

UNIVERSIDAD CATÓLICA SEDES SAPIENTIAE
FACULTAD DE INGENIERÍA



Un sistema de recomendación basado en el algoritmo KNN para la línea
de ropa sport, Empresa Avalanch

TESIS PARA OPTAR EL TÍTULO PROFESIONAL DE
INGENIERO DE SISTEMAS

AUTOR

Jhon David Altamirano Altamirano

ASESOR

Joel Benigno Lopez Del Mar

Rioja, Perú

2025

METADATOS COMPLEMENTARIOS

Datos del autor

Nombres	Jhon David
Apellidos	Altamirano Altamirano
Tipo de documento de identidad	DNI
Número del documento de identidad	76036892
Número de Orcid (opcional)	

Datos del asesor

Nombres	Joel Benigno
Apellidos	Lopez Del Mar
Tipo de documento de identidad	DNI
Número del documento de identidad	08584920
Número de Orcid (obligatorio)	https://orcid.org/0000-0002-4302-7559

Datos del Jurado

Datos del presidente del jurado

Nombres	Marco Antonio
Apellidos	Coral Ygnacio
Tipo de documento de identidad	DNI
Número del documento de identidad	09983907

Datos del segundo miembro

Nombres	Walter Pedro
Apellidos	Contreras Flores
Tipo de documento de identidad	DNI
Número del documento de identidad	07743259

Datos del tercer miembro

Nombres	Daniel
Apellidos	Villafuerte Mathews
Tipo de documento de identidad	DNI
Número del documento de identidad	06993892

Datos de la obra

Materia*	Avalanch, Distancia euclidiana, Sistema de recomendación, Prendas de Vestir Sport, K-Nearest Neighbors
Campo del conocimiento OCDE Consultar el listado: enlace	https://purl.org/pe-repo/ocde/ford#2.02.04
Idioma (Normal ISO 639-3)	SPA - español
Tipo de trabajo de investigación	Tesis
País de publicación	PE - PERÚ
Recurso del cual forma parte (opcional)	
Nombre del grado	Ingeniero de Sistemas <input type="text"/>
Grado académico o título profesional	Título Profesional <input type="text"/>
Nombre del programa	Ingeniería de Sistemas <input type="text"/>
Código del programa Consultar el listado: enlace	612076

*Ingresar las palabras clave o términos del lenguaje natural (no controladas por un vocabulario o tesoro).



FACULTAD DE INGENIERÍA
ACTA N° 014-2025-UCSS-FI/TPISIS
SUSTENTACION DE TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE
INGENIERO DE SISTEMAS
FILIAL RIOJA: NUEVA CAJAMARCA

Rioja, 20 de noviembre de 2025

Siendo las 10:30 horas del 20 de noviembre de 2025, el jurado evaluador se reunió de manera presencial en la Biblioteca de la Filial Rioja: Nueva Cajamarca de la Universidad Católica Sedes Sapientiae para llevar a cabo la sustentación de la tesis titulada:

**Un sistema de recomendación basado en el
algoritmo KNN para la línea de ropa sport, empresa Avalanch**

Por el Bachiller en Ciencias con mención en Ingeniería de Sistemas:

ALTAMIRANO ALTAMIRANO, JHON DAVID

Ante el Jurado calificador conformado por el:

MSc. CORAL YGNACIO, Marco Antonio	Presidente
Lic. CONTRERAS FLORES, Walter Pedro	Secretario
Mg. VILLAFUERTE MATHEWS, Daniel	Miembro

Siendo las 11:35 horas, habiendo sustentado y atendido las preguntas realizadas por cada uno de los miembros del jurado; y luego de la respectiva deliberación, el jurado le otorgó la calificación de:

APROBADO

En mérito a la calificación obtenida se expide la presente acta con la finalidad que el Consejo de Facultad considere se le otorgue al Bachiller ALTAMIRANO ALTAMIRANO, JHON DAVID el Título Profesional de:

INGENIERO DE SISTEMAS

En señal de conformidad firmamos,

.....
Mg. VILLAFUERTE MATHEWS, Daniel
Miembro

.....
Lic. CONTRERAS FLORES, Walter Pedro
Secretario

.....
MSc. CORAL YGNACIO, Marco Antonio
Presidente

Anexo 2

CARTA DE CONFORMIDAD DEL ASESOR DE TESIS CON EL INFORME DE EVALUACIÓN DEL SOFTWARE ANTIPLAGIO

Rioja, 19 de noviembre de 2025

Señora,

DAYMA SADAMI CARMENATES HERNANDEZ
Jefe del Departamento de Investigación
Facultad Ingeniería - UCSS

Reciba un cordial saludo.

Sirva el presente para informar que la tesis, bajo mi asesoría, con título “Un sistema de recomendación basado en el algoritmo KNN para la línea de ropa sport, empresa Avalanch”, presentado por el Bachiller ALTAMIRANO ALTAMIRANO, JHON DAVID (código de estudiante: 2017100761 y DNI 76036892) para optar el título profesional de Ingeniero de Sistemas ha sido revisado en su totalidad por mi persona y **CONSIDERO** que el mismo se encuentra **APTO** para ser sustentado ante el Jurado Evaluador.

Asimismo, para garantizar la originalidad del documento en mención, se le ha sometido a los mecanismos de control y procedimientos antiplagio previstos en la normativa interna de la Universidad, **cuyo resultado alcanzó un porcentaje de similitud de 14 %**.

Por tanto, en mi condición de asesor, firmo la presente carta en señal de conformidad y adjunto el informe de similitud del Sistema Antiplagio Turnitin, como evidencia de lo informado.

Sin otro particular, me despido de usted. Atentamente,



LOPEZ DEL MAR, JOEL BENIGNO

DNI N°: 08584920

ORCID: <https://orcid.org/0000-0002-4302-7559>

Facultad de Ingeniería - UCSS

* De conformidad con el artículo 8°, del Capítulo 3 del Reglamento de Control Antiplagio e Integridad Académica para trabajos para optar grados y títulos, aplicación del software antiplagio en la UCSS, se establece lo siguiente:

Artículo 8°. Criterios de evaluación de originalidad de los trabajos y aplicación de filtros

El porcentaje de similitud aceptado en el informe del software antiplagio para trabajos para optar grados académicos y títulos profesionales, será máximo de veinte por ciento (20%) de su contenido, siempre y cuando no implique copia o indicio de copia.

DEDICATORIA

Dedico esta tesis en primer lugar a Dios y también a todas las personas que han sido fundamentales en mi camino académico y personal. A mi madre quien es mi fortaleza en mi camino, a mi Padre por el apoyo que siempre me brinda. Asimismo, extendo mi gratitud a todas aquellas personas que de manera directa o indirecta contribuyeron el desarrollo de este trabajo.

Finalmente quiero dedicar esta labor a mi asesor el Magister López Del Mar Joel quien con su conocimiento y guía fueron clave para la realización de esta tesis.

AGRADECIMIENTO

A Dios por haberme dado la fortaleza, salud, a mis padres por brindarme su ayuda en todo momento, al magister López Del Mar Joel quien gracias a las asesorías brindadas me permitió culminar el proyecto de tesis.

A la empresa Avalanch por brindarme la información y acceso para que esta investigación logre su finalidad, a todos ellos mi sincero agradecimiento.

RESUMEN

En el presente trabajo de investigación se ha implementado un sistema de recomendación de prendas de vestir de línea Sport para hombres el cual brinda recomendaciones a los usuarios que estén registrados de acuerdo a sus preferencias, dicha implementación se realizó con el algoritmo K-vecinos más cercanos (K-Nearest Neighbors), el cual permite realizar la clasificación de muestras entrantes como también realizar predicción es por ello que para esta implementación se utilizó el mencionado algoritmo, junto a ello se utilizó el cálculo de la distancia euclidiana, como resultado se obtuvo que todos los usuarios recibieron una recomendación personalizada y de acuerdo a sus preferencias por lo que se concluye que el sistema de recomendación ha optimizado el proceso de recomendación que realizan los trabajadores en la empresa Avalanch generándole rentabilidad.

El algoritmo KNN es utilizado en muchos sistemas de recomendación, ya que permite encontrar el vecino más cercano con variables que se hayan identificado de tal manera poder realizar la predicción o recomendación, los resultados que muestra son positivos y permiten el desarrollo de las entidades porque los clientes o usuarios se sienten satisfechos con las recomendaciones que el sistema les brinda.

Palabras clave: Avalanch, Distancia euclidiana, Sistema de recomendación, Prendas de Vestir Sport, K-Nearest Neighbors.

ABSTRACT

In this research, a recommendation system for men's sportswear was implemented. This system provides recommendations to registered users based on their preferences. This implementation was carried out using the K-Nearest Neighbors algorithm, which allows for the classification of incoming samples and predictions. Therefore, for this implementation, the aforementioned algorithm was used. In addition, the Euclidean distance calculation was also used. As a result, all users received a personalized recommendation based on their preferences. It is concluded that the recommendation system has optimized the recommendation process carried out by employees at Avalanch, generating profitability for the company.

The KNN algorithm is used in many recommendation systems because it allows the nearest neighbor to be found with identified variables in order to make the prediction or recommendation. The results are positive and allow for the development of the entities because customers or users are satisfied with the recommendations provided by the system.

Keywords: Avalanch, Euclidean Distance, Recommendation System, Sportswear, K-Nearest Neighbors.

ÍNDICE

Dedicatoria	2
Agradecimiento	3
Resumen	4
Abstract	5
Introducción	14
Capítulo I: Planteamiento metodológico	16
Diagnóstico estratégico	16
Descripción de la empresa	16
Visión y misión	16
Análisis FODA	17
Organización de la empresa	17
Planteamiento del problema	19
Formulación del problema	20
Objetivos	21
Objetivo general	21
Objetivo específico	21
Justificación e importancia del proyecto	21
Justificación: Necesidad e importancia	21
Análisis de viabilidad de la investigación	22
Límites y alcances	27
Límites	27
Alcances	27
Propuesta	27

	7
Organización del informe	28
Capítulo II: Marco teórico	29
Antecedentes de la investigación	29
Antecedentes internacionales	29
Antecedentes nacionales	32
Bases teóricas	36
Evolución	36
Conceptos Básicos	40
Clasificación de los sistemas de recomendación	45
Formas de implementación de un sistema de recomendación	47
Tecnologías asociadas	51
Aspectos legales de ropa sport	53
Definición de términos básicos	54
Capitulo III: Diseño de la solución	56
Módulo de recomendación	58
Funcionalidades clave del sistema	62
Diseño de la base de datos	63
Requerimientos técnicos	63
Capítulo IV: Construcción de la solución	65
Especificación del caso de estudio	65
Adecuación del problema	66
Especificación de la solución	69

Ejecución de la solución	77
Capítulo V: Implementación	93
Modelado de negocios	93
Requisitos del sistema	93
Matriz de requisitos vs. Cus	94
Diagrama de casos de uso básicos	95
Especificaciones de caso de uso	95
Diagrama de actividades	101
Modelo de análisis	105
Diagrama de clases de análisis	105
Diagrama de secuencia	108
Prototipos	110
Modelo de datos	115
Modelo físico	115
Alcance del prototipo del sistema de información a desarrollar	116
Implementación	116
Pruebas	117
Capítulo VI: Aspectos económicos financieros	121
Presupuesto y financiamiento de inversiones y capital de trabajo inicial	121
Presupuesto de ingresos y egresos	122
Análisis de riesgos	123
Determinación de riesgos del proyecto	123

Propuestas para la mitigación de riesgos	123
Presupuesto de mitigación de riesgos	124
Capítulo VII: Análisis Costo-Beneficio	125
Beneficios no financieros	125
Impacto social	125
Beneficio tecnológico	126
Beneficio económico	126
Capítulo VIII. Determinación de la viabilidad del proyecto	129
Capítulo IX Conclusiones y recomendaciones	130
Conclusiones	130
Recomendaciones	131
Referencias	132
Anexos	144

ÍNDICE DE FIGURAS

Figura 1 <i>Organigrama de la Empresa Avalanch</i>	18
Figura 2 <i>Línea de Tiempo de la Evolución de los Sistemas de Recomendación</i>	39
Figura 3 <i>Modelo conceptual de la solución</i>	56
Figura 4 <i>Cuadro arquitectónico</i>	57
Figura 5 <i>Diagrama de casos de uso del sistema básico</i>	95
Figura 6 <i>Diagrama de actividades - Registro de trabajador</i>	101
Figura 7 <i>Diagrama de actividades - Registro de prendas</i>	102
Figura 8 <i>Diagrama de actividades - Registro de clientes</i>	103
Figura 9 <i>Diagrama de actividades - Gestión de recomendaciones</i>	104
Figura 10 <i>Diagrama de clases - Registrar trabajador</i>	105
Figura 11 <i>Diagrama de clases - Registro de ropa</i>	106
Figura 12 <i>Diagrama de clases - Registro de clientes</i>	106
Figura 13 <i>Diagrama de clases - Gestión de recomendación</i>	107
Figura 14 <i>Diagrama de secuencias - Registro de trabajador</i>	108
Figura 15 <i>Diagrama de secuencias - Registro de ropa</i>	109
Figura 16 <i>Diagrama de secuencias - Registro de clientes</i>	109
Figura 17 <i>Diagrama de secuencias - Gestión de recomendación</i>	110
Figura 18 <i>Prototipo de Registrar trabajador</i>	111
Figura 19 <i>Prototipo de Registro de ropa</i>	112
Figura 20 <i>Prototipo de Registrar Cliente</i>	113
Figura 21 <i>Prototipo de Generar Recomendación</i>	114
Figura 22 <i>Modelo Físico</i>	115

Figura 23 <i>Inicio de sesión tienda de ropa AVALANCH</i>	117
Figura 24 <i>Crear cuenta tienda de ropa AVALANCH</i>	117
Figura 25 <i>Cliente - tienda de ropa AVALANCH</i>	118
Figura 26 <i>Carrito - tienda de ropa AVALANCH</i>	118
Figura 27 <i>Carrito - tienda de ropa AVALANCH</i>	119
Figura 28 <i>Lista carrito tienda de ropa AVALANCH</i>	119
Figura 29 <i>Configuración tienda ropa AVALANCH</i>	120

INDICE DE TABLAS

Tabla 1 <i>Análisis FODA</i>	17
Tabla 2 <i>Conceptos básicos de sistemas de recomendación.</i>	41
Tabla 3 <i>Variables de entrada para el sistema de recomendación.</i>	66
Tabla 4 <i>Variables de conocimiento</i>	68
Tabla 5 <i>Conversión de la Tabla 3 (Variables de Entrada)</i>	69
Tabla 6 <i>Conversión de la Tabla 4 (Variables de Conocimiento)</i>	71
Tabla 7 <i>Relación entre las variables de entrada y las variables del conocimiento según su abreviatura</i>	72
Tabla 8 <i>Prendas Registradas</i>	74
Tabla 9 <i>Prendas disponibles datos cuantificados</i>	75
Tabla 10 <i>Base de datos de las prendas con 50 registros</i>	78
Tabla 11 <i>Conversión a valores numéricos</i>	83
Tabla 12 <i>Base de datos convertido a valores numéricos</i>	85
Tabla 13 <i>Especificaciones del usuario</i>	87
Tabla 14 <i>Resultado del cálculo de la distancia euclidiana</i>	89
Tabla 15 <i>Resultados de la distancia euclidiana de las 3 prendas más cercanas para recomendación.</i>	90
Tabla 16 <i>Porcentaje de similitud de las 3 prendas de vestir más cercanas para el cliente.</i>	91
Tabla 17 <i>Requisitos del sistema</i>	93
Tabla 18 <i>Matriz de Requisitos Vs. CUS</i>	94
Tabla 19 <i>Actores del Sistema</i>	95
Tabla 20 <i>Especificación del caso de uso CUS01 – Gestión de registro trabajador.</i>	96
Tabla 21 <i>Especificación del caso de uso CUS02 – Gestión de registro de ropa.</i>	97

Tabla 22	<i>Especificación del caso de uso CUS03 – Gestión de registro de cliente</i>	98
Tabla 23	<i>Especificación del caso de uso CUS03 – Gestión de recomendación</i>	99
Tabla 24	<i>Inversiones y capital de trabajo inicial</i>	121
Tabla 25	<i>Presupuesto de Ingresos y Egresos</i>	122
Tabla 26	<i>Riesgos del proyecto</i>	123
Tabla 27	<i>Propuestas para mitigar los riesgos</i>	123
Tabla 28	<i>Presupuesto de Mitigación de Riesgos</i>	124

INTRODUCCIÓN

En este informe de tesis se presenta el desarrollo de un sistema de recomendación para la empresa Avalanch, el sistema tiene como objetivo optimizar el proceso de compra de los clientes en donde ellos podrán seleccionar prendas de manera personalizada, esto con la ayuda del algoritmo K-Nearest Neighbor (K-NN) que permite identificar patrones y correlaciones en gustos y preferencias del usuario al momento de elegir una prenda. Con los resultados obtenidos, se realizó un análisis minucioso de la efectividad del sistema, dando como resultado un impacto en la experiencia de compra.

La tesis está compuesta por 7 capítulos y sus respectivos anexos que se detallan a continuación:

Capítulo 1: Planteamiento metodológico, en este capítulo se puede apreciar el problema de investigación, los objetivos, la justificación, la importancia, las limitaciones y las restricciones del área investigativa.

Capítulo 2: Aquí se observa los antecedentes de la investigación, bases teóricas, antecedentes tanto nacionales como internacionales y los conceptos de términos clave.

Capítulo 3: Diseño de la solución, se verifica los algoritmos considerados y se realiza una comparación para luego seleccionar el que nos ayude o aporte para la investigación de este proyecto.

Capítulo 4: En este capítulo se construye la solución, la adecuación del problema y se realiza unas especificaciones de la solución de la propuesta.

Capítulo 5: Para este capítulo se realiza la implementación en donde se tiene todo el proceso experimental de la tesis, se incluye la recolección y el análisis de datos sobre los gustos y preferencias de las prendas por parte de los clientes.

Capítulo 6: Aspectos económicos y financieros, en este periodo se trabaja con los costos relacionados para la implementación del sistema de recomendación.

Capítulo 7: Análisis costo-beneficio, en este apartado se realiza la evaluación ente los costos y beneficios del sistema.

Capítulo 8: Este es el último capítulo de la investigación en donde se tiene las conclusiones y recomendaciones como también sugerencias para futuras investigaciones.

CAPÍTULO I: PLANTEAMIENTO METODOLÓGICO

Diagnóstico Estratégico

Descripción de la Empresa

La empresa Avalanch es una empresa que está dedicada al rubro de venta de ropa, cuenta con tres sucursales, Nueva Cajamarca, Rioja y la ciudad de Moyobamba; la tienda central está ubicada en la ciudad de Lima, como mercado consumidor tiene a todo tipo de clientes de todas las edades, hoy en día la empresa no cuenta con página web, solo cuenta con un sistema de ventas con la cual gestionan las ventas, no cuenta con marketing es decir no realizan publicidad, por lo que un sistema de recomendación le sería de mucha ayuda a la empresa porque le permitirá brindar sugerencias sobre lo que tienen en la tienda como consecuente estará realizando marketing.

Avalanch cuenta con las siguientes áreas, área de compras, área de administración; en el área de compras se basa en adquirir ropa al mejor precio para posteriormente brindarle al cliente, el área de administración se basa en verificar y administrar todas las sucursales para tener un control de las tiendas.

Visión y misión

Visión

“Ser una empresa líder y reconocida en la venta de ropa, también poder desarrollarse dentro del país y crear nuestras cadenas de almacenes, proporcionando cada día más un servicio de excelencia a nuestros clientes y que al mismo tiempo nos permitan competir en el mercado nacional con los mejores precios del mercado”.

Misión

“Ofrecer a todos nuestros clientes productos de calidad, brindándole precios cómodos que cumplan con las expectativas y que se sientan satisfechos con los productos ofrecidos por la empresa, abarcando sus gustos de acuerdo a su estilo de ver y vivir la vida”.

Análisis FODA

La empresa Avalanch de la ciudad de Nueva Cajamarca tiene un análisis FODA interno como externo identificándose las fortalezas, oportunidades y las amenazas. Con este análisis la empresa puede identificar carencias que tiene y verificar de qué manera puede mejorar y ser competitivo ante el mercado, los detalles se pueden observar en la siguiente tabla:

Tabla 1

Análisis FODA

ANÁLISIS FODA DE LA EMPRESA AVALANCH	
<p>Fortalezas:</p> <ul style="list-style-type: none"> Contar con buena ubicación en la ciudad. Buena atención al cliente. Trabajadores comprometidos en el rubro. Tener precios bajo en relación a la competencia. <p>Debilidades:</p> <ul style="list-style-type: none"> No contar con estrategias de marketing. Falta de publicidad en medios de comunicación. 	<p>Oportunidades:</p> <ul style="list-style-type: none"> Obtener contactos de proveedores directos que permiten conseguir el producto que se necesita. Poder abrir más sucursales alrededor de la ciudad. Reconocidos en el mercado. <p>Amenazas:</p> <ul style="list-style-type: none"> Entrada de competidores del mismo rubro. Desastres Naturales

Nota. Datos tomados de la empresa Avalanch.

Organización de la Empresa

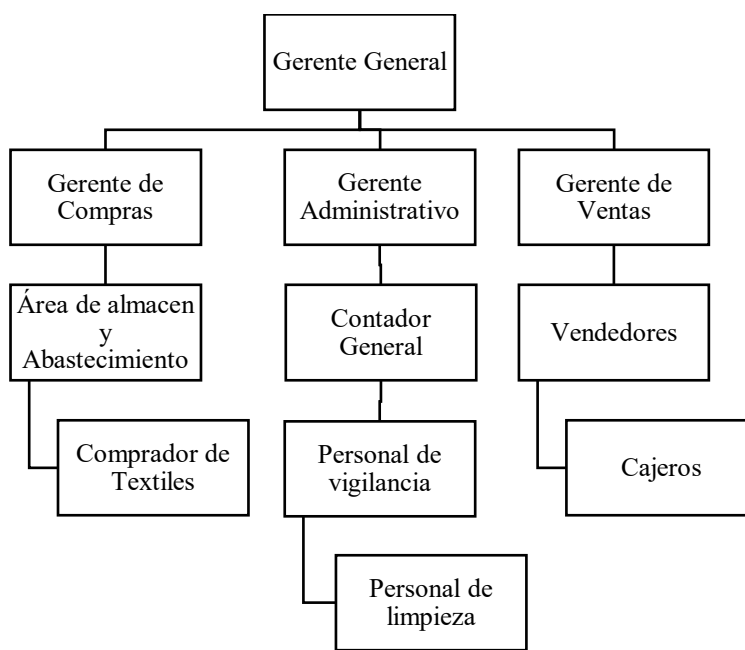
El organigrama de la empresa Avalanch está constituida por distintas áreas que son: Gerente general, es el dueño y fundador de la empresa, gerente de compras, es el encargado de verificar las posibilidades de proveedor a trabajar para obtener mejores precios, gerente

administrativo, es el encargado de gestionar los precios que se distribuirá al consumidor final, área de almacén y abastecimiento, el personal encargado del área se dedica a tener todo de manera ordenada los productos que ingresan a la empresa, contador general, es el encargado de llevar la contabilidad de la empresa como también velar la emisión de boletas u facturas que se soliciten. Además, se encarga de gestionar el pago del personal de la empresa. Vendedores, es el personal encargado de atender a los clientes. Compradores de textiles, son encargado de adquirir tela para que realicen producción de sus propias prendas. Personal de vigilancia, encargado de velar por la seguridad de la empresa. Cajeros, personal encargado de realizar los cobros a los clientes que realizan una compra.

Por último, está el personal de limpieza quienes son los encargados de mantener en orden y limpieza la empresa permitiendo dar una buena imagen.

Figura 1

Organigrama de la Empresa Avalanch



Nota. La figura muestra la estructura orgánica de la empresa Avalanch.

Planteamiento del problema

En la industria de la moda que es la que más cambios sufre a nivel mundial, se tiene que adaptar constantemente a las diferentes estaciones del año, las tendencias globales y a los avances tecnológicos (Chakraborty et al. 2021). Esta dinámica genera que todos los clientes se enfrenten a un sinfín de opciones, complicando de esta manera el proceso de decidir que prendas de vestir adquirir, especialmente en el sector sport; dicho sector ha mostrado un crecimiento exponencial debido a su carácter juvenil, versátil y de uso diario (Ferrando, 2021). A nivel global, empresas como H&M, Zalando o incluso Shein han ido incorporando progresivamente sistemas de recomendación inteligente que están basadas en el aprendizaje automático y de acuerdo al comportamiento del consumidor, esto con el objetivo de ofrecer experiencias personalizadas y, de esa manera, lograr una fidelización de los clientes (Fuster, 2023; Llosá, 2023).

En el contexto latinoamericano, el sector textil empieza un proceso de digitalización acelerada, teniendo como punto de quiebre la pandemia, en donde el comercio electrónico y la personalización de las compras se han convertido en factores críticos y determinantes para enfrentar a toda la competencia (Salgado y Trujillo, 2024). Sin embargo, muchas empresas y emprendimientos aun no aprovechan las soluciones tecnológicas para mejorar las preferencias y gustos de los clientes. Estudios recientes señalan que las empresas requieren distintas estrategias tecnológicas de recomendación inteligente para que puedan gestionar el inventario y reducir las decisiones indecisas de los compradores (Arroyo et al., 2024).

En el caso peruano, las pequeñas y micro empresas del rubro de la moda suelen presentar complicaciones para poder aplicar herramientas de inteligencia artificial para realizar sus procesos de ventas y lograr una fidelización del cliente (Torres, 2024). Entre ellas, la empresa Avalanch, solo se limitan a utilizar sus redes sociales para difundir las distintas ofertas y promociones, sin

tener en cuenta la implementación de un sistema de recomendación automatizado que logre analizar las preferencias de los clientes, mucho menos los gustos de los clientes. Esta falta de actualización provoca pérdidas de oportunidades de venta, menor rotación del inventario y una demora significativa en la elección de prendas de vestir.

