” https://es.wikipedia.org/wiki/Mercado_Libre, [Internet; Consultado 19/06/2025].
- [20] —, “Grupo exito,” https://es.wikipedia.org/wiki/Grupo_%C3%89xito, [Internet; Consultado 19/06/2025].
- [21] —, “Alkosto,” <https://es.wikipedia.org/wiki/Alkosto>, [Internet; Consultado 19/06/2025].

- [22] Anonymous, “What is web scraping?” <https://www.zyte.com/learn/what-is-web-scraping/>, [Internet; Consultado 19/06/2025].
- [23] UNIR, “¿qué es node.js y qué ventajas ofrece?” <https://builtin.com/data-science/collaborative-filtering-recommender-system>, [Internet; Consultado 19/06/2025].
- [24] D. A., “Qué es react: definición, características y funcionamiento,” <https://www.hostinger.com/co/tutoriales/que-es-react>, [Internet; Consultado 19/06/2025].
- [25] aplyca, “Supabase: una alternativa ágil de código abierto, howpublished = <https://www.aplyca.com/blog/blog-supabase-una-alternativa-agil-de-codigo-abierto>, note = ”[internet; consultado 19/06/2025]”.”
- [26] V. Kurama, “Qué es typescript, howpublished = <https://codigofacilito.com/articulos/typescript>, note = ”[internet; consultado 19/06/2025]”.”
- [27] U. Hernández, “Cómo usar vercel ai sdk: Guía para principiantes,” <https://apidog.com/es/blog/vercel-ai-sdk/>, [Internet; Consultado 19/06/2025].
- [28] A. W. Service, “¿qué es python?” <https://aws.amazon.com/es/what-is/python/#:~:text=Python%20es%20un%20lenguaje%20de,ejecutar%20en%20muchas%20plataformas%20diferentes.>, [Internet; Consultado 19/06/2025].
- [29] browserstack, “How to use python webdriver manager for selenium testing?” <https://www.browserstack.com/guide/python-selenium-webdriver-manager>, [Internet; Consultado 19/06/2025].
- [30] D. Google, “¿qué es chromedriver?” <https://developer.chrome.com/docs/chromedriver?hl=es-419>, [Internet; Consultado 19/06/2025].
- [31] C. Google, “Gemini 2.0 flash-lite,” <https://cloud.google.com/vertex-ai/generative-ai/docs/models/gemini/2-0-flash-lite?hl=es-419#:~:text=Gemini%202.0%20Flash%20DLite%20es,precio%20y%20la%20misma%20velocidad>, [Internet; Consultado 19/06/2025].

Anexos

Esta sección incluye los enlaces a los repositorios que documentan la codificación empleada en la creación del prototipo web. Se solicita amablemente que, al momento de realizar la prueba del prototipo, el evaluador se comunique previamente conmigo por correo electrónico. Esto con el fin de realizar la activación de la base de datos y habilitar nuevamente el despliegue de la aplicación.

Repositorio del prototipo web: : <https://github.com/Adrian-Martinez28/Odyssey.git>

Prototipo web: odyssey-production-8859.up.railway.app

Repositorio del webScraping: <https://github.com/Adrian-Martinez28/WebScraping.git>