A nivel local, la empresa Avalanch enfrenta estos desafíos como el gran porcentaje de tiendas en la región. Los clientes suelen demorar en decidir que prenda elegir debido a la gran cantidad de modelos, colores y diseños, reduciendo el flujo de compra, algunos clientes solo se retiran, afectando de sobremanera la rentabilidad de la empresa. Esta situación evidencia una necesidad crítica de implementar un sistema de recomendación de prendas de vestir, que tome en cuenta los gustos, preferencias y comportamientos del cliente, para poder sistematizar el proceso de la decisión de compra y mejorar la experiencia de la compra, siguiendo buenas prácticas comerciales.

Formulación del problema

La empresa Avalanch está enfocada a la venta de ropa sport, sin embargo, la empresa no cuenta con el marketing adecuado para la gestión de venta de ropa sport, no tiene página web, no cuenta con un personal dedicado a realizar marketing, eso genera que la empresa no tenga más alcance en la población por ende menos ingresos económicos. Otro problema que se identifica en la empresa Avalanch es que la ropa sport es variada lo que genera pérdida de tiempo para los clientes e incluso molestias porque no lograron obtener una ropa adecuada. En la actualidad se tiene diferentes diseños, por lo que al cliente se le hace complicado lograr decidir que adquirir, mencionando todos los puntos de la problemática se puede observar que la empresa Avalanch enfrenta retos importantes en captar sus clientes esto a consecuencia de la falta de estrategias sistemáticas que ayuden a elegir ropa sport acordes a los gustos y preferencias de los clientes, lo

que afecta negativamente en los ingresos económicos y en su desarrollo a la empresa dentro del mercado.

Objetivos

Objetivo general

Optimizar el proceso de ventas de la empresa Avalanch mediante la implementación de un sistema de recomendación de ropa sport utilizando el algoritmo (K-NN).

Objetivo específico

Desarrollar un sistema enfocado al tratamiento de datos, que incorpore los gustos y preferencias de los clientes para comprar ropa sport de la empresa Avalanch.

Implementar el algoritmo K-Nearest Neighbor (K-NN) para agilizar el proceso de recomendación de ropa sport de la empresa Avalanch, permitiendo una precisión más adecuada para el cliente.

Disminuir el tiempo que invierte el cliente al momento de elegir una ropa sport a comprar.

Justificación e importancia del proyecto

Justificación: Necesidad e importancia

Realizar un sistema de recomendación con el algoritmo K-Nearest Neighbor (K-NN) para ropa Sport permitirá que el cliente pueda elegir según sus gustos y preferencias, ya que este sistema le brindará muchas opciones que existe en la empresa Avalanch según a los gustos y preferencias, generándole de tal manera tener más clientela y obtener un mejor ingreso económico hacia la empresa; que como resultado motivará a la empresa como a otras empresas del mismo rubro a invertir en un sistema de recomendación.

El desarrollo de un sistema de recomendación será de suma importancia para la empresa Avalanch, ya que le permitirá obtener información de los gustos y preferencias que tienen los clientes sobre las ropas sport que existen y de esta manera le permitirá cumplir con las ventas objetivas de la empresa paralela a ello le generará a que obtenga ingresos económicos más rentables.

Análisis de viabilidad de la investigación

Viabilidad económica

Todo proyecto se tiene que financiar con un presupuesto económico para su ejecución, en este caso la implementación de un sistema de recomendación de ropa sport para la empresa Avalanch tendrá un presupuesto que abarque todos los recursos necesarios para su desarrollo e implementación como son: materiales, herramientas tecnológicas, tiempo de trabajo y otros gastos adicionales que se presenten en el desarrollo del proyecto.

Viabilidad técnica

Para la viabilidad técnica se tendrá en cuenta que la implementación de un sistema de recomendación está enfocado a funcionar en unos equipamientos tecnológicos, a continuación, se detallan los requerimientos necesarios:

- **Requerimiento de Hardware**

El sistema de recomendación está enfocado a ejecutarse en una infraestructura tecnológica, la cual permite la reducción de equipos especializados, por ejemplo, el uso de servidores locales o en la nube, estos requerimientos se detallan a continuación.

Servidor: Procesador con un mínimo de 4 núcleos, 12 GB de RAM y 500 GB de almacenamiento disponible.

Conectividad: Tener acceso a internet estable para algunas actualizaciones de datos y el acceso para los clientes.

Dispositivos de acceso: Los clientes tendrán la posibilidad de ingresar al sistema a través de un navegador de internet utilizando ya sea una PC, laptops, tabletas o teléfonos.

Requerimientos de Software

Para los requerimientos de software se tendrá en cuenta lo siguiente:

Lenguaje de programación: Para el desarrollo del sistema de recomendación se utilizará PHP, Java Script, Html y Css. Cruz (2025) refiere a PHP como un lenguaje de programación gratuito que está enfocado para diseñar plataformas webs, además, acepta ingresar líneas de código en documentos HTML ayudando a que las páginas sean dinámicas. Para Germain (2020) JavaScript es un lenguaje de programación que permite implementar funciones complejas para las páginas webs, las páginas web solo se muestran información estática y si se implementa JavaScript se podrá tener mapas interactivos, animaciones, desplazamientos. JavaScript es la tercera capa del pastel de todas las tecnologías aplicadas en desarrollo dentro de HTML y CSS. Toga et al. (2025) explican que HTML es un lenguaje usado para diseñar estructuras y presentaciones de documentos en la World Wide Web, además, HTML puede reproducir gráficos vectoriales separados (SVG), también permite ingresar JavaScript para que los sitios webs sean más interactivos ayudando a que sea más moderno. Trampert et al. (2025) CSS (Cascading Style Sheets) es un lenguaje de estilos de hoja que es usado para webs. Los CSS son cruciales para web actuales ya que juega un papel importante en el diseño responsivo ayudando a que sea adaptable.

Base de datos: Para la gestión de nuestra base de datos se utilizará MySQL, Muslim et al. (2025) indican que ese gestor de base de datos ayuda a que se logre almacenar y gestionar datos

de las aplicaciones de manera eficiente, cuando se fusiona PHP con MySQL se logra ejecutar de manera óptima ayudando con la facilidad de administrar los datos y permitiendo a los usuarios acceder a las aplicaciones de manera adecuada y flexible.

Framework: Se utilizará Laravel para el mejor rendimiento del desarrollo del sistema y la gestión de recursos.

API y algoritmos: El sistema de recomendación a implementar hará uso del algoritmo K-Nearest Neighbors (K-NN) es adecuado y viable porque el lenguaje Hypertext Preprocessor (PHP) admite la implementación del algoritmo usando bibliotecas o código personalizado.

Capacidad de Implementación

Escalabilidad: El sistema de recomendación está construido para ser escalable, esto refiere a que podrá adaptarse a una mayor cantidad de información o datos en el sistema sin tener la necesidad de modificar todo el sistema.

Mantenimiento: Se tiene a la perspectiva de que el mantenimiento técnico no sea elevado debido a que está construido en tecnologías de código abierto y estándar, si hubiese cualquier ajuste se podrá realizar sin dificultad.

Riesgos Técnicos y Soluciones

Sobre utilización de recursos del servidor: Si la base de datos se incrementa de manera significativa, el procesamiento puede tener la probabilidad de disminuir su velocidad.

Integración de nuevas funcionalidades: De ser necesario integrar con otros sistemas como como las APIS (Interfaz de Programación de Aplicaciones), las cuales permiten trabajar con otros sistemas y tener mejor rendimiento en un sistema.

Viabilidad tecnológica

La viabilidad tecnológica del sistema de recomendación de ropa sport en la empresa Avalanch hace referencia a las herramientas, plataformas y tecnologías que se aplicarán para el funcionamiento adecuado del sistema. A continuación, se presenta a detalle esos aspectos:

Herramientas y Tecnologías Utilizadas

Para la elaboración del sistema de recomendación se utilizará el lenguaje PHP (Hypertext Preprocessor), el cual es un lenguaje ampliamente utilizado para sistemas webs, PHP es flexible y se puede integrar con algoritmo como el KNN de manera eficiente.

También se contemplará un Frameworks como Laravel para PHP, la cual tiene una estructura sólida, es segura y se puede simplificar la interacción con a base de datos ayudando con el tiempo de desarrollo y asegurando un código limpio, ordenando y mantenible.

Para la construcción de la base de datos se utilizará MySQL ya que es para datos relacionales, además, que es de código abierto y permite almacenar y gestionar los datos de manera eficiente con esto se podrá realizar las búsquedas y recomendaciones se realicen de manera precisa y automatizada.

Para que el sistema tenga el funcionamiento requerido se integrará el algoritmo K-NN que es una técnica de machine learning y se adapta perfectamente los sistemas de recomendación, el algoritmo no necesita un entrenamiento intensivo, su implementación y ejecución es factible.

Infraestructura de Servidores y Alojamiento

Para los servidores del sistema de recomendación de ropa sport se usará una infraestructura en la nube permitiendo escalabilidad, seguridad y redundancia ayudando a que el sistema pueda adecuarse al tráfico y demanda sin tener la necesidad de recurrir a un hardware físico.

Compatibilidad y Adaptabilidad Tecnológica

El sistema de recomendación está construido para ser accesible desde cualquier dispositivo con internet porque tiene tecnologías web estándar como es HTML5, CSS3 y JavaScript además el sistema es responsive es decir se adapta a todo tipo de pantalla y resoluciones.

El sistema tiene la capacidad de adherirse con herramientas y tecnologías externas como las redes sociales y APIs de mensajería convirtiéndose en una solución adaptable y adecuada a futuros requisitos.

Seguridad y Mantenimiento

Para la seguridad del sistema de recomendación se desarrollará en PHP y MySQL ya que permiten una implementación robusta, encriptando datos sensibles, inyecciones SQL y uso de HTTPS para la transmisión segura de datos. El sistema es de código abierto lo cual reduce los costos de mantenimiento y no se tendría la necesidad de solicitar licencias costosas. Para la implementación también se utilizará JavaScript, CSS y HTML.

Escalabilidad y Actualizaciones Futuras

El sistema de recomendación tiene que ser escalable es decir tiene que tener la capacidad de aumentar o disminuir su rendimiento permitiendo tener una respuesta a los cambios de acuerdo a la demanda de la empresa Avalanch. Todo sistema tiene que tener esas posibilidades porque

recordar que las empresas crecen de manera que pasa el tiempo entonces sería necesario que el sistema logre adaptarse a estos cambios.

Límites y alcances

Límites

El proyecto de la realización de un sistema de recomendación está limitado a ser usado por la empresa Avalanch, la cual se utilizará a través de internet.

El sistema de recomendación solo funcionará cuando exista conexión a internet de lo contrario tendrá esas limitaciones porque el sistema contará con su hosting y dominio esto con la finalidad que puedan ingresar al sistema desde cualquier lugar.

Alcances

El sistema de recomendación propuesto incluye la implementación de dos componentes: gestión de ventas y el registro de preferencias., estos componentes se describen a continuación:

- La gestión de ventas permitirá el registrar las operaciones de ventas.
- El registro de preferencias ayudará que los clientes puedan registrar comentarios sobre un producto que desean adquirir.

Propuesta

Como propuesta se tiene la implementación de un sistema de recomendación para la venta de ropa Sport en la empresa Avalanch que le permita realizar más ventas y a la vez obtener ingresos económicos, el sistema se basará en recomendar según los gustos y preferencias de los usuarios sobre la ropa Sport, será implementado con algoritmos inteligentes que brinden información o recolecten esta información de los usuarios según sus búsquedas. Avalanch también no cuenta con

un plan de marketing lo cual un sistema de recomendación le sería de mucha ayuda, obteniendo por consecuente un desarrollo del negocio.

Organización del informe

El informe está organizado de la siguiente manera; el capítulo I se basa en los aspectos relevantes del caso de estudio y la parte metodológica de la investigación, el capítulo II abarca el marco teórico y estado del arte, seguido del capítulo III se muestran los métodos de implementación, también se tiene el capítulo IV donde se desarrolla la propuesta en función al caso de estudio, el capítulo V se detalla la implementación del prototipo, luego está el capítulo VI que son los aspectos económicos-financieros en donde se estructura el presupuesto, el análisis de riesgo, etc. En el capítulo 7 es el análisis costo-beneficio en donde se toma en cuenta el impacto social, el capítulo 8 es la determinación de la viabilidad del proyecto, en el capítulo 9 es donde se estructura las conclusiones y recomendaciones del proyecto de investigación, por último, tenemos el apéndice y los anexos en donde se plasma evidencias de la investigación.

CAPÍTULO II: MARCO TEÓRICO

Antecedentes de la investigación

Antecedentes Internacionales

En primer lugar, Ferrando (2021) en su tesis titulada *“Sistemas de recomendación en la industria de la moda con especial enfoque en el tiempo y la estacionalidad”*, realizada en España, para la Universidad Politécnica de Valencia. El objetivo principal del estudio fue el diseñar y evaluar diferentes modelos de recomendación, que sean capaces de incorporar la dimensión temporal y la estacionalidad en las preferencias de los clientes. Para la investigación se recolectaron datos reales de interacción web de los usuarios en el sitio web de H&M, en donde se consideró los historiales de navegación y las compras realizadas, dichos datos fueron procesados en secuencias temporales que sirvieron para el entrenamiento de los modelos. Los algoritmos que se utilizaron incluyen el modelo base de factorización matricial (ALS) y modelos neuronales secuenciales, tales como, RNN, LSTM y GRU. Se obtuvieron resultados que indican que los modelos basados en Deep Learning superan de forma amplia a los modelos tradicionales, logrando una mayor cobertura y personalización. En conclusión, se determinó que los modelos neuronales secuenciales permiten capturar de manera eficaz la estacionalidad y el comportamiento de los clientes.

También, Chakraborty et al. (2021) en su investigación que lleva por nombre *“Sistemas de recomendación de moda, modelos y métodos: una revisión”*, presentada en los países de Estados Unidos y Canadá. Su objetivo principal es el integrar avances de los años 2010 al 2020 en lo que a sistemas de recomendación de moda se refiere, describiendo diferentes métricas de evaluación y haciendo una comparación con técnicas de filtrado de datos. usaron modelos algorítmicos tales como: KNN, GAN, CNN, y LSTM, recolectando datos de diferentes comercios electrónicos y de

diferentes redes sociales de E-Commerce. Los hallazgos identifican que los enfoques profundos e híbridos superan ampliamente de los sistemas tradicionales de precisión, indica además que los temas de privacidad y ética en el tratamiento de los datos siguen siendo retos en busca de solución. Como conclusión propone líneas futuras como filtros neuronales colaborativos, modelos autorregresivos y filtrado grafico neural, para que se puedan mejorar los datos y atributos de las prendas de vestir.

Por otro lado, Llosá (2023) desarrolló en España una investigación titulada “*Sistema de recomendación de moda basada en atributos multimodales*”, en donde propone un recomendador visual para negocios dedicados a la moda. Su objetivo principal es el sugerir prendas similares a partir de imágenes que sirven como datos de entrada y diferentes atributos que son seleccionados por el cliente, reduciendo tiempo y elevando la pertinencia. El sistema emplea el dataset iMaterialist 2020; además, realiza la segmentación de las prendas de vestir para aislar la prenda del fondo mediante U2-Net, por último, extrae los vectores de las diferentes características de las prendas usando VGG16 para que calcule la similitud coseno y pueda calcular y ranquear los resultados. Para programar su sistema uso una interfaz web basado en React y TypeScript, en donde le permite subir imágenes, fijar numero de recomendaciones y realizar el filtro por atributos. Los resultados muestran que al usar mascarar mejora de forma significativa la similitud promedio, mientras que el filtrado por múltiples características incrementa de forma exponencial la personalización de las prendas para los usuarios. En conclusión, se evidencia que la combinación de todas las tecnologías usadas en el desarrollo del sistema es una vía eficaz y escalable para realizar mejores recomendaciones de prendas de vestir a partir de imágenes.

Asimismo, Rus (2024) desarrolló en España su tesis que lleva por título “*Sistemas de recomendaciones basadas en aprendizaje automático aplicados al comercio electrónico*”, su

objetivo principal es el diseñar e implementar un sistema de recomendación inteligente que mejore la experiencia del usuario y la eficiencia de las plataformas de ventad en línea mediante el uso de diferentes técnicas de Machine Learning. Para lograr eso, se utilizaron datos reales del comportamiento de la compra y navegación de los clientes en diferentes tiendas virtuales, con el fin de modelar patrones claros acerca de las preferencias de los clientes. Los algoritmos empleados y que destacan son los KNN, arboles de decisión, modelos de regresión logística y redes neuronales artificiales, los cuales fueron comparados para elegir el mejor, siendo los seleccionados las redes neuronales y los KNN, debido a que tiene una mayor tasa de adaptabilidad y acierto frente a los métodos clásicos, logrando una personalización más detallada en las recomendaciones. En conclusión, el autor determina que la implementación de sistemas de recomendación basados en aprendizaje automático son una herramienta que incrementa la satisfacción del cliente y ayuda a optimizar las ventas en el negocio.

También Fuster (2024) elaboró en España su investigación titulada “*Desarrollo de un sistema recomendador para la compra de ropa online*”. Su investigación tiene como objetivo la elaboración de un sistema de recomendación inteligente adaptado a las tendencias del comercio electrónico actual, que sea capaz de generar recomendaciones en funciona al historial de compras y las características visuales de las prendas de vestir. Para lograr ello, el sistema se desarrolló en base a cuatro módulos que están interconectados entre sí, se distribuyeron de la siguiente manera: la extracción y almacenamientos de los datos se realizo mediante la web Scraping en la plataforma Zalando, la codificación de las imágenes se realizó con autoenconders convolucionales, la recomendación inicial se logró mediante la factorización de matrices no negativas y por último, el modelo se case en redes neuronales que se encargaron de generar las diferentes combinaciones de atuendos completos. El sistema utilizó datos reales y generó un promedio de 16 millones de

posibles combinaciones de prendas de vestir, los cuales fueron procesadas y puntuadas en base a métricas aleatorias pero que fueron controladas por los desarrolladores. Los resultados mostraron que el sistema desarrollado es capaz de identificar diversos patrones visuales que son coherentes con las elecciones de los clientes. En conclusión, se determinó que el sistema de recomendación es una alternativa eficiente y escalable para la personalización de las elecciones de prendas de vestir de los clientes al momento de comprar.

Por último, Salgado y Trujillo (2024) en el país de Ecuador publicaron un artículo científico con el nombre de “Sistemas de recomendación personalizados: implementación de recomendación utilizando técnicas de aprendizaje automático para mejorar la experiencia del usuario en plataformas en línea”, teniendo como objetivo principal el análisis de un sistema de recomendación basado en Machine Learning que sirva para optimizar la experiencia de los usuarios en diferentes entornos de comercio electrónico. Los métodos y modelos que analizaron son los sistemas colaborativos, basados en contenido, aprendizaje profundo y de filtrado híbrido, los cuales mostraron una eficacia en la personalización de retención de los clientes. Los resultados de la investigación indican que la implementación del sistema de recomendación contribuye de forma significativa a la eficiencia, satisfacción y beneficios económicos del cliente. En conclusión, establecen que los sistemas de recomendación apoyados en machine learning son herramientas claves para el mejoramiento y la adaptabilidad digital, siempre y cuando se apliquen bajo principios éticos y que busquen el equilibrio entre el beneficio económico y la equidad tecnológica.

Antecedentes Nacionales

Vizcarra y Medina (2020) en su trabajo de investigación desarrollado en la ciudad de Lima, que lleva por nombre “*Implementación de un asistente virtual de modas con el uso de una cámara Kinect v2 y procesamiento de imágenes*”, tiene como objetivo principal la mejora de la experiencia

de compra en diferentes tiendas minoristas de prendas de vestir mediante la asistencia virtual que será capaz de generar recomendaciones personalizadas a partir de la colorimetría personal y morfología corporal de los clientes. El sistema fue desarrollado para que pueda operar en un SmartMirror, en donde se integraran componentes de software y hardware que puedan permitir la captura de imágenes que será mediante Kinect v2 y para el procesamiento de los rasgos faciales y corporales se usó OpenCV, SBY y Python. Se desarrollaron distintos módulos para el análisis de todos y cada uno de los rasgos faciales. A partir de estos parámetros el sistema generó recomendaciones de prendas de vestir y combinación de colores personalizadas para cada cliente. Los resultados mostraron una aprobación del 8.31 sobre 10 en facilidad de uso, precisión en la colorimetría y en satisfacción en general. En conclusión, se demostró que el uso de sensores de visión artificial combinadas con los algoritmos de colorimetría permite el desarrollo de asistentes virtuales inteligentes que ayudarán al sector de la moda en el mercado peruano.

También, Ccoyccossi et al. (2021) en su investigación titulada *“Propuesta de un modelo de Machine Learning para el pronóstico de prendas de vestir en la Corporación Brusko S.A.C”*, tiene como objetivo principal la predicción de la demanda de pantalones de caballero aplicando la metodología CRISP-DM y el algoritmo de regresión lineal supervisada en Python, esto con el fin de lograr una optimización en la planificación y la reducción de las pérdidas por falta de stock. Se utilizaron datos reales de las ventas de los años 2018 al 2021, obteniendo porcentajes desfavorables, pero al eliminar los datos de la pandemia, el error promedio se redujo en un 29.98%, evidenciando una mejora significativa en la precisión del modelo; de esa manera los resultados muestran que el modelo de regresión lineal multivariable es capaz de pronosticar de forma confiable la gestión de inventarios y por consecuencia tomar buenas decisiones comerciales. En conclusión, los autores determinan que el uso de técnicas de Machine Learning permite optimizar

de forma efectiva la predicción de la demanda y fortalece la toma de decisiones en el sector de la moda.

Asimismo, Melgarejo (2023) en su investigación titulada “*Sistema de recomendación de prendas basada en reconocimiento corporal (SISCOPR)*”, el objetivo principal es la elaboración de un probador virtual que, a partir de dos fotos en posición frontal y lateral del cliente, logre estimar las medidas corporales y en función a ello sugiera la talla adecuada de la prenda de vestir; Melgarejo menciona que el margen de error es de un máximo 2%, asegurando la correcta asignación de los rangos establecidos. El sistema integra visión por computadora y redes neuronales profundas en una aplicación web que está orientado a negocios de moda que puedan adoptar una suscripción anual, además, cuenta con el MVP que detalla los costos operativos y administrativos y brinda proyecciones de ingresos. Concluye que el sistema es una solución económica y técnicamente viable para reducir significativamente devoluciones y mejorar la experiencia de compra de los usuarios.

Además, Torres (2024) en su investigación realizada en Lima que lleva por nombre “*Sistema de recomendaciones inteligentes para la selección de productos en tiendas retail, Lima, 2024*”, tiene como objetivo determinar la influencia del sistema de recomendación inteligente en la reducción de tiempo de satisfacción y selección del cliente mediante la compra en línea que realizará. Para lograr ello, realizó las pruebas en 60 clientes, utilizó el lenguaje de programación Python y técnicas de web scraping para la recolección de los datos, además del desarrollo de un módulo de recomendación que está asistido por IA para que pueda sugerir diferentes opciones. Los resultados muestran una disminución del tiempo promedio de la selección en un 47% y un incremento en el índice de satisfacción del 50%. En conclusión, se evidencia que la

implementación del sistema de recomendación inteligente ayuda en la mejora significativa de la selección y satisfacción del cliente en el contexto textil.

Por otro lado, Arroyo et al. (2024) en su artículo científico titulado “*Modelo clasificador de prendas de vestir basado en redes neuronales*”, tienen como propósito principal la implementación un modelo de red neuronal convolucional, que sea capaz de clasificar diferentes imágenes de prendas de vestir y lograr la optimización de los catálogos digitales, mejorando de esa manera la experiencia de compra en las plataformas digitales de ventas. El estudio utilizó más de 70000 imágenes de la empresa Zalando y que estuvieron distribuidos en 10 categorías, aplicando un proceso de la normalización de píxeles y realizando la división en conjuntos de entrenamiento y pruebas. El modelo fue desarrollado utilizando Python, con las librerías de TensorFlow y TensorFlow Datasets, también usaron Google Colab y estructuraron con capas Flatten con activación ReLU y teniendo una salida en Softmax. Los resultados obtenidos demostraron una precisión del 90.42% tras 5 entrenamientos, evidenciando de esa manera la capacidad del modelo para adaptarse correctamente a los datos del entrenamiento y realiza clasificaciones con precisión. En conclusión, los autores confirmaron que el uso de redes neuronales convolucionales forma parte de una herramienta eficaz para mejorar la clasificación automática de prendas de vestir, ayudado de sobremanera a los comercios digitales de prendas de vestir.

Por último, Torres (2024) en su trabajo de investigación realizado en Chiclayo, que lleva por nombre “*Sistema web basado en un modelo de recomendación de Machine Learning para apoyar el proceso de ventas de una ferretería*”, tiene como objetivo apoyar y mejorar el proceso de ventas mediante un sistema web que integra un sistema de recomendación en donde utilizaron la metodología CRISP-DM y utilizaron el lenguaje de programación Python, HTML, Google

Colab y MySQL. Utilizaron 208535 registros de ventas de la empresa López y Cía S.A.C, para compararlos con A priori, FP-Growth y FP-Max, seleccionando FP-Growth debido a su mejor eficiencia, generando una precisión promedio del 90%, en tiempos de respuesta adecuados, ausencia de errores y cumplimiento de seguridad, compatibilidad y usabilidad. En conclusión, demostraron que el recomendador basado en reglas de asociación mejora la eficiencia en el proceso de ventas en el ámbito ferretero pero que puede ser empleado en cualquier otro contexto.

Bases teóricas

Evolución

La historia de los sistemas de recomendación se describe seguidamente, mencionando los diferentes métodos, algoritmos, etc. Según Galán (2007) el Filtrado Colaborativo data en comienzos del año 1990, dicho término fue usado en 1992 para un sistema de filtrado de correo electrónico no automatizado, posteriormente se encontraron algunas cuestiones relevantes para el desarrollo del algoritmo como es: Escalabilidad, viabilidad económica, puntuaciones explícitas como también implícitas, también el autor menciona que los primeros en desarrollar el filtrado colaborativo fue el proyecto GroupLens que es de la universidad de Minesota el cual sigue vigente y que ha brindado gran parte de base algorítmica para sistemas de recomendación, hoy en día los sistemas de recomendación con filtrado colaborativo siguen activos en recomendaciones musicales, filtrado de noticias, etc. Seguidamente, tenemos al algoritmo K-medias en el cual los autores James et al. (1967) mencionan que nació en el año 1967, siendo presentado por MacQueen. Este algoritmo ayuda a descubrir agrupamientos en un conjunto de datos, teniendo como objetivo producir una partición de un conjunto de N observaciones en K agrupaciones. Según Palma et al. (2000) en el año 1970 surgió o nació la ingeniería del conocimiento partiendo de la IA (Inteligencia Artificial), a consecuencia de que investigadores en el área de la IA visualizaron de que los

métodos generales de resolución de problemas y también las técnicas de búsqueda implementada en años anteriores eran insuficientes para solucionar problemas de investigación y desarrollo. Por otra parte, se tiene a la técnica Delphi en donde el autor Lynch (2014), menciona que fue desarrollada en los años 1950 por los científicos Olaf Helmer y Norman Dalkey, esta técnica permitía pronosticar eventos futuros usando cuestionarios, también tenemos al filtrado basado en contenido el cual según Lops et al. (2019), mencionan en su artículo denominado “Tendencias en la recomendación basada en contenido” que se originó en el año 1960, como objetivo de este tipo de recomendación era poder distribuir información que esté ligada en la similitud de los elementos de información.

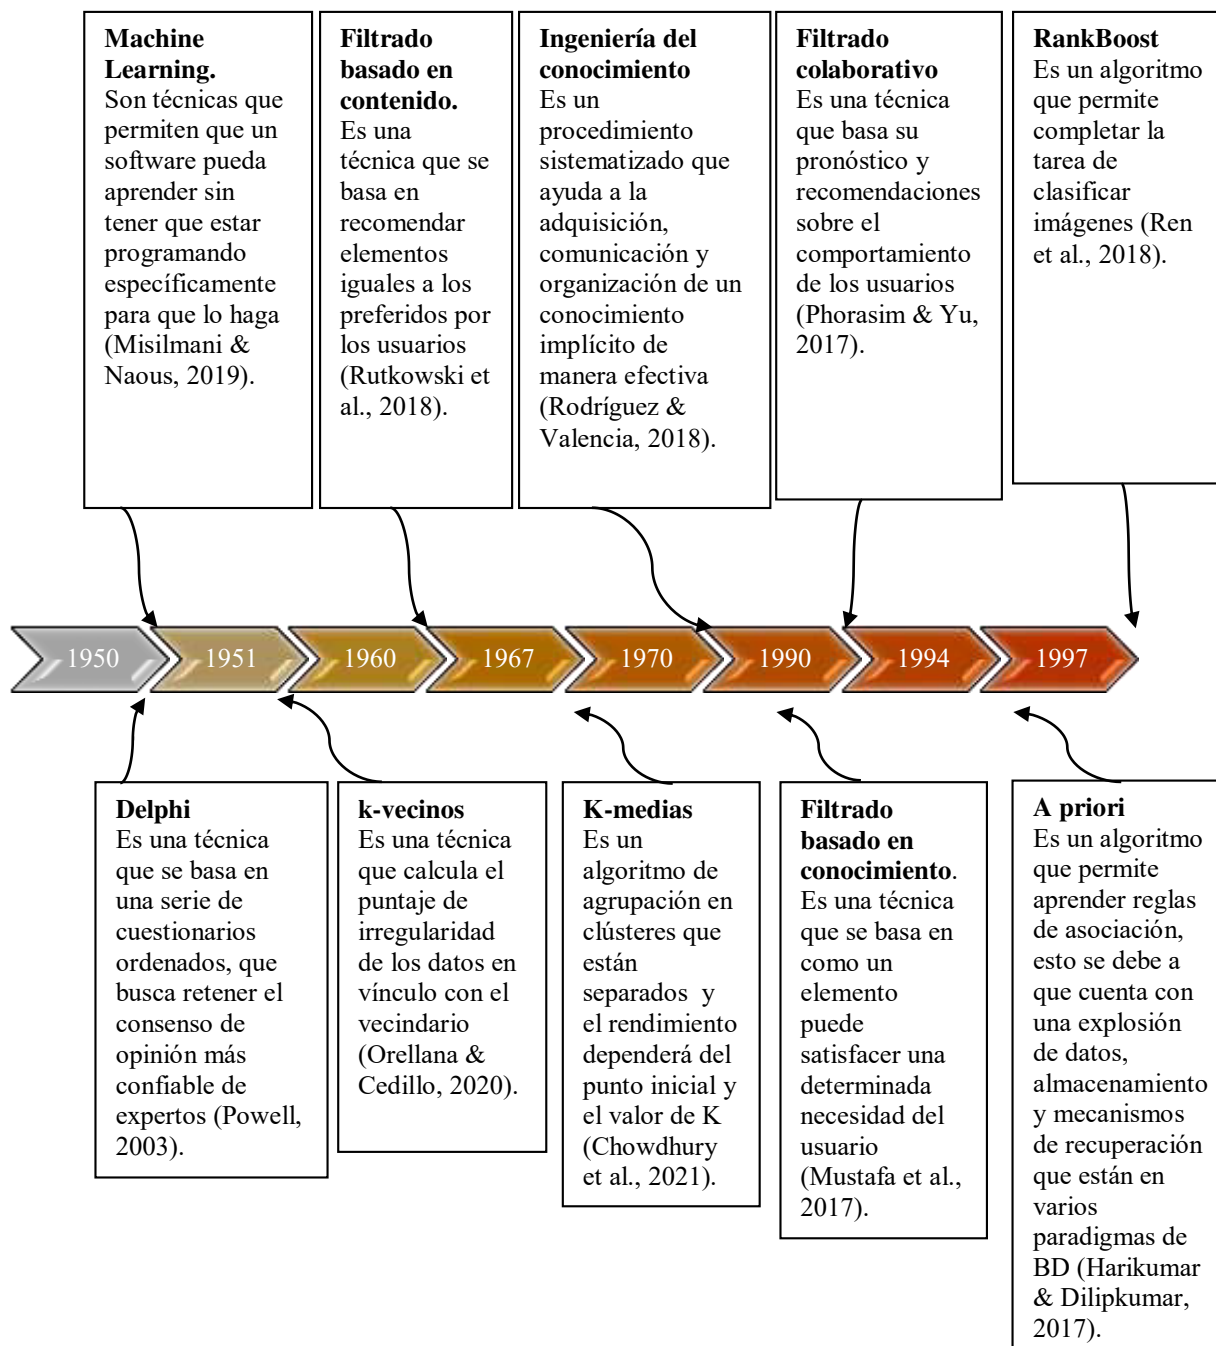
Por otro lado, los autores Frederick & Neil (1994) menciona que el sistema de recomendación basado en conocimientos (KBS) nació en la informática en el año 1970, el cual fue resultado de un sistema DENTRAL que permite explicar estructuras químicas. Según los autores Romero et al. (2017), la técnica de K-Vecinos nació en el año 1951, fue acuñada por Fix y Hodges, esta técnica se basa en buscar usuarios que tengan tendencias y características similares que brinden información importante para que se pueda realizar recomendaciones. Por otro lado, según los autores Nichol et al. (2008) menciona que el algoritmo a priori fue desarrollado o diseñado en el año 1994 por Agrawal y R. Srikant para obtener conjunto de elementos secuenciales en un conjunto de datos hacia la regla de asociación booleana, fue denominado a priori porque usa el conocimiento anticipado de las propiedades recurrentes del conjunto de elementos.

Posteriormente, tenemos al algoritmo de aprendizaje RankBoost que según los autores Freund et al. (2004) menciona que dicho algoritmo nació en el año 1997 y está basado en el algoritmo AdaBoost de Freund y Schapire, el autor también menciona que el algoritmo funciona mezclando muchas combinaciones débiles de las instancias dadas. La técnica Machine Learning

(Aprendizaje Automático) según los autores Patel & Gaurav (2020) mencionan que se originó en el año 1950 por Alan Turing, que permite realizar un análisis de la computadora para visualizar si tiene un intelecto verídico o no, luego en el año 1952, Arthur Samuel implementó el primer programa que podía jugar ajedrez y tenía la capacidad de aprender estrategias nuevas con cada nuevo juego que realizaba.

Figura 2

Línea de Tiempo de la Evolución de los Sistemas de Recomendación.



Nota. Elaboración Propia

Conceptos básicos

Sistemas de recomendación

Un sistema de recomendación es una técnica que permite filtrar cantidades de información las cuales permiten que los usuarios tengan información más específica y no se sobrecarguen con todo ello, además los sistemas de recomendación permiten que los usuarios puedan tomar decisiones de manera más clara y precisa ya que tendrán información más abstracta (Bron & Mar, 2022).

La mayoría de sistemas de recomendación utilizan el filtrado colaborativo que es una de las técnicas más aplicadas dentro de este tipo de implementación, las empresas hoy en día manejan grandes cantidades de datos por lo que los sistemas de recomendación tienen la finalidad de ayudar al usuario es decir trabajan como asistente permitiendo que estos usuarios logren tener información más específica de lo que desean tener. Las preferencias y los gustos de los usuarios son de vital importancia para las empresas ya que con esa información ellos pueden brindar de manera más acertada un producto o servicio que un usuario o cliente requiera (Vega, 2021).

Los sistemas de recomendación han dado un impacto dentro de los sistemas modernos ya que se optimiza procesos de manera sistemática, se tiene sistemas de contenido, sistemas publicitarios personalizados en los servicios digitales, a medida que la información va incrementando se tiene que implementar sistemas que respondan a la demanda de los usuarios como por ejemplo existen los sistemas de recomendación de música en donde se tiene bastante data entonces para ello se generan sistemas de recomendación que permitan adecuarse a los gustos y preferencias de los usuarios respecto a lo que ellos elijan (Garriga, 2023).

Tabla 2*Conceptos básicos de sistemas de recomendación.*

Título	Cita	Concepto
Recommender Systems: An overview of different approaches to recommendations	Shah, K., Salunke, A., Dongare, S., & Antala, K. (2018). Recommender systems: An overview of different approaches to recommendations. Proceedings of 2017 International Conference on Innovations in Information, Embedded and Communication Systems, ICIECS 2017, 2018-January, 1–4. https://doi.org/10.1109/ICIECS.2017.8276172	“Los sistemas de recomendación son técnicas y herramientas de software el cual permite recuperar información para brindar recomendaciones para los usuarios” (Shah et al., 2018)
A state-of-the-art survey on recommendation system and prospective extensions	Patel, K., & Patel, H. B. (2020). A state-of-the-art survey on recommendation system and prospective extensions. Computers and Electronics in Agriculture, 178(June), 105779. https://doi.org/10.1016/j.compag.2020.105779	“Un SR se centra en generar una lista de preferencias de ciertos elementos utilizando una correlación a través de usuarios vecinos y recolectando información del historial de calificaciones pasados de los usuarios” (K. Patel & Patel, 2020).
Social Networking in Web Based Movie Recommendation System	Das, N., Borra, S., Dey, N., & Borah, S. (2018). Social Networking in Web Based Movie Recommendation System. Social Networks Science: Design, Implementation, Security, and Challenges, 25–45. https://doi.org/10.1007/978-3-319-90059-9_2	“Los sistemas de recomendación son un tipo de servicios personalizados que generan recomendaciones ya sea de productos o como también servicios a los usuarios respecto a sus necesidades” (Das et al., 2018)

Título	Cita	Concepto
How smart is e-tourism? A systematic review of smart tourism recommendation system applying data management	Hamid, R. A., Albahri, A. S., Alwan, J. K., Al-Qaysi, Z. T., Albahri, O. S., Zaidan, A. A., Alnoor, A., Alamoodi, A. H., & Zaidan, B. B. (2021). How smart is e-tourism? A systematic review of smart tourism recommendation system applying data management. <i>Computer Science Review</i> , 39, 100337. https://doi.org/10.1016/j.cosrev.2020.100337	“Los sistemas de recomendación aportan o ayudan a proveer soluciones que se presentan en los usuarios finales, ya que potencia los datos personales en sistemas de apoyo permitiendo brindar soluciones respecto a la toma de decisiones, existen varias técnicas en el SR que pueden satisfacer las necesidades de los intereses y preferencias de los usuarios” (Hamid et al., 2021).
A comprehensive study on recommendation systems their issues and future research direction in e-learning domain	Rawat, B., Samriya, J. K., Pandey, N., & Wariyal, S. C. (2020). A comprehensive study on recommendation systems their issues and future research direction in e-learning domain. <i>Materials Today: Proceedings</i> , xxxx. https://doi.org/10.1016/j.matpr.2020.09.796	“Los SR cooperan con el usuario permitiéndole que pueda elegir de la extensa información que existe en función a sus gustos y preferencias, como función de los sistemas de recomendación es apoyar con la toma de decisiones de los usuarios recomendándole algo sobre su interés” (Rawat et al., 2020).
Meta-learning strategy based on user preferences and a machine recommendation system for real-time cooling load and COP forecasting	Li, W., Gong, G., Fan, H., Peng, P., & Chun, L. (2020). Meta-learning strategy based on user preferences and a machine recommendation system for real-time cooling load and COP forecasting. <i>Applied Energy</i> , 270(April), 115144. https://doi.org/10.1016/j.apenergy.2020.115144	“Un sistema de recomendación es el integrante central del meta aprendizaje, el sistema de meta aprendizaje es el más usado en los sistemas HVAC (Calefacción, y Aire Acondicionado)” (W. Li et al., 2020).

Título	Cita	Concepto
Ontology and context-based recommendation system using Neuro-Fuzzy Classification	Razia Sulthana, A., & Ramasamy, S. (2019). Ontology and context-based recommendation system using Neuro-Fuzzy Classification. <i>Computers and Electrical Engineering</i> , 74, 498–510. https://doi.org/10.1016/j.compeleceng.2018.01.034	“Los sistemas de recomendación se basan en identificar servicios o productos de interés según los gustos y preferencias que tengan los usuarios” (Razia Sulthana & Ramasamy, 2019). “Los sistemas de recomendación es una aplicación que está diseñada para brindar recomendaciones exactas para los usuarios por medio de la recopilación y el procesamiento de los datos personales por medio de un tratamiento eficaz” (Wang et al., 2018).
Toward Privacy-Preserving Personalized Recommendation Services	Wang, C., Zheng, Y., Jiang, J., & Ren, K. (2018). Toward Privacy-Preserving Personalized Recommendation Services. <i>Engineering</i> , 4(1), 21–28. https://doi.org/10.1016/j.eng.2018.02.005	“Un sistema de recomendación es un diseño específico de filtrado de la información que tiene como propósito mostrar elementos de interés para el usuario” (Zitouni et al., 2020).
New contextual collaborative filtering system with application to personalized healthy nutrition education	Zitouni, H., Meshoul, S., & Mezioud, C. (2020). New contextual collaborative filtering system with application to personalized healthy nutrition education. <i>Journal of King Saud University - Computer and Information Sciences</i> , xxxx. https://doi.org/10.1016/j.jksuci.2020.04.012	“Los sistemas de recomendación son algoritmos que permiten a todos los usuarios a que tomen las mejores decisiones en entornos on-line” (Holguera et al., 2018).
Computación empotrada de funciones de los sistemas de recomendación mediante FPGAs	Holguera, F. P., G, J. A., & Dur, A. (2018). Computación empotrada de funciones de los sistemas de recomendación mediante FPGAs. <i>Jornadas Sarteco 2018</i> .	

Título	Cita	Concepto
Similarity and evaluation metrics for collaborative based recommender systems	Mendoza Olguín, G., Laureano De Jesús, Y., & Pérez de Celis Herrero, M. C. (2019). Métricas de similaridad y evaluación para sistemas de recomendación de filtrado colaborativo. <i>Revista de Investigación En Tecnologías de La Información</i> , 7(14), 224–240. https://doi.org/10.36825/riti.07.14.019	“Un sistema de recomendación se puede definir como una función que reintegra un listado de ítems de manera ordenada con respecto a los usuarios” (Mendoza et al., 2019).
Desarrollo de Nuevas Técnicas de Gestión de Datos para Entornos Móviles: Profundizando en las Recomendaciones Móviles	del Carmen Rodríguez-Hernández, M., Ilarri, S., Hermoso, R., & Trillo-Lado, R. (2017). DataGenCARS: A generator of synthetic data for the evaluation of context-aware recommendation systems. <i>Pervasive and Mobile Computing</i> , 38, 516–541. https://doi.org/10.1016/j.pmcj.2016.09.020	“Un Sistema de recomendación es una aplicación que ayuda a los usuarios a minimizar la carga de información y sugerir recomendaciones específicas realizando filtrados según a las preferencias de los usuarios ya que, hoy en día estamos en la era de Big Data” (del Carmen et al., 2017).

Nota. Elaboración Propia

Basándose en la recaudación de información de los diferentes autores sobre conceptos de sistema de recomendación descritos en la tabla 2, se puede mencionar que un sistema de recomendación es una aplicación o software que está diseñada para filtrar información relevante según los intereses, gustos y preferencias de los usuarios permitiéndole solucionar la demasiada información existente y poder tomar decisiones sobre un ítem que desean adquirir esto con la ayuda de los sistemas de recomendación.

Clasificación de los sistemas de recomendación

Según los autores Fayyaz et al. (2020) mencionan que los sistemas de recomendación se clasifican en filtrado basado en contenido, filtrado colaborativo, basado en demografía, filtrado basado en conocimiento y filtrado híbrido, el más usado para implementar un sistema de recomendación es el filtrado colaborativo y el filtrado basado en contenido.

Filtrado basado en contenido

Según Walek & Fojtik (2020) describen que el filtrado basado en contenido busca información de otros productos con características similares lo cual en un momento fueron calificados por un usuario, los comentarios y también las calificaciones son de gran ayuda para que se pueda desarrollar una recomendación conveniente para un usuario. Relaciona el contenido de todos los elementos nuevos que probablemente se pueda recomendar a un usuario, trata de encontrar elementos que son iguales a los que un usuario calificó efectivo anteriormente (Felfernig et al., 2019). Este método propone elementos que son semejantes a los elementos que le han interesado al usuario anteriormente (Pimenidis et al., 2019).

Filtrado colaborativo

Este método aplica preferencias de usuarios el cual se basa en los patrones de las interacciones pasadas de los usuarios y elementos (Raziperchikolaei et al., 2020). Recopilan información y analizan el comportamiento de los usuarios respecto a sus comentarios, preferencias, actividades y calificaciones para posteriormente verificar las similitudes entre los varios usuarios analizados con ello poder predecir calificaciones que faltan, permitiendo brindar recomendaciones específicas (Mohamed et al., 2019). El filtrado colaborativo emplea las opiniones de otros usuarios con sus gustos y preferencias similares para realizar recomendaciones

porque el filtrado colaborativo no necesita análisis de contenido mostrando así ventajas frente a muchas situaciones donde las características del filtrado en contenido son complejo de extraer, por lo que el filtrado colaborativo deduce que las calificaciones brindadas por los usuarios pueden reflejar gustos y preferencias de los usuarios (Cai & Zhu, 2019).

Filtrado basado en demografía

Esta técnica se enfoca específicamente en la información del usuario, esto incluye la edad, el género, etnia, situación laboral, conocimiento de idiomas, hogar y también ubicación. Toda esta información será de vital importancia para el desarrollo e implementación de un sistema de recomendación demográfico, ya que se puede obtener información única de los usuarios, en donde el sistema recomienda todos los elementos de acuerdo a la semejanza demográfica (Vargas & Leiva, 2015).

Se basa en características demográficas de usuarios como edad, género, nacionalidad y nivel de educación para que se pueda seleccionar usuarios y de esa manera facilitar una mejor recomendación (Beheshti et al., 2020).

Filtrado basado en conocimiento

Se basa en todos los intereses que están especificados por el usuario, esta técnica emplea el conocimiento sobre un usuario y productos, combinando requisitos concretos por los usuarios y también los atributos de los elementos con el conocimiento del dominio, los sistemas basado en conocimiento no usan calificaciones para que puedan generar recomendaciones, sino que usan métricas de similitud que están basadas en el conocimiento del dominio, pero la construcción y también la actualización es un trabajo complejo porque se requiere de una suficiente experiencia y conocimiento del dominio (Shokeen & Rana, 2020). Se encarga de realizar recomendaciones de

elementos a los usuarios sobre la base de sus necesidades, gustos y preferencias (Zhang et al., 2020). Este tipo de método necesita de la creación de una base de datos en donde se encuentre información relacionada con bienes o artículos en el área que se utilizará (Alamdari et al., 2020).

Filtrado híbrido

Es la combinación entre filtrado colaborativo y basado en contenido que evitan las posibles limitaciones de los enfoques permitiendo obtener beneficios del otro, la hibridación emplea información representativa que está basada en todo el contenido de un nuevo elemento sin tener una calificación de usuario (Batmaz et al., 2019). El filtrado híbrido tiene en consideración todas las fortalezas de las técnicas compuestas para de esa manera brindar recomendaciones válidas (George & Lal, 2019).

Formas de implementación de un sistema de recomendación

Los autores Paudel et al. (2018) implementaron un sistema de recomendación musical basándose en la información de los rasgos de personalidad de las redes sociales, para ello los autores señalan que empezaron con la identificación de los rasgos de la personalidad de los usuarios recolectando datos de actualizaciones de estado del perfil de Facebook que permitan predecir el tipo de personalidad que tiene un usuario en específico, estos autores implementaron API de Facebook Graph que permitió rescatar dicha información, posteriormente mencionan que realizaron el preprocesamiento de estos datos recolectados que consiste en la conversión de las actualizaciones de estado en representaciones vectoriales usando un modelo de bolsa de palabras, luego usaron un clasificador denominado Naive Bayes para que clasifique el texto de actualizaciones de estado con esto se logró el objetivo poder brindar recomendaciones musicales a los usuarios. Y. G. Shin et al. (2019) en su trabajo de investigación denominado “Sistema de

recomendación de moda profunda con descomposición de características de estilo” mencionan que la red neuronal convolucional (CNN) solo obtiene dos tipos de información que son estilo y categoría ocasionando un problema que es la recomendación de ropa no compatible, por lo tanto, el autor para dar solución a dicho problema implementa método de extracción de características de estilo (SFE) que se encarga de descomponer de manera eficaz el vector de ropa en estilo y también en categoría.

También utilizó el algoritmo K-means, el cual agrupa los vectores de estilo de ropa según clase, dándole como valor a $K=20$ y obtener 20 centroides $\{C_1, C_2, C_{20}\}$, encontrando de tal manera el más cercano centroide C_n respecto al vector de estilo de las prendas, posterior a ello el m artículos más cercanos que están dentro a la clase n -ésima se escoge como candidatos para la ropa que hará juego es decir ropa compatible, m tendrá un valor de 10 $m=10$, en el experimento realizado usaron GoogLeNet (Red neuronal convolucional profunda de 22 capas) como una red base, por lo que según los autores la capa SFE brinda un resultado superior en la predicción de ropa realizando combinaciones óptimas.

Por otro lado, los autores Sharma et al. (2019) quienes realizaron un trabajo de implementación de un sistema de recomendación de moda de prendas personalizada, detallan puntos relevantes de como hicieron aquella construcción del sistema, en donde los autores mencionan que usaron la técnica de filtrado híbrido, cumpliendo con ciertos trabajos como es la recopilación de datos, el modelado de los datos, el procesamiento de los datos y el análisis de los datos sobre antecedentes de compras de los usuarios, en donde tomaron en cuenta el historial de compras de un usuario también la descripción de las prendas, es decir qué tipo de prenda como también la tela, posteriormente los autores tuvieron que realizar el desarrollo del sistema enfocándolo a una empresa de moda denominada UE el cual permitirá obtener información

relevante como los datos históricos de la plataforma de la empresa el que nos permitirá verificar los datos del perfil del cliente, también el historial de pedidos del cliente incluso los comentarios realizados todo esto nos brindará una mejor visualización para poder brindar las recomendaciones de ropa según los gustos de los usuarios, también mencionan que usaron Python y SQL el que les permitirá generar estadísticas descriptivas mostrando a detalle la tendencia central, la dispersión y la distribución de los datos.

Por último los autores mencionan que el sistema de recomendación que implementaron lo dividieron en tres fases, la primera fase el sistema funcionara con un algoritmo llamado K-means de aprendizaje automático no supervisado, el algoritmo tiene la necesidad de brindarle un valor a K para que se identifique en el conjunto de datos, los datos serán la altura, peso y tamaño de cuello, en la segunda fase se utiliza Brute quien permitirá encontrar el objeto más cercano y por último en la fase tres el autor señala al algoritmo RFC (Clasificador de bosque aleatorio) el que permitirá obtener el mejor estilo para el ajuste de los parámetros biométrico de los usuarios, RFC usa varios árboles de decisión y une los resultados para que pueda obtener una predicción más acertada o precisa en el sistema de recomendación.

Chen et al. (2018) implementó un sistema de recomendación para el diagnóstico y el tratamiento de enfermedades (DDTRS), para ello utilizaron el algoritmo clustering Analysis para que pueda agrupar los síntomas de las enfermedades, dentro de ello también usaron el algoritmo A priori, la plataforma en la nube Apache Spark fue una herramienta para dicha implementación. La manera en la que implementaron el sistema de recomendación se basa en dos módulos el primero es el análisis de agrupamiento de sistemas de enfermedad en donde se introduce el algoritmo de agrupamiento que está basado en DPCA para que brinde la clasificación de los síntomas de acuerdo a los informes de inspección, el segundo módulo es el diagnóstico de la

enfermedad y el módulo de recomendación del tratamiento esto se hace con el algoritmo A priori, se procede a recolectar información de datos médicos que fueron sacados de varios hospitales como son: Código de identificación, nombre, teléfono y la dirección.

Los experimentos del sistema se realizaron en una plataforma en la nube Apache Spark en NSCC, 32 GB de memoria, como resultado de esta implementación se muestra que tanto como el médico y un paciente obtienen recomendaciones de tratamientos que está basada en los informes de inspección las cuales fueron brindadas por diferentes hospitales por lo que el sistema es efectivo y se logra cumplir con el objetivo. Por otra parte, los autores Wu et al. (2019) implementaron un sistema de recomendación de películas usando la técnica filtrado colaborativo, primeramente ellos obtienen datos de películas de la base de datos de Yahoo Research Webscope quien les proporciona dos archivos una de ellas es “Yahoo clasificaciones de usuarios de películas”, este archivo abarca 211231 registros así mismo tiene el ID de usuario, ID de películas y calificaciones. El otro archivo es “Yahoo información de contenido”, quien tiene 54058 registros y tiene ID de película, título, género, director, actores, etc. Posteriormente, los autores mencionan que realizaron una limpieza de datos, es decir el archivo de información de contenido como también en el archivo de usuarios de películas encontraron columnas que no fueron necesarias para el experimento, existía valores en blanco incluso duplicados por ende fueron eliminados; luego realizaron el análisis de datos para que puedan obtener información sobre las películas permitiendo desarrollar el sistema, también identificaron patrones como son: Películas que tienen más calificaciones, géneros más calificados, cantidad de películas en cada género y la cantidad de películas calificadas por categoría.

Por último los autores construyen el modelo del sistema, para ello usaron la biblioteca Mahout que les permitió construir el sistema de recomendación, respecto al filtrado basado en los usuarios, usaron la clase User Similarity y Pearson Correlation Similarity que usa el coeficiente de

correlación de Pearson permitiendo encontrar la similitud entre las calificaciones de los usuarios por ende saber las preferencias, también usaron el algoritmo de aprendizaje automático de agrupación en clústeres denominado Nether NUser Neighborhood donde N es definido en el código de programa, el algoritmo de vecino más cercano busca el N puntos más cercano posible para obtener el máximo de puntos de datos iguales y poder agruparlos, el filtrado basado en elementos se puede implementar con el Item Similarity clase de Mahout, el algoritmo que permite calcular la similitud del artículo es Log Likelihood Similarity esto debido a que los elementos son estáticos, los resultados de la recomendación basado en artículos se cargan al sistema de archivos de Hadoop (HDFS) quien almacena esta información y es resistente a fallos, respecto a la recomendación basado en el usuario se calcula cada vez porque a diferencia de los elementos, las calificaciones son proporcionadas por el usuario.

Como resultado de esta implementación muestra que el sistema brinda las recomendaciones esperadas por el usuario, pero existe un detalle cuando se registra un usuario nuevo, este aún no ha realizado una calificación a una película y es allí en donde entra el dilema del arranque en frío el sistema no podrá brindarle recomendaciones porque no tiene información que le permita realizar esta acción, de igual forma sucede cuando almacenan una nueva película.

Tecnologías asociadas

Java

Nathoo et al. (2019) describen que java es un lenguaje de programación que está orientado a objetos el cual describe el foco de los diferentes objetos dentro de la fracción de código en lugar de leerlo línea por línea. Tecnología utilizada para el desarrollo de un sistema de recomendación, el autor también describe en su trabajo que el software está compuesto por tres grupos de agentes

como es: El agente de ejecución denominado (EA), el de información (IA) y el agente híbrido (HA) (Ejecución e información).

Respecto al EA es encargado de ejecutar los procedimientos definidos y de tal modo tomar decisiones que sean necesarias, la IA se encarga de brindar información a otros agentes con la finalidad de anunciar a los demás sobre aquellos cambios del sistema.

La interfaz del usuario se construyó usando HTML y AJAX, la comunicación entre agentes se usó HTTPS y JADE; estas tecnologías permitieron la construcción del sistema de recomendación basado en la web para SmartTourism: Tecnología multiagente realizada por (Liberati et al., 2018).

Python

Horton & Parnin (2018) es un lenguaje de programación conocido y está entre los más solicitados por el mercado hoy en día, Python es utilizado frecuentemente para brindar clases de introducción a la programación, así como también es usado por programadores no profesionales, como científicos.

Según los autores Ahuja et al. (2019) en su trabajo realizado sobre un sistema de recomendación de películas describen que como tecnología asociada para poder desarrollar un sistema de recomendación utilizaron al lenguaje de programación Python de la mano con la biblioteca de agrupamiento de K-Means y K-Ne vecino, el desarrolló del sistema de recomendación tiene muchas subsecciones es decir procesos a seguir: Se realiza la recopilación de los datos necesarios, se procede a preparar los datos, se crea los modelos, se realiza el entrenamiento de los modelos y por último se prueba el modelo.

Aspectos Legales de ropa Sport

La negociación de productos de ropa sport en el Perú esta supervisada por múltiples normativas que respaldan la protección de los consumidores, la privacidad de los datos y la ejecución de los estándares de calidad.

Propiedad industrial: En el Decreto Legislativo N° 1075 regula el registro de marcas y diseños industriales, resguardando la protección de los derechos sobre las creaciones y rechazando la copia o el uso no permitido de marcas y diseños.

Etiquetado: Es necesario proporcionar información adecuada es decir clara sobre la composición, los cuidados y origen de los productos, de acuerdo con la normativa vigente, para certificar la transparencia y seguridad del consumidor.

Protección de Datos Personales: La ley N° 29733 y su reglamento (Decreto Supremo N° 003-2013-JUS) norman el tratamiento de datos personales. Esto solicita tener el consentimiento informado de los usuarios, así como desarrollar medidas de seguridad para proteger su privacidad, específicamente si se utilizan sistemas de recomendación en línea.

Comercio electrónico: Según la ley N° 29571 (Código de protección y defensa del consumidor), en este caso el sistema de recomendación a implementar funcionara en plataformas de comercio electrónico por lo que es necesario garantizar que los consumidores tengan una información clara, precisa y veraz sobre los productos recomendados en la plataforma.

Protección al consumidor: La ley N° 29571 exige que los productos satisfagan con los estándares de calidad, seguridad y que la publicidad sea visible evitando prácticas engañosas.

Normativa Internacional: Para gestionar a nivel global, es importante cumplir con regulaciones internacionales como por ejemplo el reglamento general de protección de datos

(GDPR) de la Unión Europea, si se operan datos de ciudadanos extranjeros, así como normativas comerciales aplicables en cada región.

Definición de términos básicos

Sistema de recomendación

Es un conjunto de técnicas que pueden predecir las preferencias de los clientes y ordenarlos en diferentes ítems para poder personalizar la experiencia en el tema de compras online (Chakraborty et al., 2021).

K-Nearest Neighbors (KNN)

Algoritmo que busca una recomendación basada en los K vecinos más cercanos, según una distancia que puede ser la euclidiana (Rus, 2024).

Filtrado basado en contenido

Recomendación realizada por parecidos en diferentes atributos de las prendas tales como color, forma, rasgos visuales, etc. (Fuster, 2023).

Normalización

Es un conjunto de componentes lógicos que son necesarios permitiendo desarrollar o ejecutar tareas específicas (Rus, 2024).

Técnica

Es un procedimiento que permite usar recursos necesarios de manera que se logre obtener un resultado esperado, cumpliendo con los objetivos y poder satisfacer las necesidades de quien desea aplicarlo (Torres, 2024).

Tecnología

Es la agrupación de técnicas, métodos, procesos y también habilidades usadas para producir bienes como también servicios o lograr objetivos como la investigación científica (Arroyo et al., 2024).

Métodos

Es una manera organizada y a la vez sistemática de alcanzar un objetivo, los métodos se pueden aplicar en muchas áreas (Melgarejo, 2023).

Validación de usuarios

Medición de la usabilidad y satisfacción para poder asegurar una utilidad real (Vizcarra y Medina, 2020).

Similitud

Medida en la cual se ve cual es el parecido entre dos vectores; en K-NN se suele usar la similitud euclidiana o coseno (Llosá, 2023).

Conjunto de entrenamiento

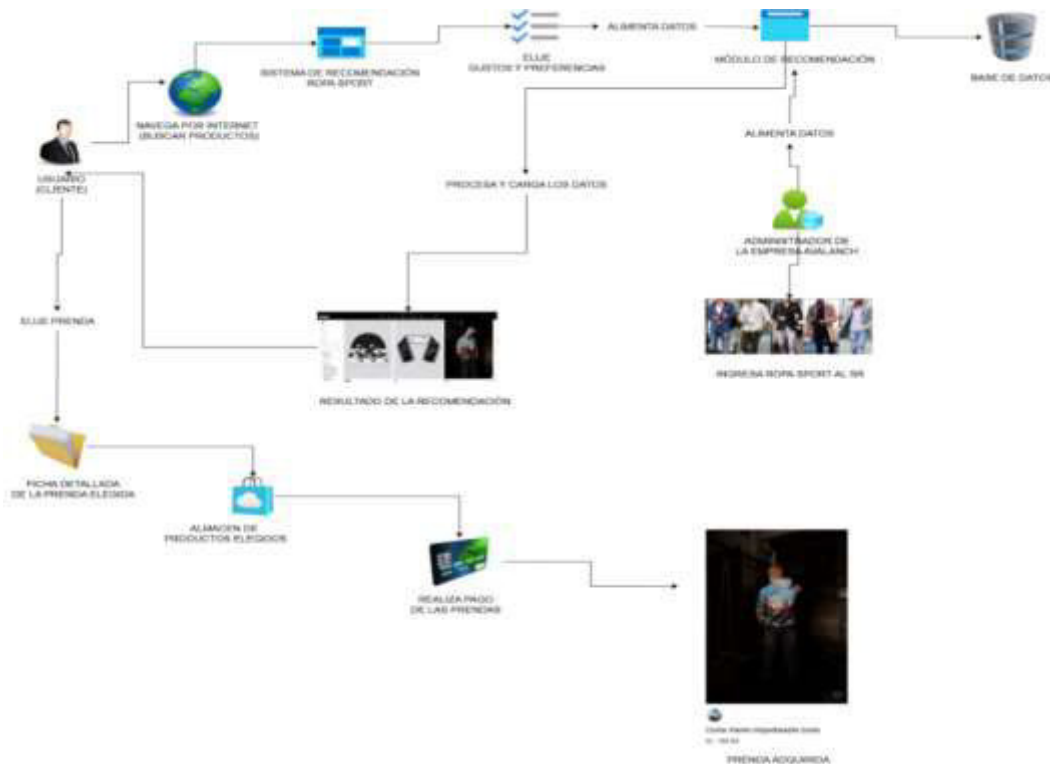
División de datos para poder aprender y poder validar el desempeño de las pruebas sin ningún tipo de sesgo (Ferrando, 2021).

CAPITULO III: DISEÑO DE LA SOLUCIÓN

Para la solución de la problemática identificada en la empresa Avalanch se busca implementar un sistema de recomendación para ropa sport basado en los gustos y preferencias de los clientes. Con la ayuda de la solución se busca que la empresa obtenga más clientes y la incrementación de las ventas por ende un crecimiento como empresa, la solución iniciará mencionando el modelo conceptual, allí es donde se detalla la aplicación del algoritmo que ayude con la generación de recomendaciones y el cuadro arquitectónico de la solución, en este apartado se detalla la arquitectura propuesta del sistema. El modelo conceptual se visualiza en la siguiente figura:

Figura 3

Modelo conceptual de la solución.

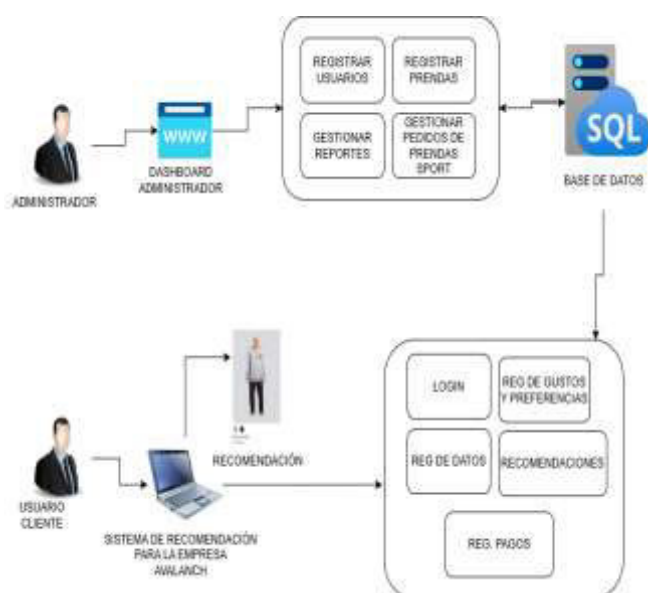


Nota. Elaboración Propia

En la figura 3 podemos apreciar el funcionamiento general del sistema de recomendación propuesto, el usuario (cliente) desea adquirir una prenda por lo que decide ingresar a verificar en internet y al buscar se muestra el sistema de recomendación de la empresa Avalanch en donde ingresa y el sistema solicita que el usuario elija 3 categorías sobre sus gustos y preferencias para que de esa manera el sistema pueda dar las previas de recomendación de acuerdo a lo seleccionado por el usuario de esa manera poder dar solución al arranque en frío que tienen los sistemas de recomendación, el módulo de recomendación empieza a trabajar enviando opciones similares a lo que el usuario seleccionó anteriormente, esta función lo hace con el algoritmo K-NN quien le ayuda con esa funcionalidad, para que este módulo de recomendación funcione se cuenta con un administrador del sistema quien ya subió información al sistema para que este tenga data. Cuando el sistema muestra las prendas similares a lo elegido por el usuario, este seleccionará lo que le gusta para poder comprarlo, el sistema permite comprar a través de internet. Todo esto es de manera generalizada, el siguiente gráfico se observa a detalle.

Figura 4

Cuadro arquitectónico



Nota. Elaboración Propia

En la figura 4 muestra al funcionamiento del sistema de recomendación de prendas de vestir dando solución a lo propuesto en este trabajo, como primer paso para utilizar el sistema, el usuario tiene que registrarse para hacer uso del sistema de recomendación posterior a ello inicia sesión con su cuenta ya creada, al iniciar sesión se le solicitará que seleccione categorías de su preferencia como, por ejemplo: Polos, pantalones, casacas, short, etc. Esto se hace para evitar el arranque en frío que hoy en día tiene los sistemas de recomendación, al realizar todo ese procedimiento la base de datos almacenará esa elección y generará recomendaciones de prendas según a los ítems elegidos por el usuario, el sistema de recomendación mostrará todas las opciones disponibles según a las preferencias, si el usuario desea comprar allí entra en acción el banco permitiendo al usuario realizar el pago de manera segura y más rápida.

Módulo de recomendación

El módulo de recomendación utilizará el algoritmo K-Nearest Neighbor (K-NN), que contrasta los gustos y preferencias de los clientes para la compra de una prenda sport de la empresa Avalanch, con un análisis específico se logra identificar las prendas que mejor se asimilen a los gustos del cliente, brindando una lista de recomendaciones acorde a los gustos y preferencias del cliente, esos detalles se muestran en el sistema (interface) cuando el cliente ingrese o se logue.

La ejecución de la recomendación sigue los siguientes pasos:

- Registro de gustos y preferencias: El cliente o usuario ingresa sus gustos y preferencias al momento de entrar al sistema para que tengas los mejores resultados de similitud (Marca, Tipo_prenda, Rango_precio, Talla, etc).

- **Procesamiento de datos:** El sistema transforma esos gustos y preferencias en datos numéricos y los relaciona con las variables que el usuario haya seleccionado almacenado en la base de datos.
- **Cálculo de la distancia:** El cálculo se realizará mediante la distancia euclidiana, el sistema de recomendación determina que prendas tienen similitud a los gustos y preferencias de los usuarios.
- **Generación de recomendaciones:** El sistema brinda prendas sport lo más similares posibles al perfil del usuario.

El algoritmo K-NN lo que hace es clasificar datos o conjunto de datos usando información almacenada que este acorde a los datos iniciales. La clasificación se hace calculando la distancia de los datos que se desea clasificar con el conjunto de datos más cercanos. La precisión del clasificar depende de los parámetros como la distancia y el número k (k representa a los vecinos más cercanos) (González y otros, 2025). Se presenta un pseudocódigo para describir como se implementa el algoritmo K-NN para el sistema de recomendación de ropa sport. El algoritmo verifica los gustos y preferencias de los clientes calculando la similitud mediante la distancia euclidiana.

Seudocódigo para el sistema de recomendación:

1. Se define el número de vecinos más cercanos, es decir K, por ejemplo: $K=3$.
2. Para cada cliente/usuario del sistema:

- 2.1. Obtener los gustos y preferencias de los clientes/usuarios, esto se da usando las variables internas como, por ejemplo: Marca, precio, tipo_prenda, color, temporada_uso, tipo_fibra, diseño, nivel de comodidad, etc.
- 2.2. Obtener el tipo de ropa sport preferido por el cliente/usuario.
- 2.3. Contar con una lista básica con lo que el cliente/usuario haya elegido al inicio para que de acuerdo a ello se genere las recomendaciones.
3. Filtrar la base de datos de la ropa sport según tipo de prenda preferido por el cliente/usuario.
4. Para cada ropa sport en la base de datos:
 - 4.1. Calcular la distancia euclidiana entre los gustos y preferencias de los clientes/usuarios y las características de la ropa:

$$\text{Distancia} = \text{sqr}((\text{mrc-row}(\text{mrc})^2 + (\text{tr-row}(\text{tr})^2 + (\text{c-row}(\text{c})^2 + (\text{di-row}(\text{di})^2 + (\text{ta-row}(\text{ta})^2 + (\text{pre-row}(\text{pre})^2 + (\text{fi-row}(\text{fi})^2 + (\text{gp-row}(\text{gp})^2 + (\text{tu-row}(\text{tu})^2 + (\text{nc-row}(\text{nc})^2 + (\text{ar-row}(\text{ar})^2 + (\text{ra-row}(\text{ra})^2 + (\text{g-row}(\text{g})^2 + (\text{e-row}(\text{e})^2 + (\text{u-row}(\text{u})^2 + (\text{ev-row}(\text{ev})^2 + (\text{cli-row}(\text{cli})^2 + (\text{up-row}(\text{up})^2 + (\text{pm-row}(\text{pm})^2)).$$
 - 4.2. Almacenar la distancia que se ha calculado junto con la selección de la ropa sport en la lista.
5. Ordenar la lista de ropa sport de acuerdo a la distancia euclidiana calculada que sea de mayor a menor.
6. Seleccionar las K ropa sport con distancias más cortas.
7. Brindar la lista de recomendaciones la cual está basada en K ropas sport más cercanas.

Explicación del Seudocódigo:

Definir K: Se debe definir el valor de K para este caso le daremos un valor de 3 por lo que nos quedaría $K=3$ eso significa que se realizará 3 recomendaciones de prendas sport a los clientes/usuarios con los gustos y preferencias similares a los que ellos dieron selección.

Obtener los gustos y preferencias del cliente/usuario: Recolectar información importante del cliente/usuario incluyendo sus propias características como los gustos y preferencias que este tenga sobre una prenda sport. Referente al paso 2.2, se debe captar los gustos y preferencias del cliente/usuario referente al tipo de ropa sport deseado (polos, pantalones, poleras, etc.). En el paso número 3 se empieza a realizar el filtro para dar limitaciones a la base de datos solo a la ropa sport que tengan coincidencia con el tipo seleccionado.

Calcular la distancia euclidiana: Para cada ropa sport se comparará las características de acuerdo a los gustos y preferencias de los clientes/usuarios. La fórmula de distancia euclidiana lo que hace es medir que tan lejos están los gustos y preferencias que tiene un cliente/usuario sobre una ropa sport que desea adquirir.

Ordenar las distancias: Cuando se haya realizado el cálculo de las distancias, la ropa sport se ordena de la más cercana a la más lejana y se toma las que tengan cercanía.

Seleccionar las K prendas sport más cercanas: Se toma las primeras K prendas sport, es decir, las que tienen menor distancia euclidiana.

Generar la recomendación: Las K prendas sport seleccionadas se muestran al adoptante como recomendaciones personalizadas.

Funcionalidades clave del sistema

El sistema de recomendación de prendas sport para la empresa Avalanch se fragmenta en dos grandes módulos: El módulo del administrador y el módulo del cliente.

Módulo del cliente:

Inscripción e inicio de sesión: El usuario/cliente se registra en el sistema para que pueda iniciar sesión en el sistema y de tal manera poder tener recomendaciones.

Preferencias de ropa sport: Se muestra opciones de elección muy similares al tiktok esto con la finalidad de romper el arranque en frío y tener datos importantes para sus primeras recomendaciones.

Generación de recomendaciones: El sistema de recomendación muestra la ropa sport que mejor de ajusten a los gustos y preferencias de los usuarios haciendo uso del algoritmo K-NN, mientras más navega por el sistema, este recolecta más información de tal manera que las recomendaciones son más precisas.

Solicitud de compra de ropa sport: Una vez que el usuario selecciona una ropa puede realizar la compra o adquisición pagando con tarjeta.

Módulo del Administrador:

Gestión de ropa sport: El administrador puede registrar ropa sport, registrar usuarios en el sistema de recomendación, actualizar, eliminar y visualizar las compras que hacen los clientes en el sistema.

Gestión de ventas: El administrador puede colocar precios, ofertas entre otros dentro del sistema de recomendación.

Gestión de reportes: El sistema permitirá tener reportes de las recomendaciones a cada cliente, las prendas disponibles y otra información relevante.

Diseño de la Base de Datos

La base de datos del sistema de recomendación para ropa sport esta implementada para almacenar usuarios/clientes que compraran ropa a la empresa, almacenar ropa sport, almacenar las recomendaciones para cada usuario/cliente, asegurando que las consultas y la comparación de los datos se realice adecuadamente. La base de datos cuenta con las siguientes tablas fundamentales:

Ventas: Almacena todos los datos de los clientes en donde se registra sus nombres, apellidos, prenda adquirida, etc.

Ropa sport: Contiene información relevante sobre las prendas como marca, tipo de ropa, color, precio, etc.

Recomendaciones: Se registra todas las recomendaciones realizadas a los clientes para que de esa manera se tenga data y poder enviar recomendaciones cada vez más precisas.

Requerimientos Técnicos

El sistema de recomendación de ropa sport para la empresa Avalanch está diseñado para ser amigable, accesible y eficiente refiriendo al punto de vista tecnológico en los requerimientos principales se muestran las siguientes:

Frontend: El sistema tendrá una interface de usuario amigable y accesible diseñada en HTML5, CSS3 y JavaScript. El sistema será responsive lo que ayudará a que los usuarios puedan ingresar con cualquier tipo de dispositivo.

Backend: El servidor se construirá en PHP, usando base de datos relacionales con es MySQL o PostgreSQL para lograr tener una mejor gestión de la información.

Algoritmo de Recomendación: Para la recomendación se utilizará el algoritmo K-NN será el ejecutor del sistema de recomendaciones.

CAPÍTULO IV: CONSTRUCCIÓN DE LA SOLUCIÓN

Especificación del caso de estudio

La empresa “Avalanch” se dedica a la comercialización de prendas de vestir en general, para todas las edades, ofrece una amplia variedad de colores, marcas, estilos y tallas, teniendo un enfoque en la atención al cliente dentro del local. En la actualidad, existen varios trabajadores que se dedican a la atención al cliente brindándole información previa, respondiendo a las dudas que este tenga respecto algún producto en específico ellos están al pendiente del cliente que llega a la tienda, para que este no salga sin comprar una prenda, aunque en algunas ocasiones el cliente no realiza ninguna compra, sin embargo, se ofrece un buen servicio en atención al cliente.

El cliente se acerca a la empresa “Avalanch” y lo primero que hace es buscar que prenda es de su agrado, como bien sabemos hoy en día existe diferentes diseños, colores, marcas, tallas, etc. Por lo que es tarea compleja decidir, en el caso de que el cliente encuentre lo que busca realiza la compra de lo contrario los vendedores empiezan a dar recomendaciones que se acerquen al gusto del cliente. La recomendación lo hace con la ayuda de catálogos, en donde los clientes pueden visualizar las prendas sport, el experto brinda información acerca de las prendas que tienen en venta, esta es la herramienta más utilizada por los expertos dentro de la empresa Avalanch.

Cuando el cliente realiza una compra el vendedor de la empresa Avalanch también realiza recomendaciones de otros productos por que debe de generar ventas siendo este el principal objetivo del experto, si bien es cierto, el vendedor realiza las recomendación en base a su experiencia, estas no siempre se personalizan para cada cliente, en muchos casos, no se cuenta con el historial de compras de los clientes, lo cual limita aún más la capacidad de poder ofrecer

sugerencias relevantes y atractivas, reduciendo de forma significativa la probabilidad de concretar ventas adicionales.

Para dar solución al problema de las recomendaciones y mejorar la experiencia de los clientes desde el primer contacto que tengan con el sistema, se implementará una estrategia basada en la selección inicial de intereses por partes de los clientes, lo cual permitirá superar el problema de la falta de información previa de los clientes acerca de sus preferencias. Al momento de ingresar al sistema, el cliente tendrá la oportunidad de elegir al menos tres categorías que tengan relación con sus gustos personales, tales como, tipo de prenda, estilo, marca o color: luego en base a esa selección se podrán generar las primeras recomendaciones personalizadas. A medida que el usuario siga interactuando con la plataforma, esta irá afinando las recomendaciones, mejorando de esa manera la precisión y aumentando las probabilidades de compra, lo que contribuye de forma directa al objetivo comercial de la tienda.

Adecuación del problema

Partiendo de lo descrito anteriormente, el algoritmo elegido para la presente investigación es el K vecinos más cercanos (KNN) debido a que el algoritmo muestra una mejor efectividad para realizar recomendaciones a un usuario, en el siguiente cuadro se especificará las variables que fueron descritas anteriormente para la construcción y funcionamiento del algoritmo KNN:

Tabla 3

Variables de entrada para el sistema de recomendación.

Variable	Factor	Dimensión	Descripción	Abreviatura
Prenda	Marca	Zara, Hio, Adidas, Element.	Fabricante o marca de la prenda.	V1
	Tipo de ropa	Polo, camisa, Pantalón, Chaqueta, Jogger, Blazer.	Tipo de prenda.	V2

Variable	Factor	Dimensión	Descripción	Abreviatura
Prenda	Color	Negro, Blanco, Azul, Rojo, Verde, etc.	Color predominante de la prenda.	V3
	Diseño	Liso, estampado, rayado, cuadros, minimalista, etc.	Estilo o diseño de la prenda.	V4
	Talla	XS, S, M, L, XL, XXL, etc.	Talla de la prenda.	V5
	Precio	Menos de 50 soles, 50-100 soles, 100-200 soles, más de 200 soles.	Rango de precio de la prenda.	V6
	Fibra	Algodón, Poliéster, Lycra, Mezcla sintética.	Material principal de la prenda.	V7
	Género de la prenda	Hombre, Mujer, Unisex.	Público al que está destinada la prenda	V8
	Temporada de uso	Verano, invierno, todo el año.	Clima recomendado para el uso.	V9
	Nivel de comodidad	Baja, Media, Alta.	Sensación de confort al usarla.	V10
	Ajuste de la ropa	Ajustado, Regular, Oversize.	Tipo de calce en el cuerpo.	V11
	Resistencia al agua	No resistente, Salpicaduras, Impermeable.	Protección contra la humedad.	V12
Cliente	Género	Hombre, Mujer, No especificado.	Género del cliente.	V13
	Edad	Mayores de edad.	Grupo de edad del cliente	V14
	Ubicación	Tarapoto, Moyobamba, Rioja, Nueva Cajamarca y alrededores.	Ciudad de residencia.	V15
	Estilo de vida	Activo, Casual, Deportivo, Elegante.	Estilo de vida y vestimenta.	V16
	Clima	Cálido, Templado. Frío.	Tipo de clima donde usará la ropa.	V17
	Uso principal	Diario, Entrenamiento, Competición. Casual.	Propósito de uso de la ropa.	V18
	Preferencia de marca	Sí, No.	Si el usuario tiene una marca favorita.	V19

Nota. Elaboración Propia.

Tabla 4*Variables de conocimiento*

Variable	Factor	Dimensión	Descripción	Abreviatura
Físicas	Ubicación de la empresa.	Nueva Cajamarca, Rioja, Sda. Jerusalén, alrededores.	Ciudad donde se encuentra la empresa.	VC1
	Categoría de ropa.	Sport, Casual, Urbana, etc.	Estilo principal de la prenda.	VC2
	Material principal.	Lino, cuero, Algodón.	Tipo de tejido o material predominante.	VC3
	Nivel de transpirabilidad.	Baja, media, alta.	Capacidad de ventilación del tejido.	VC4
	Color predominante.	Claro, oscuro, multicolor.	Tonalidad principal de la prenda.	VC5
	Género	Hombre, mujer, unisex.	Público al que está destinada la ropa.	VC6
	Rango de edad recomendado.	Adulto, adolescente, joven, adulto mayor.	Grupo de edad ideal para la ropa.	VC7
Conductuales	Estilo de la ropa.	Clásico, moderno, minimalista, extravagante.	Tipo de diseño que representa la ropa.	VC8
	Ocasión de uso.	Diario, oficina, eventos, salidas.	Situaciones en las que se suele usar la prenda.	VC9
	Temporada recomendada.	Verano, invierno, todo el año.	Estación en la que es más adecuada la prenda.	VC10
	Compatibilidad con otras prendas.	Fácil de combinar, difícil de combinar.	Versatilidad de la ropa con otras.	VC11
	Personalidad del cliente.	Sofisticado, relajado, atrevido, clásico.	Estilo de vida y personalidad del cliente.	VC12
	Nivel de exclusividad.	Edición limitada, alta costura, común.	Disponibilidad y exclusividad de la ropa.	VC13
	Tendencia de moda.	Clásico, en tendencia.	Actualización de la ropa con las tendencias.	VC14

Nota. Elaboración Propia.

Especificación de la solución

Concluyendo la identificación de las variables de entrada se realiza la conversión de los datos para que de esa manera el algoritmo K-NN pueda funcionar, las variables de entrada y las variables de conocimiento son cualitativas y el algoritmo K-NN solo puede trabajar con datos cuantitativos entonces se procede a convertir esos datos cualitativos a datos numéricos, a todo ese proceso se le denomina cuantificación como se puede observar en el siguiente cuadro.

En la tabla 5 se visualiza las variables de entrada para el sistema de recomendación de ropa sport planteado para el caso, estos datos se tienen que convertir a datos o valores numéricos que faciliten la lectura del sistema de recomendación.

Tabla 5

Conversión de la Tabla 3 (Variables de Entrada)

Variable	Valores cualitativos	Valores cuantificados
Marca	Zara, Hio, Adidas, Element	1,2,3,4
Tipo de ropa	Polo, camisa, Pantalón, Chaqueta, Jogger, Blazer	1,2,3,4,5,6
Color	Negro, Blanco, Azul, Rojo, Verde	1,2,3,4,5
Diseño	Sport, Playera, Deportiva	1,2,3
Talla	XS, S, M, L, XL, XXL	1,2,3,4,5,6
Precio	Menos de 50 soles, 50-100 soles, 100-200 soles, más de 200 soles	1,2,3,4
Fibra	Algodón, Poliéster, Lycra, Mezcla sintética	1,2,3,4
Género de la prenda	Hombre, Mujer, Unisex	1,2,3
Temporada de uso	Verano, invierno, todo el año	1,2,3
Nivel de comodidad	Baja, Media, Alta	1,2,3
Ajuste	Ajustado, Regular, Oversize	1,2,3
Resistencia al agua	No resistente, Salpicaduras, Impermeable	1,2,3
Género	Hombre, Mujer, No especificado	1,2,3
Edad	Mayores de edad	1

Variable	Valores cualitativos	Valores cuantificados
Ubicación	Tarapoto, Moyobamba, Rioja, Nueva Cajamarca, Sda. Jerusalén	1,2,3,4,5
Estilo de vida	Activo, Casual, Deportivo, Elegante	1,2,3,4
Clima	Cálido, Templado. Frío	1,2,3
Uso principal	Diario, Entrenamiento, Competición. Casual	1,2,3,4
Preferencia de marca	Sí, No	1,2

Nota. Elaboración Propia.

De la Tabla 5 se tiene la siguiente explicación:

Género: Los datos textuales (“Hombre”, “Mujer”, “No específico”) se transforman en 1, 2 y 3, respectivamente.

Ubicación: Cada ciudad se cuantifica con un valor único (ej. 1 para Tarapoto, 2 para Moyobamba, etc.).

Edad: Para esta variable se utiliza el valor numérico directo que el cliente ingresa.

Variables binarias: Para variables como “Nivel de comodidad” y “Ajuste” se cuantifican asignando un número único para cada opción.

La tabla 6 describe las características fenotípicas de las prendas de vestir. Al igual que las variables de entrada, estas características también deben cuantificarse.

Tabla 6*Conversión de la Tabla 4 (Variables de Conocimiento)*

Factor	Valores Cualitativos	Valores Cuantificados
Ubicación de la empresa.	Nueva Cajamarca, Rioja, Sda. Jerusalén	1,2,3
Categoría de ropa.	Sport, Casual, Urbana	1,2,3
Material principal.	Lino, cuero, Algodón	1,2,3
Nivel de transpirabilidad.	Baja, media, alta	1,2,3
Color predominante.	Claro, oscuro, multicolor	1,2,3
Género.	Hombre, mujer, unisex	1,2,3
Rango de edad recomendado.	Adulto, adolescente, joven, mayor	1,2,3,4
Estilo de la ropa.	Clásico, moderno, minimalista, extravagante	1,2,3,4
Ocasión de uso.	Diario, oficina, eventos, salidas	1,2,3,4
Temporada recomendada.	Verano, invierno, todo el año	1,2,3
Compatibilidad con otras prendas.	Fácil de combinar, difícil de combinar	1,2
Personalidad del usuario.	Sofisticado, relajado, atrevido, clásico	1,2,3,4
Nivel de exclusividad.	Edición limitada, alta costura, común	1,2,3
Tendencia de moda.	Clásico, en tendencia	1,2

Nota. Elaboración Propia.

La tabla 6 tiene la siguiente explicación:

Ubicación de la empresa: Las ubicaciones se cuantifican asignando un valor único (1 para nueva Cajamarca, 2 para rioja, etc.).

Categoría de ropa: “Sport” se convierte en 1, “Casual” en 2 y “Urbana” en 3.

Temporada recomendada: Se utilizan valores como 1,2 y 3 para “Verano”, “Invierno” y “Todo el año”, respectivamente.

VARIABLES BINARIAS: Las opciones “Sí” y “No” para “Tendencia en moda” se convierten en 1 y 2.

VARIABLES CATEGÓRICAS: Variables como “Genero” y “Nivel de exclusividad” también se cuantifican asignando un número único para cada categoría.

La relación entre las variables de entrada, que reflejan las preferencias y características del cliente, y las variables del conocimiento, que describen las características físicas y conductuales de la prenda de vestir, es clave para lograr un sistema de recomendación efectivo y personalizado. Este vínculo permite comparar aspectos esenciales como el estilo de ropa, temporada de uso y el material principal de la prenda con las preferencias del cliente, tales como su estilo de vida. Género y nivel de comodidad. Al establecer esta correspondencia entre las variables, el sistema puede identificar qué prendas de vestir son más adecuadas para cada cliente.

En la tabla a continuación se muestra cómo cada variable de entrada se relaciona con las características de la prenda de vestir, facilitando la recomendación más precisa y acorde a las necesidades de ambos.

Tabla 7

Relación entre las variables de entrada y las variables del conocimiento según su abreviatura

Variable de entrada	Variable del conocimiento
V1	VC13
V2	VC2
V3	VC5
V4	VC8
V5	VC7
V6	VC14
V7	VC3
V8	VC6

Variable de entrada	Variable del conocimiento
V9	VC3
V10	VC9
V11	VC2
V12	VC4
V13	VC6
V14	VC10
V15	VC9
V16	VC12
V17	VC1
V18	VC11
V19	VC13

Nota. Elaboración Propia

La tabla 8 se presenta datos cualitativos de 20 prendas sport registradas en la empresa Avalanch, la conversión a valores cuantitativos se observa en la tabla 9.

Tabla 8*Prendas Registradas*

Prenda de vestir	Ubicación de la empresa	Categoría de ropa	Material Principal	Nivel de transpirabilidad	Color	Genero	Rango de edad	Estilo de ropa	Ocasión de uso	Temporada recomendada	Compatibilidad	Personalidad	Nivel de exclusividad	Tendencia de moda
Polo	Nueva Cajamarca	Casual	Algodón	Alta	Claro	Hombre	Joven	Clásico	Diario	Verano	Fácil de combinar	Relajado	Común	En tendencia
Camisa	Rioja	Urbana	Lino	Media	Oscuro	Mujer	Adulto	Moderno	Oficina	Todo el año	Difícil de combinar	Sofisticado	Alta costura	Clásico
Jogger	Segunda Jerusalén	Sport	Algodón	Alta	Multicolor	Unisex	Adolescente	Minimalista	Salidas	Verano	Fácil de combinar	Atrevido	Edición limitada	En tendencia
Blazer	Rioja	Casual	Cuero	Baja	Oscuro	Hombre	Adulto	Clásico	Eventos	Invierno	Difícil de combinar	Clásico	Alta costura	Clásico
Pantalón	Nueva Cajamarca	Urbana	Algodón	Media	Claro	Mujer	Mayor	Moderno	Diario	Todo el año	Fácil de combinar	Relajado	Común	En tendencia
Chaqueta	Segunda Jerusalén	Sport	Cuero	Baja	Oscuro	Unisex	Adolescente	Extravagante	Salidas	Invierno	Difícil de combinar	Atrevido	Edición limitada	En tendencia
Polo	Rioja	Urbana	Algodón	Alta	Multicolor	Hombre	Joven	Minimalista	Diario	Verano	Fácil de combinar	Clásico	Común	En tendencia
Camisa	Nueva Cajamarca	Casual	Lino	Media	Claro	Mujer	Adulto	Clásico	Oficina	Todo el año	Fácil de combinar	Sofisticado	Alta costura	Clásico
Jogger	Segunda Jerusalén	Sport	Algodón	Alta	Oscuro	Unisex	Adolescente	Moderno	Salidas	Verano	Fácil de combinar	Relajado	Común	En tendencia
Blazer	Rioja	Urbana	Cuero	Baja	Claro	Mujer	Mayor	Extravagante	Eventos	Invierno	Difícil de combinar	Atrevido	Edición limitada	Clásico
Pantalón	Nueva Cajamarca	Casual	Algodón	Media	Oscuro	Hombre	Adulto	Clásico	Oficinas	Todo el año	Fácil de combinar	Clásico	Común	Clásico
Chaqueta	Rioja	Sport	Cuero	Baja	Claro	Mujer	Joven	Moderno	Salidas	Invierno	Difícil de combinar	Sofisticado	Alta costura	En tendencia
Polo	Segunda Jerusalén	Urbana	Algodón	Alta	Multicolor	Unisex	Adolescente	Extravagante	Diario	Verano	Fácil de combinar	Atrevido	Edición limitada	En tendencia
Camisa	Nueva Cajamarca	Casual	Lino	Media	Claro	Hombre	Adulto	Moderno	Oficina	Todo el año	Fácil de combinar	Relajado	Común	Clásico
Jogger	Rioja	Sport	Algodón	Alta	Oscuro	Mujer	Adolescente	Minimalista	Salidas	Verano	Fácil de combinar	Clásico	Común	En tendencia
Blazer	Segunda Jerusalén	Urbana	Cuero	Baja	Multicolor	Hombre	Joven	Extravagante	Eventos	Invierno	Difícil de combinar	Atrevido	Alta costura	Clásico
Pantalón	Nueva Cajamarca	Urbana	Algodón	Media	Claro	Unisex	Adulto	Clásico	Oficina	Todo el año	Fácil de combinar	Relajado	Común	En tendencia
Chaqueta	Rioja	Casual	Cuero	Baja	Oscuro	Mujer	Adolescente	Moderno	Salidas	Invierno	Difícil de combinar	Sofisticado	Edición limitada	Clásico

Prenda de vestir	Ubicación de la empresa	Categoría de ropa	Material Principal	Nivel de transpirabilidad	Color	Genero	Rango de edad	Estilo de ropa	Ocasión de uso	Temporada recomendada	Compatibilidad	Personalidad	Nivel de exclusividad	Tendencia de moda
Polo	Segunda Jerusalén	Sport	Algodón	Alta	Claro	Hombre	Joven	Minimalista	Diario	Verano	Fácil de combinar	Clásico	Común	En tendencia
Camisa	Nueva Cajamarca	Urbana	Lino	Media	Oscuro	Mujer	Adulto	Clásico	Oficina	Todo el año	Fácil de combinar	Sofisticado	Alta costura	Clásico

Nota. Elaboración propia

Tabla 9

Prendas disponibles datos cuantificados

Prenda de vestir	Ubicación de la empresa	Categoría de ropa	Material Principal	Nivel de transpirabilidad	Color	Genero	Rango de edad	Estilo de ropa	Ocasión de uso	Temporada recomendada	Compatibilidad	Personalidad	Nivel de exclusividad	Tendencia de moda
Polo	1	2	3	3	1	1	3	1	1	1	1	2	3	2
Camisa	2	3	1	2	2	2	1	2	2	3	2	1	2	1
Jogger	3	1	3	3	3	3	2	3	4	1	1	3	1	2
Blazer	2	2	2	1	2	1	1	1	3	2	2	4	2	1
Pantalón	1	3	3	2	1	2	4	2	1	3	1	2	3	2
Chaqueta	3	1	2	1	2	3	2	4	4	2	2	3	1	2
Polo	2	3	3	3	3	1	3	3	1	1	1	4	3	2
Camisa	1	2	1	2	1	2	1	1	2	3	1	1	2	1
Jogger	3	1	3	3	2	3	2	2	4	1	1	2	3	2
Blazer	2	3	2	1	1	2	4	4	3	2	2	3	1	1
Pantalón	1	2	3	2	2	1	1	1	2	3	1	4	3	1
Chaqueta	2	1	2	1	1	2	3	2	4	2	2	1	2	2
Polo	3	3	3	3	3	3	2	4	1	1	1	3	1	2
Camisa	1	2	1	2	1	1	1	2	2	3	1	2	3	1
Jogger	2	1	3	3	2	2	2	3	4	1	1	4	3	2
Blazer	3	3	2	1	3	1	3	4	3	2	2	3	2	1
Pantalón	1	3	3	2	1	3	1	1	2	3	1	2	3	2
Chaqueta	2	2	2	1	2	2	2	2	4	2	2	1	1	1

Prenda de vestir	Ubicación de la empresa	Categoría de ropa	Material Principal	Nivel de transpirabilidad	Color	Genero	Rango de edad	Estilo de ropa	Ocasión de uso	Temporada recomendada	Compatibilidad	Personalidad	Nivel de exclusividad	Tendencia de moda
Polo	3	1	3	3	1	1	3	3	1	1	1	4	3	2
Camisa	1	3	1	2	2	2	1	1	2	3	1	1	2	1

Nota. Elaboración Propia.

Ejecución de la solución

La solución se realizará usando el algoritmo KNN- vecinos más cercanos en donde se detallará el funcionamiento del algoritmo y se ingresará datos para verificar el resultado. En la Tabla 10 se muestra una posible base de datos, en este caso estará compuesta por cincuenta datos con todas las variables que fueron identificados las cuales permitirán ejecutar el algoritmo e identificar que recomendación brindar a un usuario.

Tabla 10*Base de datos de las prendas con 50 registros*

N	Marca	Tipo de Prenda	Precio	Color	Diseño Prenda	Talla	Fibra	Género de la prenda	Tempo.	Nivel de confort	Ajuste	Resistencia al agua	Género	Edad	Ubicación	Estilo de vida	Clima	Uso principal	Preferencia de Marca
1	Element	Pantalón	150.00	Celeste	Sport	32	Seda	Hombre	Invierno	Baja	Ajustado	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Casual	Templado	Casual	Sí
2	Bronco	Pantalón	150.00	Negro	Sport	32	Seda	Hombre	Verano	Media	Regular	No resistente	Hombre	Mayor	Nueva Cajamarca	Elegante	Cálido	Entrenamiento	No
3	Gzuck	Polo	90.00	Verde	Playera	XL	Algodón	Hombre	Todo el año	Alta	Oversize	Impermeable	Hombre	Mayor	Nueva Cajamarca	Deportivo	Frío	Diario	Sí
4	Butrich	Polo	100.00	Blanco	Playera	S	Algodón	Hombre	Verano	Media	Regular	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Activo	Templado	Competición	No
5	Gucci	Short	120.00	Rosa	Deportivo	L	Acrílico	Hombre	Invierno	Baja	Ajustado	Impermeable	Hombre	Mayor	Nueva Cajamarca	Casual	Cálido	Casual	Sí
6	Fendi	Short	90.00	Verde	Deportivo	S	Algodón	Hombre	Todo el año	Alta	Oversize	No resistente	Hombre	Mayor	Nueva Cajamarca	Elegante	Frío	Diario	Sí
7	Givenchy	Polera	120.00	Crema	Sport	M	Algodón	Hombre	Verano	Media	Regular	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Deportivo	Templado	Entrenamiento	No
8	Balmain	Polera	120.00	Militar	Sport	L	Algodón	Hombre	Verano	Baja	Ajustado	Impermeable	Hombre	Mayor	Nueva Cajamarca	Activo	Frío	Competición	No
9	Billabong	Polo	80.00	Blanco	Deportivo	S	Algodón	Unisex	Invierno	Alta	Oversize	No resistente	No especificado	Mayor	Nueva Cajamarca	Casual	Cálido	Casual	Sí
10	Kappa	Polo	170.00	Naranja	Deportivo	S	Algodón	Unisex	Todo el año	Media	Regular	Salpicaduras	No especificado	Mayor	Nueva Cajamarca	Elegante	Templado	Diario	No
11	Boss	Polo	90.00	Morado	Playera	M	Algodón	Unisex	Invierno	Alta	Oversize	No resistente	No especificado	Mayor	Nueva Cajamarca	Deportivo	Frío	Competición	Sí
12	Boss	Pantalón	250.00	Negro	Sport	34	Seda	Hombre	Verano	Baja	Ajustado	Impermeable	Hombre	Mayor	Nueva Cajamarca	Activo	Cálido	Entrenamiento	No
13	Boss	Pantalón	200.00	Celeste	Sport	30	Seda	Unisex	Todo el año	Media	Regular	Salpicaduras	No especificado	Mayor	Nueva Cajamarca	Casual	Templado	Casual	Sí
14	Rip Curl	Bermuda	80.00	Azul	Sport	S	Seda	Unisex	Verano	Alta	Oversize	No resistente	No especificado	Mayor	Nueva Cajamarca	Elegante	Cálido	Diario	No
15	Rip Curl	Bermuda	80.00	Verde	Sport	S	Seda	Hombre	Invierno	Baja	Ajustado	Impermeable	Hombre	Mayor	Nueva Cajamarca	Deportivo	Frío	Entrenamiento	Sí

N	Marca	Tipo de Prenda	Precio	Color	Diseño Prenda	Talla	Fibra	Género de la prenda	Tempo.	Nivel de confort	Ajuste	Resistencia al agua	Género	Edad	Ubicación	Estilo de vida	Clima	Uso principal	Preferencia de Marca
16	Rip Curl	Short	80.00	Negro	Deportivo	S	Acrílico	Unisex	Verano	Media	Regular	Salpicaduras	No especificado	Mayor	Nueva Cajamarca	Activo	Templado	Competición	Sí
17	Rip Curl	Short	50.00	Gris	Deportivo	M	Acrílico	Unisex	Todo el año	Alta	Oversize	No resistente	No especificado	Mayor	Nueva Cajamarca	Casual	Frío	Casual	No
18	Rip Curl	Bermuda	50.00	Rosa	Sport	M	Lino	Unisex	Invierno	Baja	Ajustado	Impermeable	No especificado	Mayor	Nueva Cajamarca	Elegante	Cálido	Entrenamiento	Sí
19	Denim	Bermuda	100.00	Rojo	Sport	M	Lino	Hombre	Verano	Media	Regular	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Deportivo	Templado	Diario	No
20	Denim	Pantalón	120.00	Azul	Sport	28	Seda	Unisex	Todo el año	Alta	Oversize	Impermeable	No especificado	Mayor	Nueva Cajamarca	Activo	Frío	Competición	Sí
21	Denim	Pantalón	150.00	Celeste	Sport	30	Seda	Unisex	Verano	Media	Regular	No resistente	No especificado	Mayor	Nueva Cajamarca	Casual	Cálido	Entrenamiento	No
22	Denim	Pantalón	300.00	Celeste	Sport	30	Seda	Unisex	Invierno	Alta	Oversize	Salpicaduras	No especificado	Mayor	Nueva Cajamarca	Elegante	Frío	Casual	Sí
23	Denim	Pantalón	250.00	Negro	Sport	32	Seda	Unisex	Todo el año	Baja	Ajustado	Impermeable	No especificado	Mayor	Nueva Cajamarca	Deportivo	Templado	Competición	Sí
24	Denim	Pantalón	150.00	Gris	Sport	32	Seda	Unisex	Verano	Media	Regular	No resistente	No especificado	Mayor	Nueva Cajamarca	Activo	Cálido	Diario	No
25	Denim	Pantalón	120.00	Blanco	Sport	32	Seda	Unisex	Todo el año	Alta	Oversize	Salpicaduras	No especificado	Mayor	Nueva Cajamarca	Casual	Frío	Entrenamiento	No
26	Denim	Jogger	150.00	Gris	Sport	M	Algodón	Hombre	Invierno	Baja	Ajustado	No resistente	Hombre	Mayor	Nueva Cajamarca	Elegante	Templado	Casual	Sí
27	Denim	Jogger	120.00	Negro	Sport	M	Algodón	Hombre	Verano	Media	Regular	Impermeable	Hombre	Mayor	Nueva Cajamarca	Deportivo	Cálido	Competición	No
28	Denim	Jogger	120.00	Blanco	Sport	S	Algodón	Hombre	Invierno	Alta	Oversize	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Activo	Frío	Diario	Sí
29	Denim	Jogger	120.00	Morad o	Sport	L	Algodón	Hombre	Todo el año	Baja	Ajustado	No resistente	Hombre	Mayor	Nueva Cajamarca	Casual	Templado	Casual	No
30	Adidas	Jogger	170.00	Morad o	Sport	L	Algodón	Hombre	Verano	Media	Regular	Impermeable	Hombre	Mayor	Nueva Cajamarca	Elegante	Frío	Entrenamiento	Sí

N	Marca	Tipo de Prenda	Precio	Color	Diseño Prenda	Talla	Fibra	Género de la prenda	Tempo.	Nivel de confort	Ajuste	Resistencia al agua	Género	Edad	Ubicación	Estilo de vida	Clima	Uso principal	Preferencia de Marca
31	Adidas	Jogger	150.00	Azul	Sport	L	Algodón	Hombre	Invierno	Alta	Oversize	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Deportivo	Cálido	Competición	Sí
32	Adidas	Pantalón	170.00	Celeste	Sport	30	Seda	Hombre	Todo el año	Media	Regular	Impermeable	Hombre	Mayor	Nueva Cajamarca	Activo	Templado	Diario	No
33	Adidas	Jogger	150.00	Marrón	Sport	XL	Algodón	Unisex	Verano	Baja	Ajustado	No resistente	No especificado	Mayor	Nueva Cajamarca	Casual	Cálido	Casual	Sí
34	Adidas	Pantalón	250.00	Negro	Sport	34	Seda	Unisex	Verano	Alta	Oversize	Salpicaduras	No especificado	Mayor	Nueva Cajamarca	Elegante	Frío	Entrenamiento	No
35	Pioner	Jogger	200.00	Gris	Sport	L	Algodón	Unisex	Invierno	Media	Regular	Impermeable	No especificado	Mayor	Nueva Cajamarca	Deportivo	Templado	Competición	Sí
36	Pioner	Pantalón	250.00	Negro	Sport	30	Seda	Unisex	Todo el año	Alta	Oversize	No resistente	No especificado	Mayor	Nueva Cajamarca	Activo	Frío	Diario	Sí
37	Pioner	Polo	90.00	Azul	Playera	S	Lino	Unisex	Verano	Baja	Ajustado	Salpicaduras	No especificado	Mayor	Nueva Cajamarca	Casual	Cálido	Entrenamiento	No
38	Pioner	Polo	90.00	Verde	Playera	S	Lino	Unisex	Invierno	Media	Regular	Impermeable	No especificado	Mayor	Nueva Cajamarca	Elegante	Templado	Casual	No
39	Pioner	Polo	50.00	Blanco	Deportivo	S	Algodón	Hombre	Todo el año	Alta	Oversize	No resistente	Hombre	Mayor	Nueva Cajamarca	Deportivo	Cálido	Competición	Sí
40	Pioner	Polo	90.00	Rojo	Deportivo	S	Algodón	Hombre	Verano	Baja	Ajustado	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Activo	Frío	Diario	No
41	Element	Polo	80.00	Rosa	Sport	M	Algodón	Hombre	Todo el año	Media	Regular	No resistente	Hombre	Mayor	Nueva Cajamarca	Casual	Templado	Entrenamiento	Sí
42	Element	Polera	80.00	Azul	Sport	M	Algodón	Hombre	Invierno	Alta	Oversize	Impermeable	Hombre	Mayor	Nueva Cajamarca	Elegante	Frío	Casual	No
43	Element	Polera	80.00	Militar	Sport	M	Algodón	Hombre	Verano	Baja	Ajustado	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Deportivo	Cálido	Competición	Sí
44	Element	Polo	120.00	Blanco	Playera	S	Algodón	Hombre	Todo el año	Media	Regular	No resistente	Hombre	Mayor	Nueva Cajamarca	Activo	Templado	Diario	No
45	Gzuck	Polo	120.00	Azul	Playera	S	Algodón	Hombre	Invierno	Alta	Oversize	Impermeable	Hombre	Mayor	Nueva Cajamarca	Casual	Frío	Entrenamiento	Sí

N	Marca	Tipo de Prenda	Precio	Color	Diseño Prenda	Talla	Fibra	Género de la prenda	Tempo.	Nivel de confort	Ajuste	Resistencia al agua	Género	Edad	Ubicación	Estilo de vida	Clima	Uso principal	Preferencia de Marca
46	Gzuck	Polera	90.00	Celeste	Sport	S	Algodón	Hombre	Verano	Media	Regular	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Elegante	Cálido	Casual	Sí
47	Element	Pantalón	150.00	Celeste	Sport	28	Seda	Hombre	Invierno	Alta	Oversize	Impermeable	Hombre	Mayor	Nueva Cajamarca	Deportivo	Frío	Competición	No
48	Element	Pantalón	120.00	Azul	Sport	30	Seda	Hombre	Todo el año	Baja	Ajustado	No resistente	Hombre	Mayor	Nueva Cajamarca	Activo	Templado	Diario	No
49	Adidas	Polera	90.00	Rojo	Sport	S	Algodón	Hombre	Verano	Media	Regular	Salpicaduras	Hombre	Mayor	Nueva Cajamarca	Casual	Cálido	Casual	Sí
50	Adidas	Short	50.00	Verde	Deportivo	M	Seda	Hombre	Invierno	Alta	Oversize	Impermeable	Hombre	Mayor	Nueva Cajamarca	Elegante	Frío	Entrenamiento	No

Nota. Elaboración Propia.

Una vez creada la base de datos se procede a ponderar valores numéricos a todas las marcas, tipo de prenda de vestir, color, diseño de la prenda, talla, fibra, como podemos notar la variable precio no ingresa debido a que ya es un valor numérico, este procedimiento se realiza para poder ejecutar la fórmula de la distancia euclidiana, el cual permite identificar qué valor es el más cercano a lo que se desea encontrar, a continuación, se muestra la Tabla 11, el resto de datos se complementan de la Tabla 5, en donde se encuentran los valores numéricos por cada variable.

Tabla 11*Conversión a valores numéricos*

Valor	Marca	Valor	Tipo de Prenda	Valor	Color	Valor	Diseño Prenda	Valor	Talla	Valor	Fibra
1	Element	1	Pantalón	1	Celeste	1	Sport	1	32	1	Algodón
2	Bronco	2	Polo	2	Negro	2	Playera	2	XL	2	Lino
3	Gzuck	3	Short	3	Verde	3	Deportivo	3	S	3	Lana
4	Butrich	4	Polera	4	Blanco			4	L	4	Seda
5	Gucci	5	Bermuda	5	Rosa			5	M	5	Acrílico
6	Fendi	6	Jogger	6	Crema			6	34		
7	Givenchy			7	Militar			7	30		
8	Balmain			8	Naranja			8	28		
9	Billabong			9	Morado						
10	Kappa			10	Azul						
11	Boss			11	Gris						
12	Rip Curl			12	Rojo						
13	Denim			13	Marrón						
14	Adidas										
15	Pioner										

Nota: Elaboración Propia

Una vez realizado el ponderado se procede a cambiar todos los valores de la base de datos a valores numéricos esto con la ayuda de la Tabla 11 el cual permitirá validar la base de datos general, a continuación, se muestra la Tabla 12 en donde se aprecia la base de datos completamente con valores numéricos:

Tabla 12

Base de datos convertido a valores numéricos

Marca	Tipo de Prenda	Precio	Color	Diseño Prenda	Talla	Fibra	Género de la prenda	Temporada de uso	Nivel de confort	Ajuste	Resistencia al agua	Género	Edad	Ubicación	Estilo de vida	Clima	Uso principal	Preferencia de marca
1	1	150.00	1	1	32	4	1	2	1	1	2	1	1	4	2	2	4	1
2	1	150.00	2	1	32	4	1	1	2	2	1	1	1	4	4	1	2	2
3	2	90.00	3	2	1	1	1	3	3	3	3	1	1	4	3	3	1	1
4	2	100.00	4	2	2	1	1	1	2	2	2	1	1	4	1	2	3	2
5	3	120.00	5	3	3	5	1	2	1	1	3	1	1	4	2	1	4	1
6	3	90.00	3	3	2	1	1	3	3	3	1	1	1	4	4	3	1	1
7	4	120.00	6	1	4	1	1	1	2	2	2	1	1	4	3	2	2	2
8	4	120.00	7	1	3	1	1	1	1	1	3	1	1	4	1	3	3	2
9	2	80.00	4	3	2	1	3	2	3	3	1	3	1	4	2	1	4	1
10	2	170.00	8	3	2	1	3	3	2	2	2	3	1	4	4	2	1	2
11	2	90.00	9	2	4	1	3	2	3	3	1	3	1	4	3	3	3	1
11	1	250.00	2	1	34	4	1	1	1	1	3	1	1	4	1	1	2	2
11	1	200.00	1	1	30	4	3	3	2	2	2	3	1	4	2	2	4	1
12	5	80.00	10	1	2	4	3	1	3	3	1	3	1	4	4	1	1	2
12	5	80.00	3	1	2	4	1	2	1	1	3	1	1	4	3	3	2	1
12	3	80.00	2	3	2	5	3	1	2	2	2	3	1	4	1	2	3	1
12	3	50.00	11	3	4	5	3	3	3	3	1	3	1	4	2	3	4	2
12	5	50.00	5	1	4	2	3	2	1	1	3	3	1	4	4	1	2	1
13	5	100.00	12	1	4	2	1	1	2	2	2	1	1	4	3	2	1	2
13	1	120.00	10	1	28	4	3	3	3	3	3	3	1	4	1	3	3	1
13	1	150.00	1	1	30	4	3	1	2	2	1	3	1	4	2	1	2	2
13	1	300.00	1	1	30	4	3	2	3	3	2	3	1	4	4	3	4	1
13	1	250.00	2	1	32	4	3	3	1	1	3	3	1	4	3	2	3	1
13	1	150.00	11	1	32	4	3	1	2	2	1	3	1	4	1	1	1	2
13	1	120.00	4	1	32	4	3	3	3	3	2	3	1	4	2	3	2	2
13	6	150.00	11	1	4	1	1	2	1	1	1	1	1	4	4	2	4	1
13	6	120.00	2	1	4	1	1	1	2	2	3	1	1	4	3	1	3	2
13	6	120.00	4	1	2	1	1	2	3	3	2	1	1	4	1	3	1	1
13	6	120.00	9	1	3	1	1	3	1	1	1	1	1	4	2	2	4	2

Marca	Tipo de Prenda	Precio	Color	Diseño Prenda	Talla	Fibra	Género de la prenda	Temporada de uso	Nivel de confort	Ajuste	Resistencia al agua	Género	Edad	Ubicación	Estilo de vida	Clima	Uso principal	Preferencia de marca
14	6	170.00	9	1	3	1	1	1	2	2	3	1	1	4	4	3	2	1
14	6	150.00	10	1	3	1	1	2	3	3	2	1	1	4	3	1	3	1
14	1	170.00	1	1	30	4	1	3	2	2	3	1	1	4	1	2	1	2
14	6	150.00	13	1	1	1	3	1	1	1	1	3	1	4	2	1	4	1
14	1	250.00	2	1	34	4	3	1	3	3	2	3	1	4	4	3	2	2
15	6	200.00	11	1	3	1	3	2	2	2	3	3	1	4	3	2	3	1
15	1	250.00	2	1	30	4	3	3	3	3	1	3	1	4	1	3	1	1
15	2	90.00	10	2	2	2	3	1	1	1	2	3	1	4	2	1	2	2
15	2	90.00	3	2	2	2	3	2	2	2	3	3	1	4	4	2	4	2
15	2	50.00	4	3	2	1	1	3	3	3	1	1	1	4	3	1	3	1
15	2	90.00	12	3	2	1	1	1	1	1	2	1	1	4	1	3	1	2
1	2	80.00	5	1	4	1	1	3	2	2	1	1	1	4	2	2	2	1
1	4	80.00	10	1	4	1	1	2	3	3	3	1	1	4	4	3	4	2
1	4	80.00	7	1	4	1	1	1	1	1	2	1	1	4	3	1	3	1
1	2	120.00	4	2	2	1	1	3	2	2	1	1	1	4	1	2	1	2
3	2	120.00	10	2	2	1	1	2	3	3	3	1	1	4	2	3	2	1
3	4	90.00	1	1	2	1	1	1	2	2	2	1	1	4	4	1	4	1
1	1	150.00	1	1	28	4	1	2	3	3	3	1	1	4	3	3	3	2
1	1	120.00	10	1	30	4	1	3	1	1	1	1	1	4	1	2	1	2
14	4	90.00	12	1	2	1	1	1	2	2	2	1	1	4	2	1	4	1
14	3	50.00	3	3	4	4	1	2	3	3	3	1	1	4	4	3	2	2

Nota. Elaboración Propia.

Una vez teniendo la base de datos con variables cuantitativas se procede a realizar un ejemplo de recomendación. En este caso un cliente desea que se le recomiende un polo de acuerdo a sus gustos y preferencias, para ello el cliente brinda las siguientes especificaciones que ayudarán a generar la recomendación correspondiente.

Tabla 13

Especificaciones del usuario

Factor	Valores Cualitativos	Valores Cuantificados
Ubicación de la empresa	Nueva Cajamarca	1
Categoría de ropa	Casual	2
Material principal	Algodón	3
Nivel de transpirabilidad	Baja	1
Color predominante	Claro	1
Género	Hombre	1
Rango de edad recomendado	Joven	3
Estilo de la ropa	Moderno	2
Ocasión de uso	Diario	1
Temporada recomendada	Verano	1
Compatibilidad con otras prendas	Fácil de combinar	1
Personalidad del usuario	Relajado	2
Nivel de exclusividad	Común	3
Tendencia de moda	En tendencia	2

Nota. Elaboración Propia.

Para poder optimizar el proceso de la recomendación, el sistema realiza un filtrado inicial de acuerdo a los requerimientos de prendas de vestir deseados por el cliente. En este caso, el cliente especifica que desea adquirir un polo, el sistema seleccionará únicamente las prendas de vestir que este solicita para poder realizar el cálculo de las distancias euclidianas.

Una vez obtenido los datos con las características de la prenda de vestir y características del cliente, y tras la conversión de los datos cualitativos en cuantitativos, se procede a realizar el cálculo de la similitud mediante la fórmula de la distancia euclidiana que será la siguiente:

$$Distancia = \sqrt{(V1 - VC1)^2 + (V3 - VC9)^2 + \dots + (V17 - VC15)^2}$$

A continuación, se mostrará un ejemplo del cálculo de la distancia euclidiana para el cliente, teniendo en consideración que a selecciona el tipo de prenda de vestir que desea comprar.

La Tabla 14 muestra el cálculo euclidiano que se realizó para la generación de recomendación a un usuario quien brindó algunas especificaciones sobre sus preferencias de una prenda de vestir, a continuación, se muestra el resultado de la ejecución del cálculo de la distancia euclidiana:

Tabla 14

Resultado del cálculo de la distancia euclidiana

N.º	Marca		Distancia euclidiana
4	Butrich	$\sqrt{(4-3)^2 + (2-2)^2 + (4-1)^2 + (2-2)^2 + (3-3)^2 + (2-2)^2 + (1-3)^2 + (1-1)^2 + (1-3)^2 + (2-1)^2 + (2-2)^2 + (2-1)^2 + (1-1)^2 + (1-1)^2 + (4-1)^2 + (1-2)^2 + (2-1)^2 + (3-1)^2 + (2-3)^2}$	6.08
3	Gzuck	$\sqrt{(3-3)^2 + (2-2)^2 + (3-1)^2 + (2-2)^2 + (2-3)^2 + (2-2)^2 + (1-3)^2 + (1-1)^2 + (3-3)^2 + (3-1)^2 + (3-2)^2 + (3-1)^2 + (1-1)^2 + (1-1)^2 + (4-1)^2 + (3-2)^2 + (3-1)^2 + (1-1)^2 + (1-3)^2}$	6.00000
11	Boss	$\sqrt{(11-3)^2 + (2-2)^2 + (9-1)^2 + (2-2)^2 + (5-3)^2 + (2-2)^2 + (1-3)^2 + (3-1)^2 + (2-3)^2 + (3-1)^2 + (3-2)^2 + (1-1)^2 + (3-1)^2 + (1-1)^2 + (4-1)^2 + (3-2)^2 + (3-1)^2 + (3-1)^2 + (1-3)^2}$	13.114
38	Pioner	$\sqrt{(15-3)^2 + (2-2)^2 + (3-1)^2 + (2-2)^2 + (3-3)^2 + (2-2)^2 + (2-3)^2 + (3-1)^2 + (2-3)^2 + (2-1)^2 + (2-2)^2 + (3-1)^2 + (3-1)^2 + (1-1)^2 + (4-1)^2 + (4-2)^2 + (2-1)^2 + (4-1)^2 + (2-3)^2}$	13.6748
37	Pioner	$\sqrt{(15-3)^2 + (2-2)^2 + (10-1)^2 + (2-2)^2 + (3-3)^2 + (2-2)^2 + (2-3)^2 + (3-1)^2 + (1-3)^2 + (1-1)^2 + (1-2)^2 + (2-1)^2 + (3-1)^2 + (1-1)^2 + (4-1)^2 + (2-2)^2 + (1-1)^2 + (2-1)^2 + (2-3)^2}$	15.84298
40	Pioner	$\sqrt{(15-3)^2 + (2-2)^2 + (12-1)^2 + (3-2)^2 + (3-3)^2 + (2-2)^2 + (1-3)^2 + (1-1)^2 + (1-3)^2 + (1-1)^2 + (1-2)^2 + (2-1)^2 + (1-1)^2 + (1-1)^2 + (4-1)^2 + (1-2)^2 + (3-1)^2 + (1-1)^2 + (2-3)^2}$	17.06
44	Element	$\sqrt{(1-3)^2 + (2-2)^2 + (4-1)^2 + (2-2)^2 + (3-3)^2 + (3-2)^2 + (1-3)^2 + (1-1)^2 + (3-3)^2 + (2-1)^2 + (2-2)^2 + (1-1)^2 + (1-1)^2 + (1-1)^2 + (4-1)^2 + (1-2)^2 + (2-1)^2 + (1-1)^2 + (2-3)^2}$	5.57
41	Element	$\sqrt{(1-3)^2 + (2-2)^2 + (5-1)^2 + (1-2)^2 + (5-3)^2 + (2-2)^2 + (1-3)^2 + (1-1)^2 + (3-3)^2 + (2-1)^2 + (2-2)^2 + (1-1)^2 + (1-1)^2 + (1-1)^2 + (4-1)^2 + (2-2)^2 + (2-1)^2 + (2-1)^2 + (1-3)^2}$	6.71
9	Billabong	$\sqrt{(9-3)^2 + (2-2)^2 + (4-1)^2 + (3-2)^2 + (3-3)^2 + (2-2)^2 + (1-3)^2 + (3-1)^2 + (2-3)^2 + (3-1)^2 + (3-2)^2 + (1-1)^2 + (3-1)^2 + (1-1)^2 + (4-1)^2 + (2-2)^2 + (1-1)^2 + (4-1)^2 + (1-3)^2}$	9.27
45	Gzuck	$\sqrt{(3-3)^2 + (2-2)^2 + (10-1)^2 + (2-2)^2 + (3-3)^2 + (2-2)^2 + (1-3)^2 + (1-1)^2 + (2-3)^2 + (3-1)^2 + (3-2)^2 + (3-1)^2 + (1-1)^2 + (1-1)^2 + (4-1)^2 + (2-2)^2 + (3-1)^2 + (2-1)^2 + (1-3)^2}$	10.63
39	Pioner	$\sqrt{(15-3)^2 + (2-2)^2 + (4-1)^2 + (3-2)^2 + (3-3)^2 + (2-2)^2 + (1-3)^2 + (1-1)^2 + (3-3)^2 + (3-1)^2 + (3-2)^2 + (1-1)^2 + (1-1)^2 + (1-1)^2 + (4-1)^2 + (3-2)^2 + (1-1)^2 + (3-1)^2 + (1-3)^2}$	13.45
10	Kappa	$\sqrt{(10-3)^2 + (2-2)^2 + (8-1)^2 + (3-2)^2 + (3-3)^2 + (3-2)^2 + (1-3)^2 + (3-1)^2 + (3-3)^2 + (2-1)^2 + (2-2)^2 + (2-1)^2 + (3-1)^2 + (1-1)^2 + (4-1)^2 + (4-2)^2 + (2-1)^2 + (1-1)^2 + (2-3)^2}$	11.36

Nota. Elaboración Propia

El valor K en K-NN representa el número de vecinos más cercanos que se utilizarán para tomar la decisión final. En este caso se utiliza una lógica basada en el parámetro K=3, lo que significa que, al realizar el cálculo de similitud entre las características y preferencias del cliente y las características fenotípicas de la prenda de vestir, solo se mostrarán las tres prendas más cercanas al cliente. Esto asegura que las recomendaciones sean personalizadas y que el cliente tenga opciones limitadas pero relevantes, simplificando la elección y maximizando la probabilidad de una recomendación exitosa.

El cálculo de proximidad se realizará utilizando la distancia euclidiana, y las tres prendas con los valores de distancia más bajos serán las sugeridas como las opciones más compatibles como se muestra en la siguiente tabla:

Tabla 15

Resultados de la distancia euclidiana de las 3 prendas más cercanas para recomendación.

Marca	T. prenda	Distancia euclidiana
Element	Polo	5.57
Gzuck	Polo	6.00
Butrich	Polo	6.08

Nota: Elaboración Propia

La conversión de la distancia euclidiana a un porcentaje de similitud es de vital importancia debido a que permitirá ver que los resultados sean más fáciles de interpretar para los clientes. La distancia euclidiana mide qué tan diferentes son los elementos en base a sus características, pero el valor que es difícil de comprender directamente. Al convertir este resultado en porcentaje proporciona al cliente una representación más comprensible en un contexto no técnico. Para convertir la distancia euclidiana a porcentaje de similitud se utilizará lo siguiente:

$$\text{Similitud} = 100 * \left(1 - \frac{\text{Distancia euclidiana}}{D_{\text{máxima}}}\right)$$

Distancia euclidiana: Es el valor calculado de la distancia entre las características del cliente y la prenda de vestir.

El $\left(1 - \frac{\text{Distancia euclidiana}}{D_{\text{máxima}}}\right)$ en la fórmula es necesario para invertir la relación entre distancia y similitud, haciendo que valores de distancia bajos correspondan a valores de similitud altos.

$D_{\text{máxima}}$: Representa la distancia máxima posible entre los valores de las características. Este valor establece un límite superior para la distancia, permitiendo normalizar la distancia euclidiana.

En este caso, normalizar significa ajustar la distancia euclidiana entre el cliente y la prenda de vestir para que esté en una escala relativa al valor máximo posible $D_{\text{máxima}}$. Esto permite que el resultado de similitud se mantenga en un rango consistente.

La elección de 50 como un valor específico para $D_{\text{máxima}}$ en la fórmula de similitud es debido a que un valor redondeado facilita los cálculos y convierte la similitud en un porcentaje intuitivo, asegurando que la similitud siempre se exprese en una escala de 0% a 100%.

Tabla 16

Porcentaje de similitud de las 3 prendas de vestir más cercanas para el cliente.

Marca	Porcentaje de similitud	Resultados del porcentaje de similitud
Element	$100 * \left(1 - \frac{5.57}{50}\right)$	88.86%

Marca	Porcentaje de similitud	Resultados del porcentaje de similitud
Gzuck	$100 * \left(1 - \frac{6.00}{50}\right)$	88%
Butrich	$100 * \left(1 - \frac{6.08}{50}\right)$	87.84%

Nota. Elaboración Propia

Resultados

La Tabla 16 muestra los valores en porcentaje la distancia entre las variables que desea el cliente, también se coloca un top 3 para verificar e identificar cuál es el más cercano a las especificaciones brindadas. En este caso nos centramos en el top 1, ya que es el que está más cerca y como resultado tenemos que el N.º 44 de la base de datos es el que está más próximo a lo requerido teniendo una distancia de 5.57 y un porcentaje de similitud del 88.86%; por lo que para el cliente se le recomienda la marca Element, con un precio de S/. 120.00, color blanco, talla S, siendo este el más exacto al gusto del cliente, esta información podemos apreciar en la base de datos general que está en la Tabla 10 y es exacta a lo que especificó el cliente en la Tabla 13 por lo que se concluye que la recomendación del algoritmo KNN es precisa y cumple con el objetivo del sistema que se va a implementar.

CAPÍTULO V: IMPLEMENTACIÓN

Para el desarrollo del sistema de recomendación se utilizó el lenguaje PHP con el gestor de base de datos MySQL, como entorno de programación Visual Code en base al MVC (Modelo, vista, controlador) esto para la arquitectura. Para realizar el análisis del sistema a desarrollar se utilizó la metodología RUP y para los casos de uso, diagrama de actividades, diagrama de colaboración., diagrama de clases, etc. Se uso el software RSA (Rational Software Architect) de IBM.

Modelado de Negocios

Requisitos del sistema

Rahimi et al. (2020) mencionan que los requerimientos funcionales del sistema son objetivos del usuario como también del sistema. En la tabla X se lista los requerimientos para el sistema de recomendación.

Tabla 17

Requisitos del sistema

N°	Requisito
RF01	El sistema deberá permitir al administrador el registro de trabajadores.
RF02	El sistema deberá permitir que el trabajador realice registro de ropa en el sistema.
RF03	El sistema deberá permitir el registro de los clientes.
RF04	El sistema deberá permitir el registro de criterios de recomendación.
RF05	El sistema deberá generar la recomendación de ropa sport.
RF06	El sistema deberá permitir generar reportes del historial de recomendaciones que realiza para los clientes.
RF07	El sistema deberá permitir comprar una ropa sport que el cliente seleccione en su carrito.

Nota. Elaboración propia.

Matriz de requisitos vs CUS

Se construye la matriz de requisitos vs CUS para la implementación del sistema de recomendación de ropa sport en la empresa Avalanch, los requisitos vs CUS se muestran en la Tabla 18 y los actores en la Tabla 19.

Tabla 18

Matriz de Requisitos Vs. CUS

N.º	Requisito	CUS	Descripción
01	El sistema deberá permitir al administrador el registro de trabajadores.	Registrar trabajadores	Este CUS permitirá el registro de los datos personales de los trabajadores de la empresa.
02	El sistema deberá permitir que el trabajador realice registro de ropa en el sistema.	Registrar ropa sport	Este CUS permitirá al administrador el registro de ropa sport para ser mostrados en el sistema.
03	El sistema deberá permitir el registro de los clientes.	Registrar clientes	Este CUS permitirá el registro de los datos personales de los clientes en el sistema.
04	El sistema deberá permitir el registro de criterios de recomendación.	Generar recomendación	Este CUS permitirá la generación de la recomendación de prendas sport para el cliente partiendo de los criterios de ingreso de datos.
05	El sistema deberá generar la recomendación de ropa sport.		
06	El sistema deberá permitir generar reportes del historial de recomendaciones que realiza para los clientes.	Generar reportes	Este CUS permitirá los reportes de las recomendaciones generadas por el sistema para el cliente.
07	El sistema deberá permitir comprar una ropa sport que el cliente seleccione en su carrito.	Generar compra de la ropa sport	Este CUS permitirá al cliente generar una compra de lo que agrego a su carrito.

Nota. Elaboración propia.

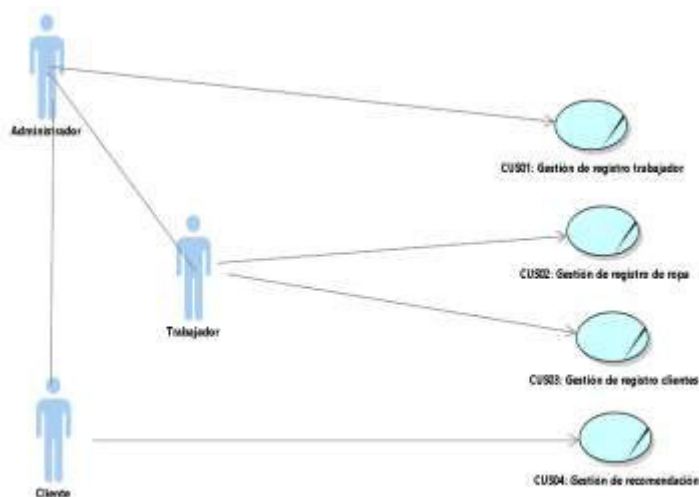
Tabla 19*Actores del Sistema*

Nombre del Actor	Descripción
Administrador	Es el encargado del registro de datos de los trabajadores y también podrá realizar registro de ropa en el sistema.
Trabajador	Es el encargado de registrar la data de ropa al sistema.
Cliente	Es el que registra sus datos personales en el sistema.

Nota. Elaboración propia

Diagrama de casos de uso básicos

Para desarrollar el sistema de recomendación de ropa sport en la empresa Avalanch se realizó el siguiente diagrama de casos de uso básicos:

Figura 5*Diagrama de casos de uso del sistema básico*

Nota. Elaboración Propia

Especificaciones de caso de uso

Las especificaciones de caso de uso para la elaboración del sistema de recomendación para la ropa sport es la siguiente:

CUS01 Gestión de registro trabajador

Tabla 20

Especificación del caso de uso CUS01 – Gestión de registro trabajador.

Identificador	CUS01
Nombre CUS	Gestión de registro trabajador.
Breve descripción	Este CUS permitirá al administrador registrar trabajadores como también podrá registrar clientes.
Precondiciones	El administrador debe estar autenticado en el sistema.
Flujo básico	<ol style="list-style-type: none"> 1. El CUS inicia cuando el actor (Administrador) selecciona la opción “Reg. Trabajadores”. (a) 2. El sistema muestra el formulario “Datos Personales”. (b) 3. El Actor digita el DNI del trabajador en el Text Input. (c) 4. El actor digita el Nombre del trabajador en el Text Input. (d) 5. El Actor digita el Apellido Paterno del trabajador en el Text Input. (e) 6. El Actor digita el Apellido Materno del trabajador en el Text Input. (f) 7. El Actor selecciona en el Data Chooser la fecha de nacimiento del trabajador (g) 8. El Actor Selecciona el sexo del trabajador en el ComboBox. (h) 9. El actor selecciona el estado civil del trabajador en el ComboBox. (i) 10. El Actor ingresa el número de celular del trabajador en el Text Input. (j) 11. El actor digita la dirección del trabajador en el Text Input. (k) 12. El Actor ingresa un usuario en el Text Input. (l) 13. El Actor selecciona en el ComboBox el tipo de usuario. (m) 14. El Actor ingresa una contraseña en el Text Input. (n) 15. El Actor ingresa la confirmación de la contraseña en el Text Input. (o) 16. El Actor selecciona el Button “Crear Cuenta”. (p) 17. El sistema registra la información ingresada y registra al usuario. 18. El actor selecciona el Button “Cerrar Sesión”. (k) 19. El CUS finaliza.
Postcondiciones	Se registrará un nuevo trabajador al sistema.
Escenarios	Proceso Registrar Trabajadores.

Nota. Elaboración Propia

CUS02 Gestión de registro de ropa

Tabla 21

Especificación del caso de uso CUS02 – Gestión de registro de ropa.

Identificador	CUS02
Nombre CU	Gestión de registro de ropa.
Breve descripción	Este CUS permitirá al trabajador registrar prendas de vestir (Imagen, descripción).
Precondiciones	El usuario (trabajador) tiene que estar autenticado en el sistema. <ol style="list-style-type: none"> 1. El CUS inicia cuando el actor (Trabajador) selecciona la opción “Reg. Prenda de Vestir” del menú principal. (a) 2. El sistema muestra el formulario “Agregar Prendas de Vestir”. (b) 3. El Actor da clic en el Button “Seleccionar archivo” y carga una imagen de una prenda de vestir. (c) 4. El Actor ingresa el nombre de la prenda de vestir en el Text Input. (d) 5. El Actor digita el precio de la prenda de vestir en el Text Input. (e) 6. El Actor selecciona en el ComboBox “Diseño” y elije un diseño de una prenda de vestir. (f) 7. El Actor selecciona el ComboBox “Marca” especificando la marca de la ropa. (g) 8. El Actor selecciona el ComboBox “Talla” eligiendo la talla que le corresponde al registro que está realizando. (h) 9. El actor selecciona el ComboBox “Tipo de prenda” especificando el tipo de ropa. (i) 10. El actor selecciona el ComboBox “Color” especificando el color de la prenda de vestir. (j) 11. El Actor selecciona el ComboBox “Fibra” y elije una opción. (k) 12. El Actor Ingresa en el Text Área una descripción de la prenda de vestir. (l) 13. El Actor selecciona el Button “Registrar” (m) 14. El sistema registra la información de la prenda de vestir que se ha registrado. 15. El actor selecciona el Button “Cerrar Sesión”. (n) 16. El sistema cierra la Interface. 17. El CUS finaliza.
Flujo básico	
Postcondiciones	Se registra nuevas prendas de vestir al sistema.
Escenarios	Proceso Registro de prendas de vestir

Nota. Elaboración Propia.

CUS03 Gestión de registro de cliente

Tabla 22

Especificación del caso de uso CUS03 – Gestión de registro de cliente

Identificador	CUS03
Nombre CU	Gestión de registro clientes.
Breve descripción	Este CUS permitirá al cliente registrar sus datos personales, crear su contraseña y poder tener acceso al sistema de recomendación de prendas de vestir.
Precondiciones	<ol style="list-style-type: none"> 1. El CUS inicia cuando el actor da clic en el link “Deseo crear mi cuenta” del menú principal, redireccionándolo a otra interface (a) 2. El sistema muestra un Field Set denominado “CREAR CUENTA”. (b) 3. El sistema muestra también un Field Set denominado Datos personales. (c) 4. El actor digita el DNI en el Text Input. (d) 5. El actor digita en el Text Input el Nombre. (e) 6. El actor digita en el Text Input el apellido paterno. (e) 7. El actor digita en el Text Input el apellido materno. (g)
Flujo básico	<ol style="list-style-type: none"> 8. El Actor selecciona en el Date Chooser su fecha de nacimiento. (h) 9. El actor selecciona en el ComboBox el sexo. (i) 10. El Actor selecciona el ComboBox “Estado Civil”. (j) 11. El actor digita el número de celular en el sistema. (k) 12. El actor digita en el Text Input la dirección. (i) 13. El sistema muestra un Field Set “Datos de la cuenta”. (m) 14. El Actor ingresa un usuario en el Text Input. (n) 15. El Actor ingresa una contraseña en el Text Input. (o) 16. El Actor confirma la contraseña. (p) 17. El actor da clic em el Botton “Crear cuenta”. (k) 18. El sistema guarda toda la información registrada. 19. El Actor da click en el Button “Cerrar”. (r) 20. El CUS finaliza.
Postcondiciones	Se registra un nuevo cliente.
Escenarios	Proceso Registro de Clientes.

Nota. Elaboración Propia

CUS03 Gestión de recomendación

Tabla 23

Especificación del caso de uso CUS03 – Gestión de recomendación

Identificador	CUS04
Nombre CUS	Gestión de Recomendaciones
Breve descripción	Este CUS permitirá al cliente ver información sobre a una prenda de vestir, también podrá dar calificaciones para que se le brinde recomendaciones.
Precondiciones	El actor (cliente) debe estar autenticado en el sistema. <ol style="list-style-type: none"> 1. El CUS inicia cuando el actor selecciona tres ítems que pide el sistema para brindar la primera recomendación, esto se da para cada usuario nuevo que se registra en el sistema. (a) 2. El sistema muestra un Fiel Set “Recomendaciones” en donde se aprecia imágenes de prendas de vestir que se le ha recomendado al usuario con sus elecciones anteriores. (b) 3. El Actor da like a una imagen de prenda de vestir que le haya gustado. (c) 4. El sistema captura el like y lo registra para generar más recomendaciones a partir de ello.
Flujo básico	<ol style="list-style-type: none"> 5. El Actor da clic en el icono de carrito para adquirir una prenda de vestir, se muestra un mensaje “Producto agregado”. (d) 6. El sistema almacena en una lista lo que vaya agregando el cliente para su posterior compra. 7. El actor selecciona el Search Box “Buscar ropa”, en donde podrá escribir lo que busca y se muestra la lista de la búsqueda. (e) 8. El sistema captura la búsqueda en un registro para a partir de ello brindar recomendaciones para el usuario. 9. El Actor puede realizar filtros para que se le muestre lo que desea, para ello el actor selecciona las categorías disponibles en el sistema. (f) 10. El sistema muestra los filtros de acuerdo a las elecciones del usuario. 11. El actor selecciona el Button “Cerrar Sesión”. (g) 12. El CUS finaliza.

Identificador	CUS04
Flujo alternativo	<p data-bbox="407 342 1045 363">En el punto 5 cuando el cliente agrega una prenda al carrito.</p> <ol data-bbox="456 390 1398 730" style="list-style-type: none"> <li data-bbox="456 390 1354 457">1. Se muestra una lista de las prendas agregadas con un detalle como: Descripción, precio, etc. <li data-bbox="456 478 1354 499">2. El actor puede limpiar la lista del carrito dando clic en button “Limpiar carrito”. <li data-bbox="456 520 1354 588">3. Cuando el actor quiere adquirir otra prenda de vestir puede dar clic en el Button “Cerrar” y agregar otros productos. <li data-bbox="456 609 1398 730">4. Cuando el actor desea comprar los productos que haya agregado a la lista, da clic en el Button “Pagar” y el sistema muestra un formulario para llenar, en donde pide número de tarjeta, DNI, celular, etc.
Postcondiciones	Se realiza las recomendaciones de acuerdo a las preferencias del cliente.
Escenarios	Proceso Recomendaciones.

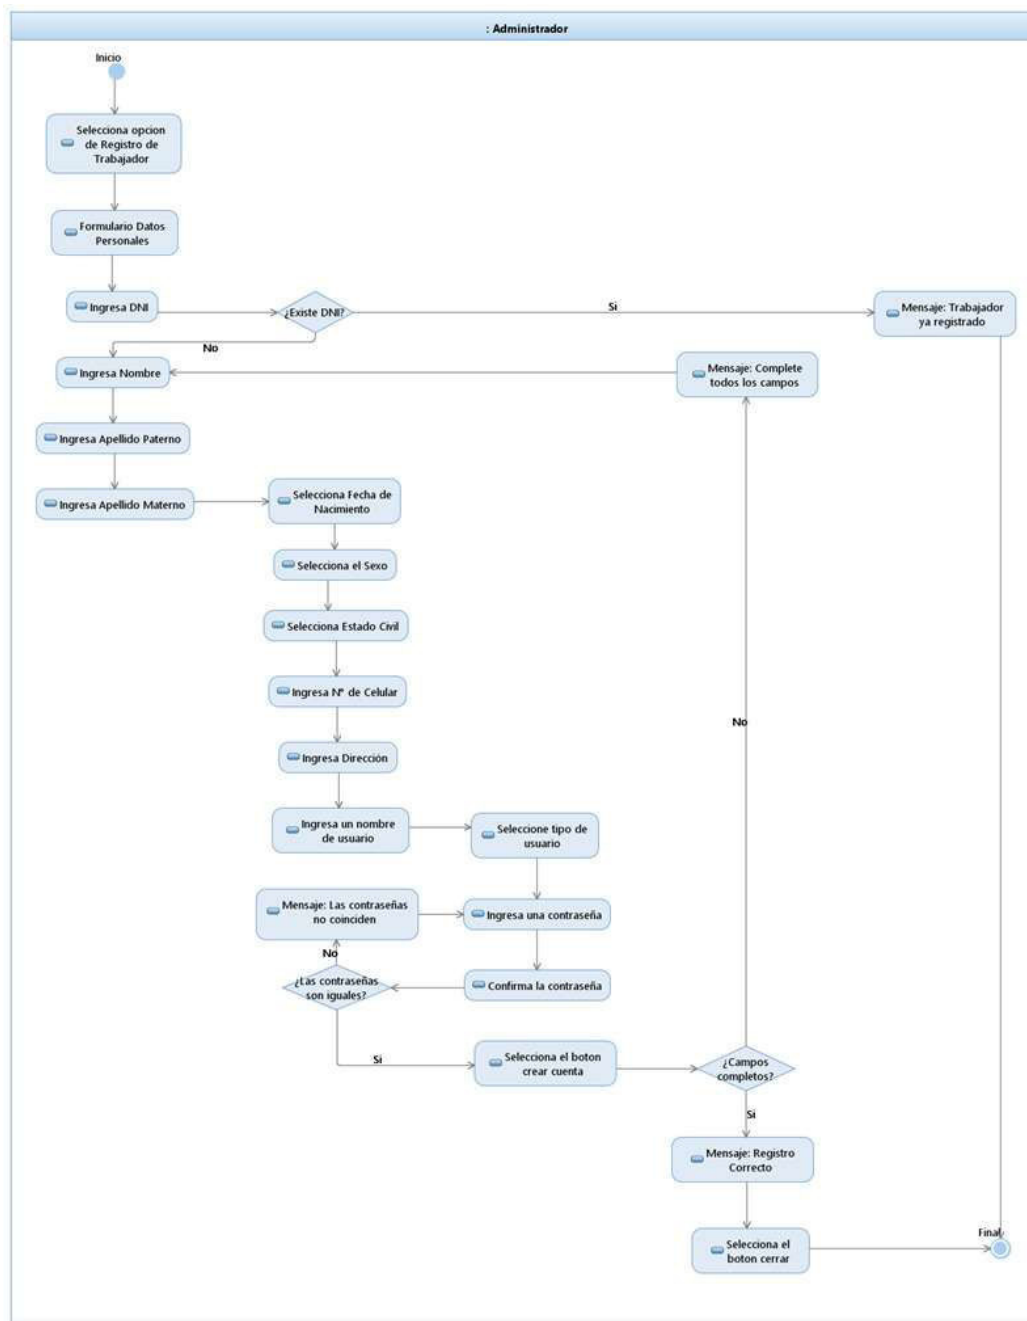
Nota. Elaboración propia

Diagrama de actividades

DA Registro de trabajador

Figura 6

Diagrama de actividades - Registro de trabajador

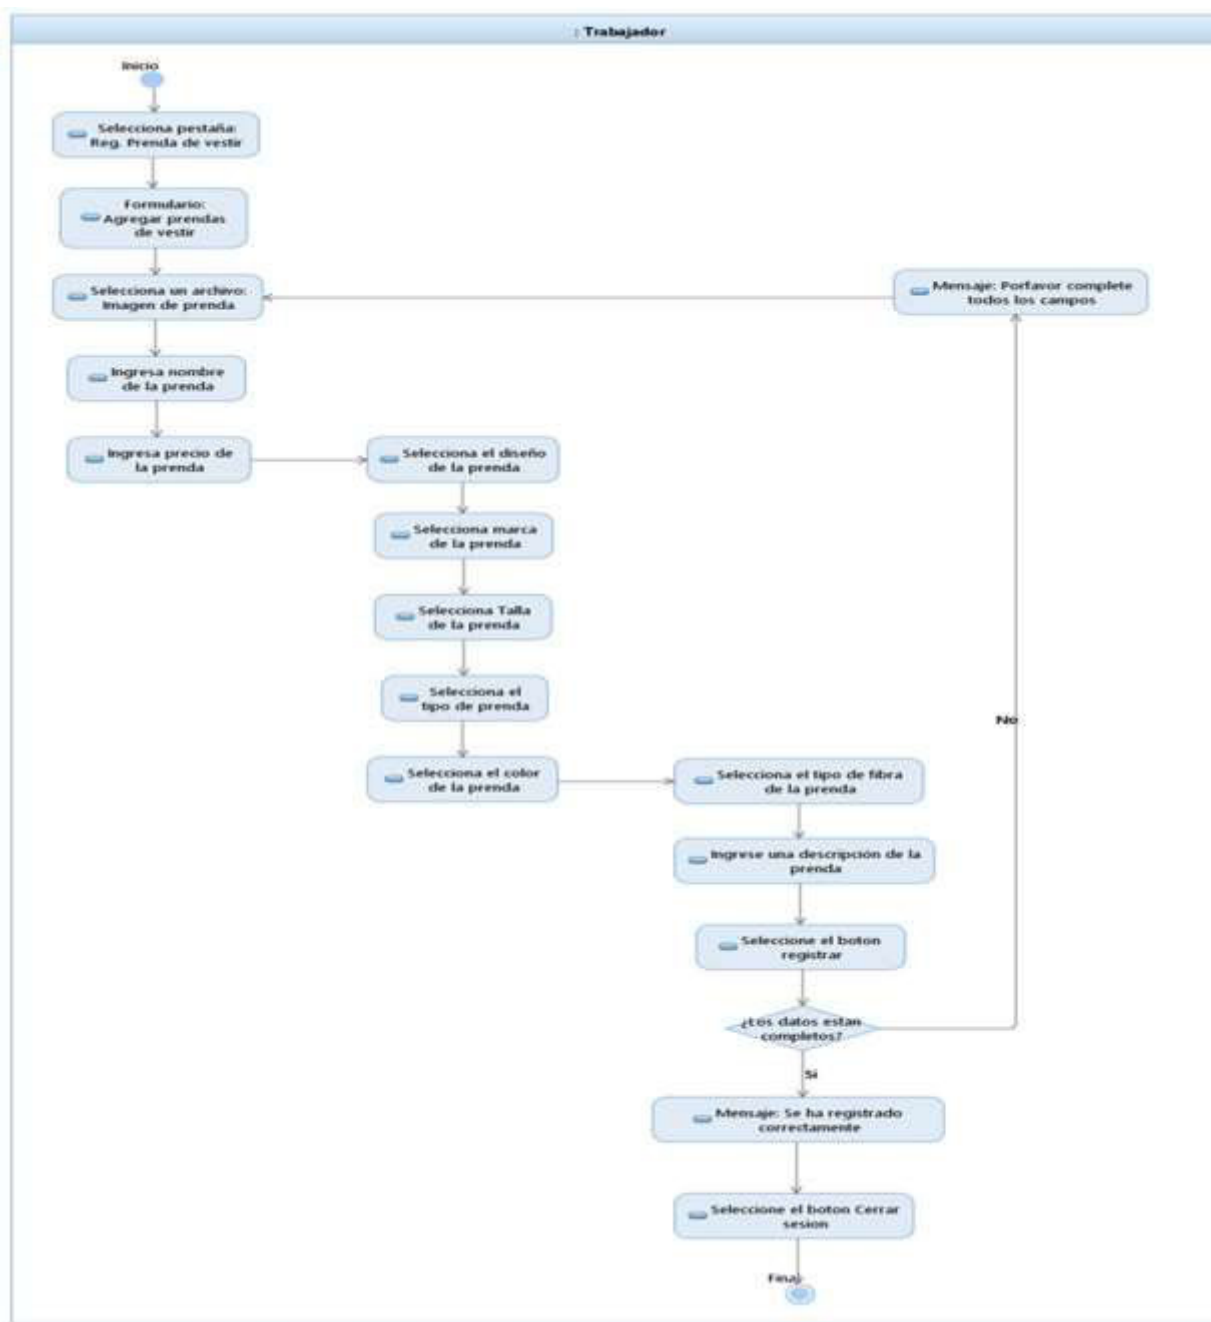


Nota. Elaboración Propia

DA Registrar ropa

Figura 7

Diagrama de actividades - Registro de prendas

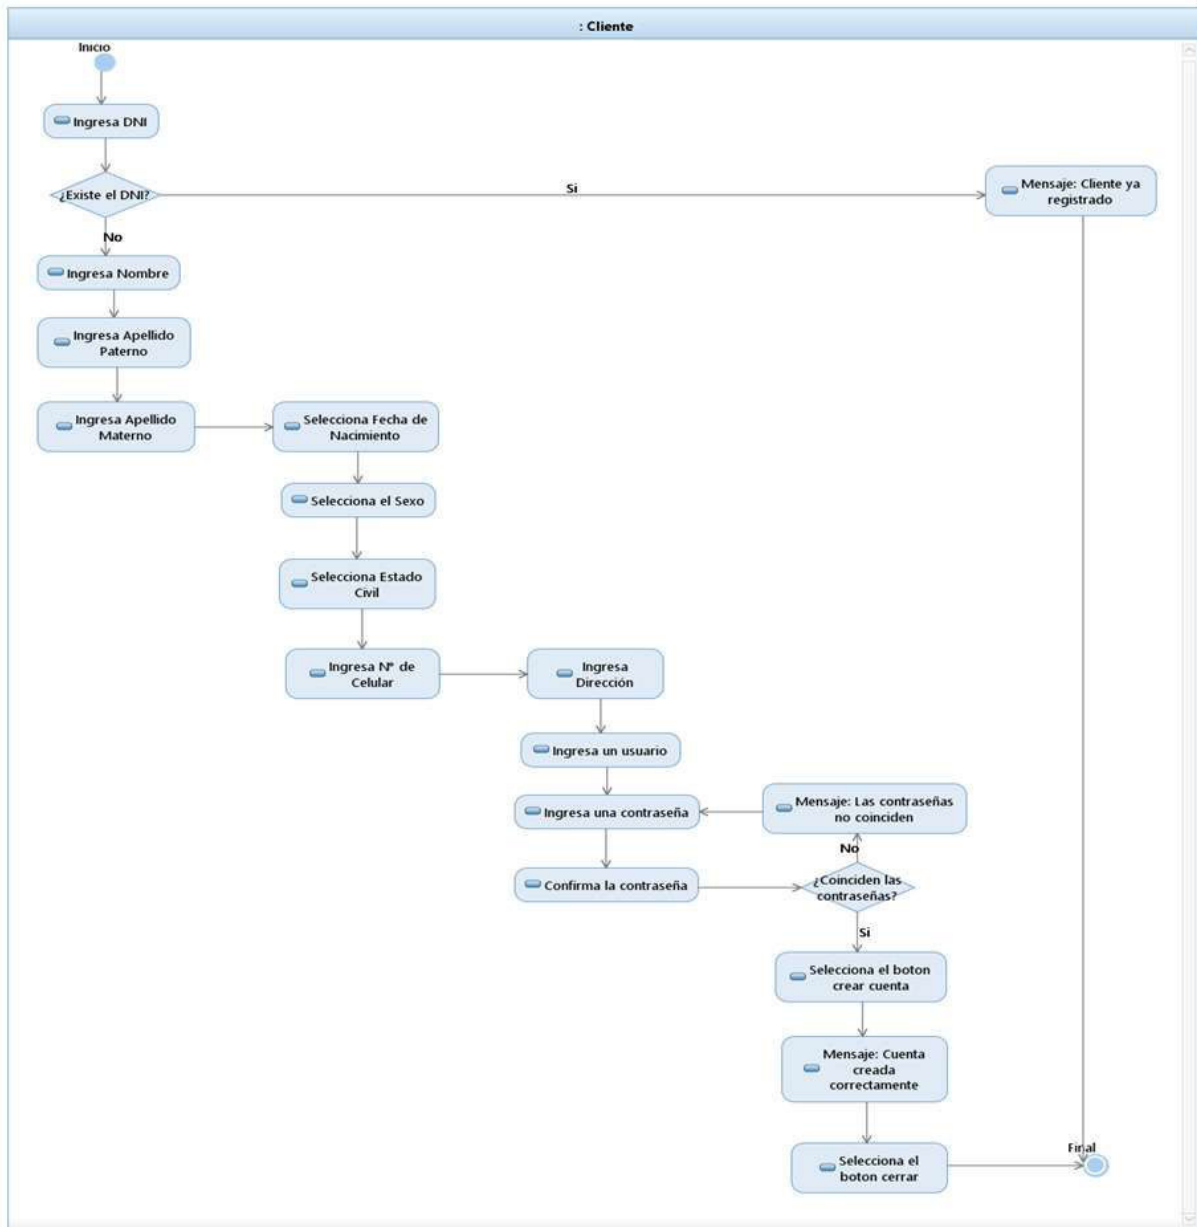


Nota. Elaboración Propia

DA Registro Cliente

Figura 8

Diagrama de actividades - Registro de clientes

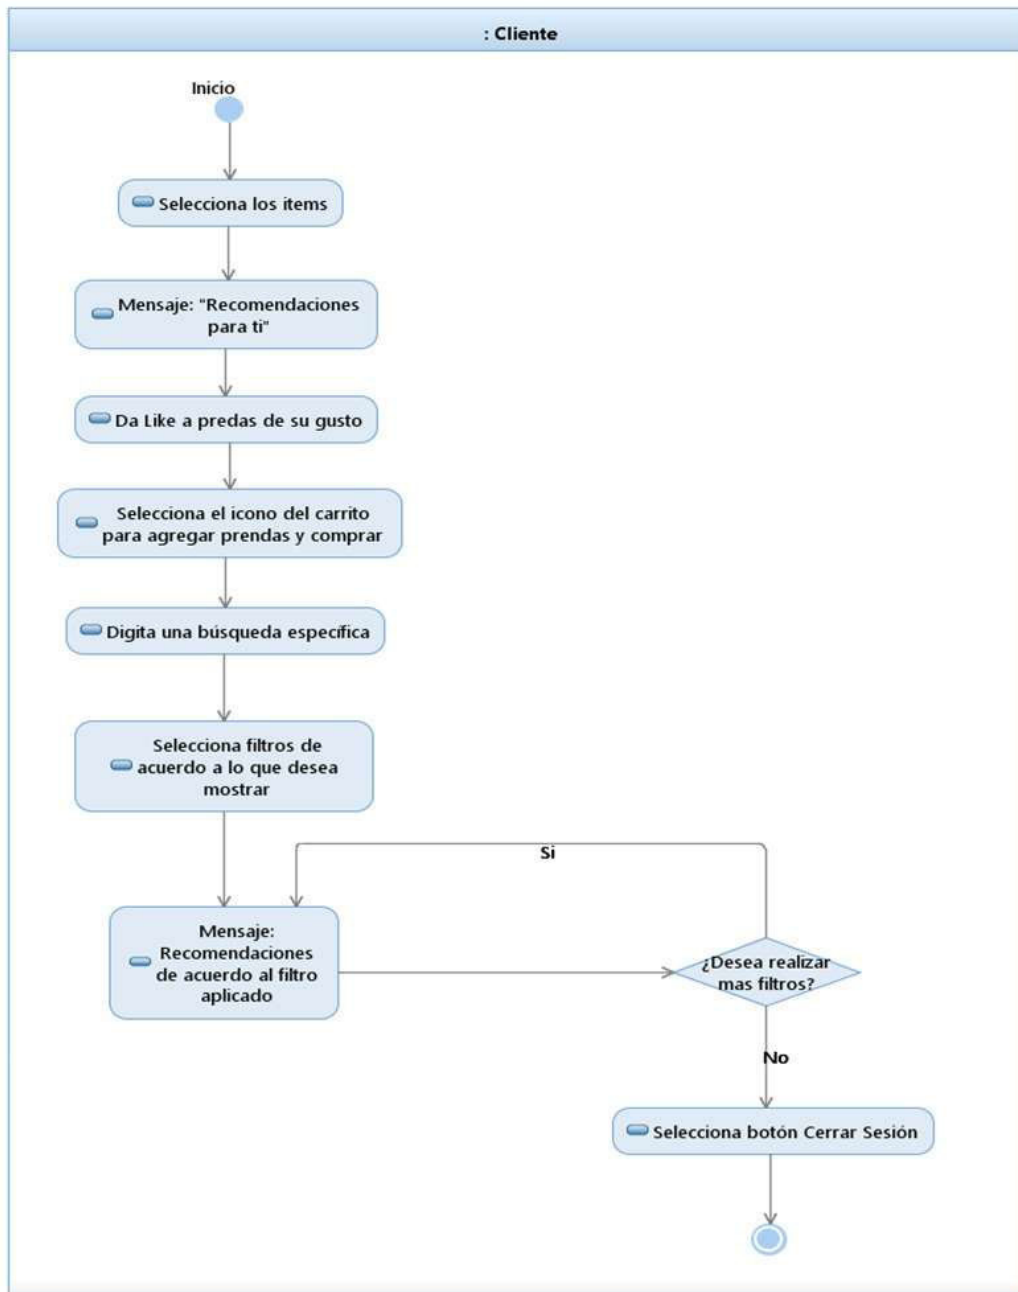


Nota. Elaboración Propia

D.A Recomendación

Figura 9

Diagrama de actividades - Gestión de recomendaciones



Nota. Elaboración Propia

Modelo de Análisis

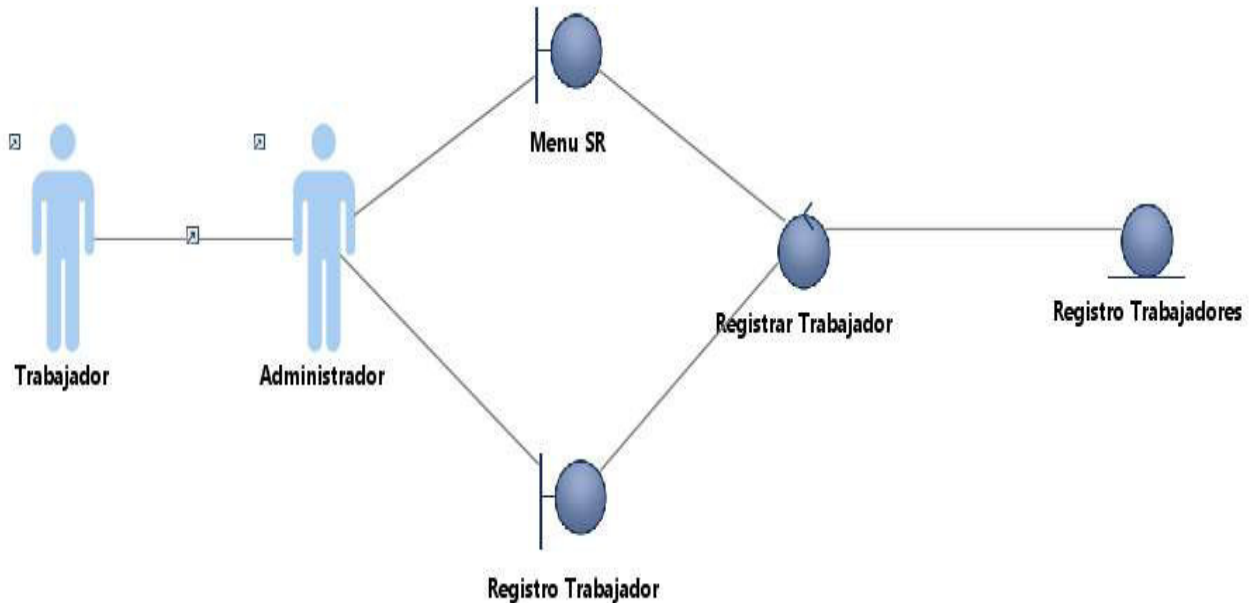
Para desarrollar el modelo de análisis, normalmente se elaboran diagramas de secuencia, colaboración y clases, basándose en las especificaciones de los casos de uso descrito en las secciones anteriores. Sin embargo, dado que esto no es un informe técnico, solo se presentarán los diagramas de colaboración y de secuencia. Estos diagramas se construyen a partir de las entidades involucradas en los casos de uso, incluyendo los actores del sistema, así como las clases interfaz y de control.

Diagrama de clases de análisis

DC Registro Trabajador

Figura 10

Diagrama de clases - Registrar trabajador

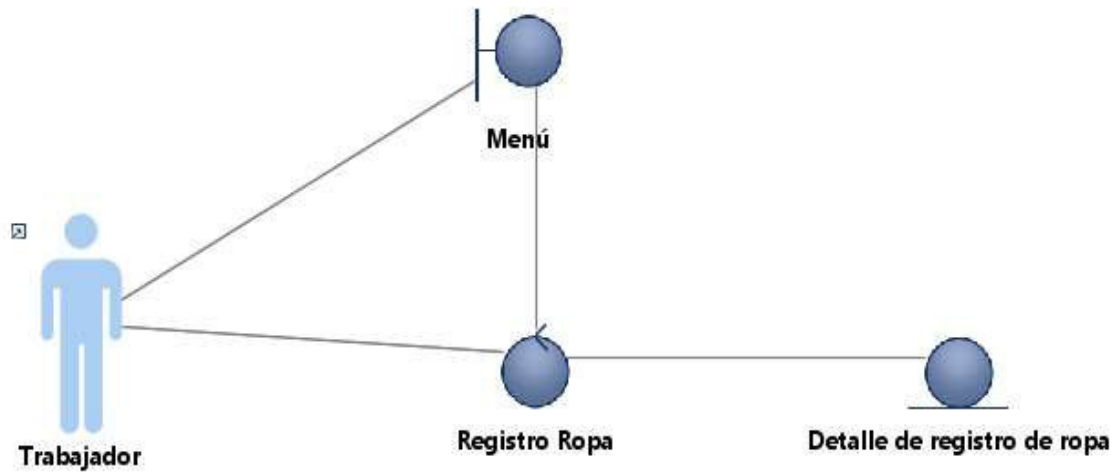


Nota. Elaboración Propia

DC Registro ropa

Figura 11

Diagrama de clases - Registro de ropa

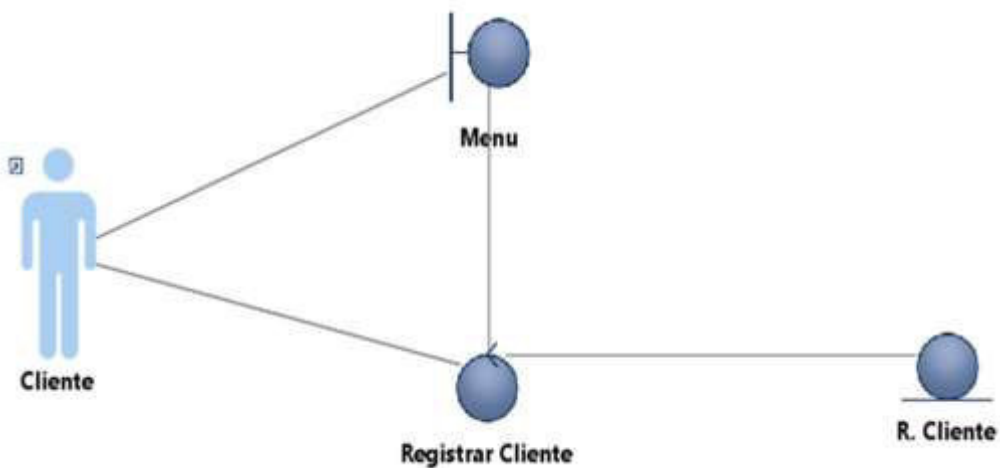


Nota. Elaboración Propia

DC Registro Cliente

Figura 12

Diagrama de clases - Registro de clientes

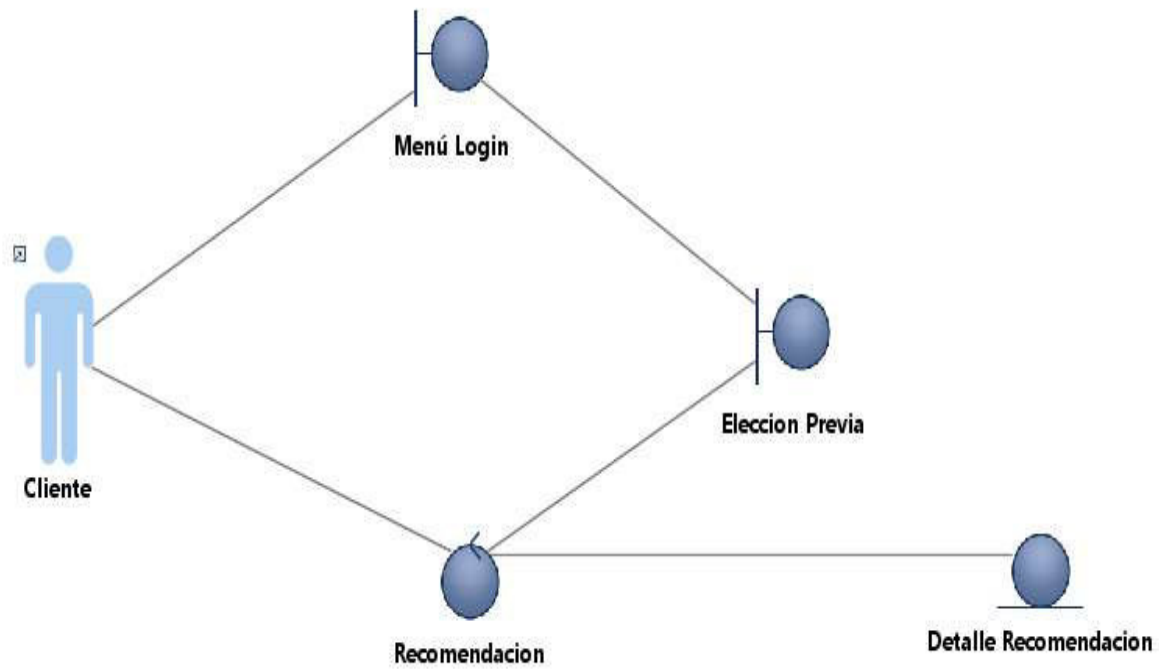


Nota. Elaboración Propia

DC Recomendación

Figura 13

Diagrama de clases - Gestión de recomendación



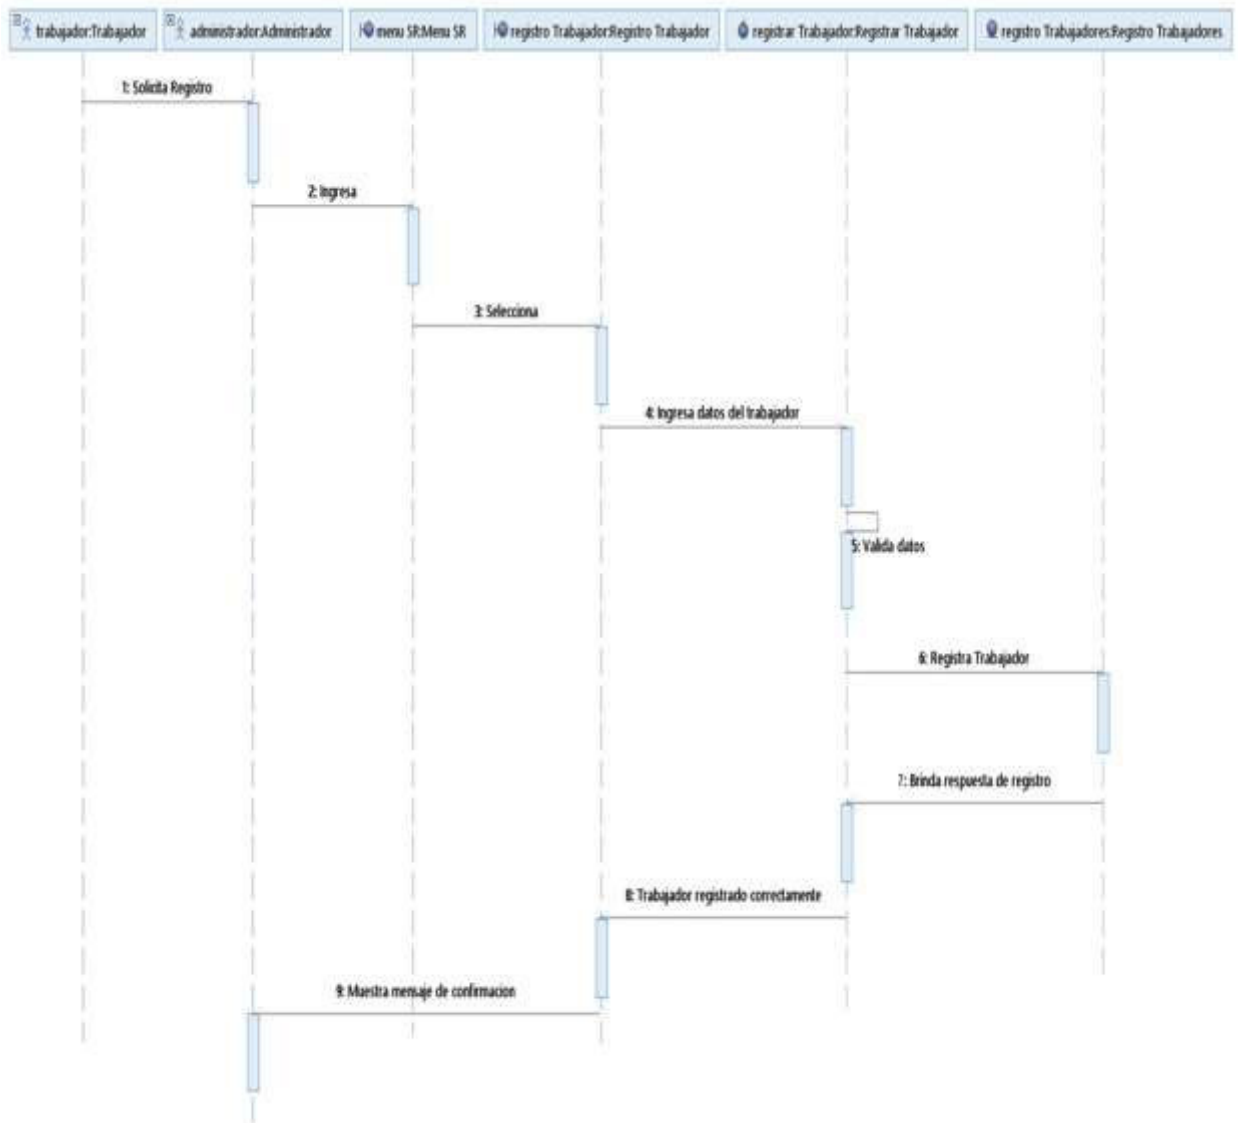
Nota. Elaboración Propia

Diagrama de secuencia

DS Registro Trabajador

Figura 14

Diagrama de secuencias - Registro de trabajador

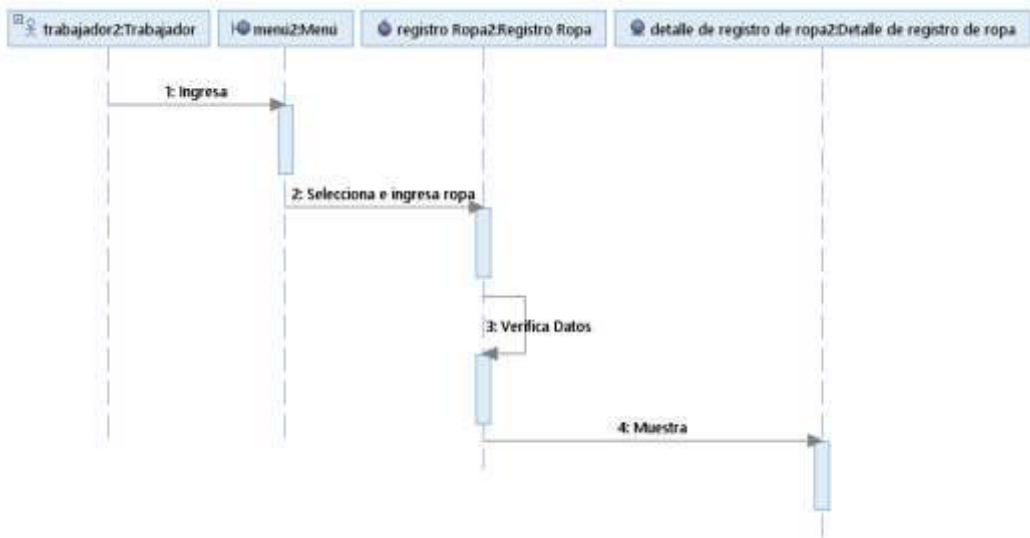


Nota. Elaboración Propia

DS Registro ropa

Figura 15

Diagrama de secuencias - Registro de ropa

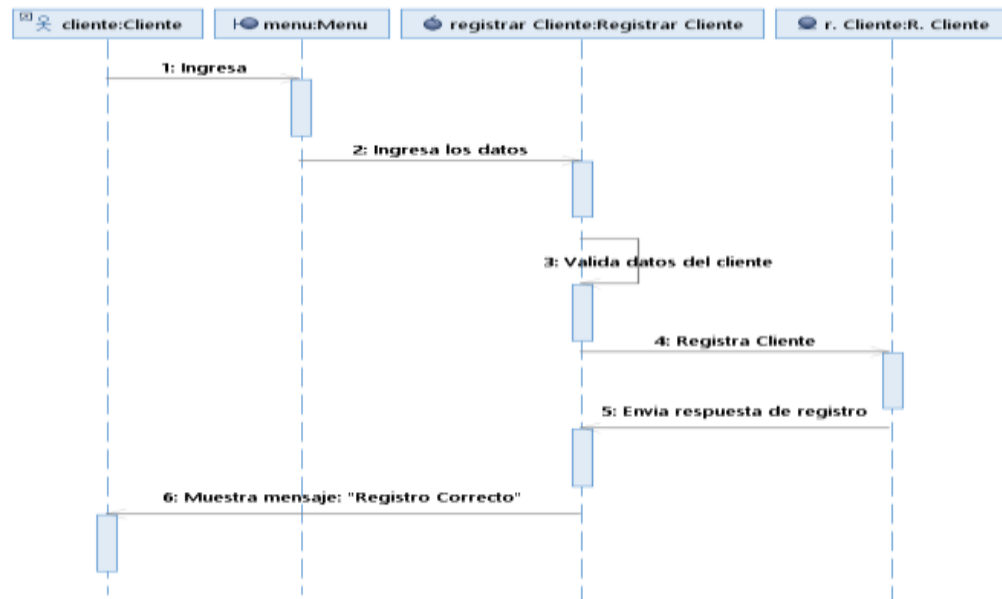


Nota. Elaboración Propia

DS Registro Cliente

Figura 16

Diagrama de secuencias - Registro de clientes

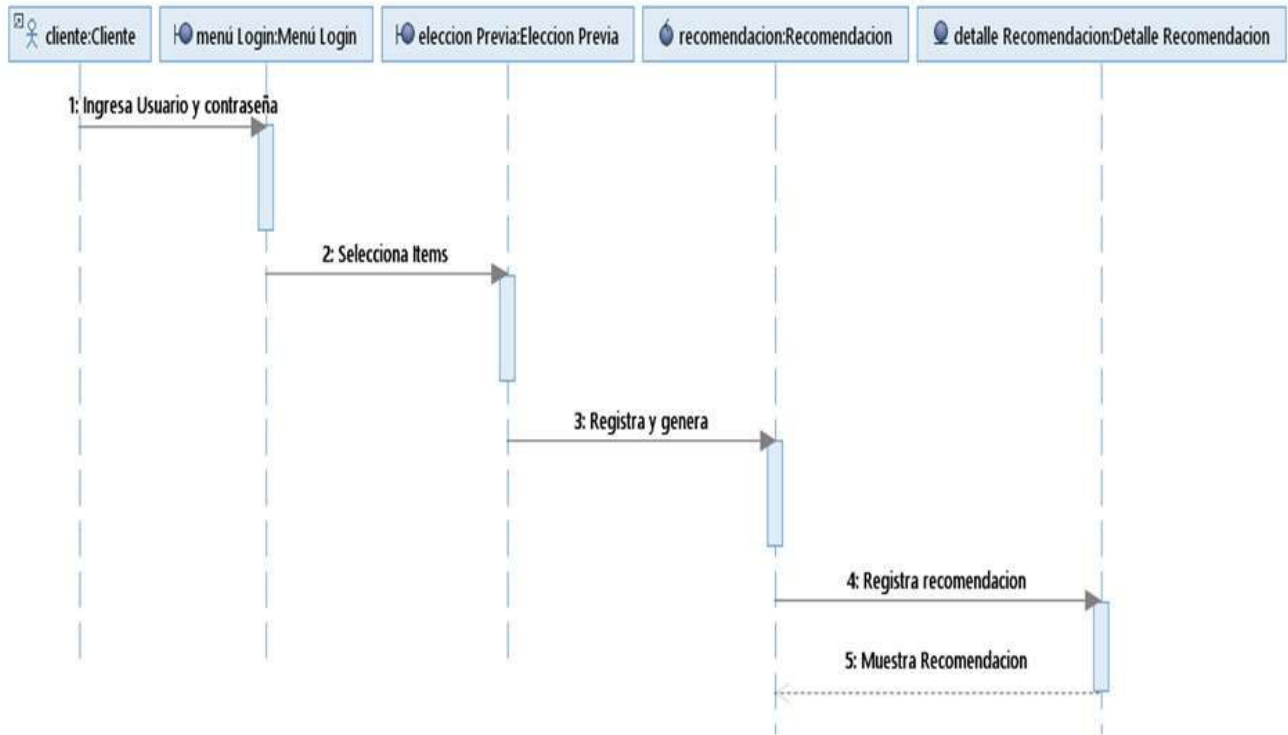


Nota. Elaboración Propia

DS Recomendación

Figura 17

Diagrama de secuencias - Gestión de recomendación



Nota. Elaboración Propia

Prototipos

El prototipado del sistema de recomendación de ropa sport se basó en la implementación de módulos que permiten una estructura adecuada para el desarrollo que son las siguientes:

Prototipo de registrar trabajador

Figura 18

Prototipo de Registrar trabajador

SISTEMA SE RECOMENDACIÓN DE ROPA SPORT

EMPRESA AVALANCH **Carrito** **Cerrar Sesión** (k)

ADMINISTRADOR

- Inicio
- Formularios
- Reg. Prenda de Vea (a)
- Reg. Trabajadores**
- Reportes
- Recomendaciones
- Filtrar por
- Bermudas
- Casacas
- Joggers
- Pantalones
- Poleras
- Polos
- Shorts

Datos Personales (b)

Nombres (c) Sexo (h)
 Masculino
 Femenino

Apellido P (d)

Apellido M (e) Estado Civil (i)
 Soltero(a)
 Casado(a)

DNI (f) Celular (j)

Fecha Nacimiento / / (g) Dirección (k)

Datos de la Cuenta

Usuario (l) Ingreso una Contraseña (n)

Tipo de Usuario (m) Confirma tu contraseña (o)
 Seleccione el tipo
 Trabajador
 Administrador
 Cliente

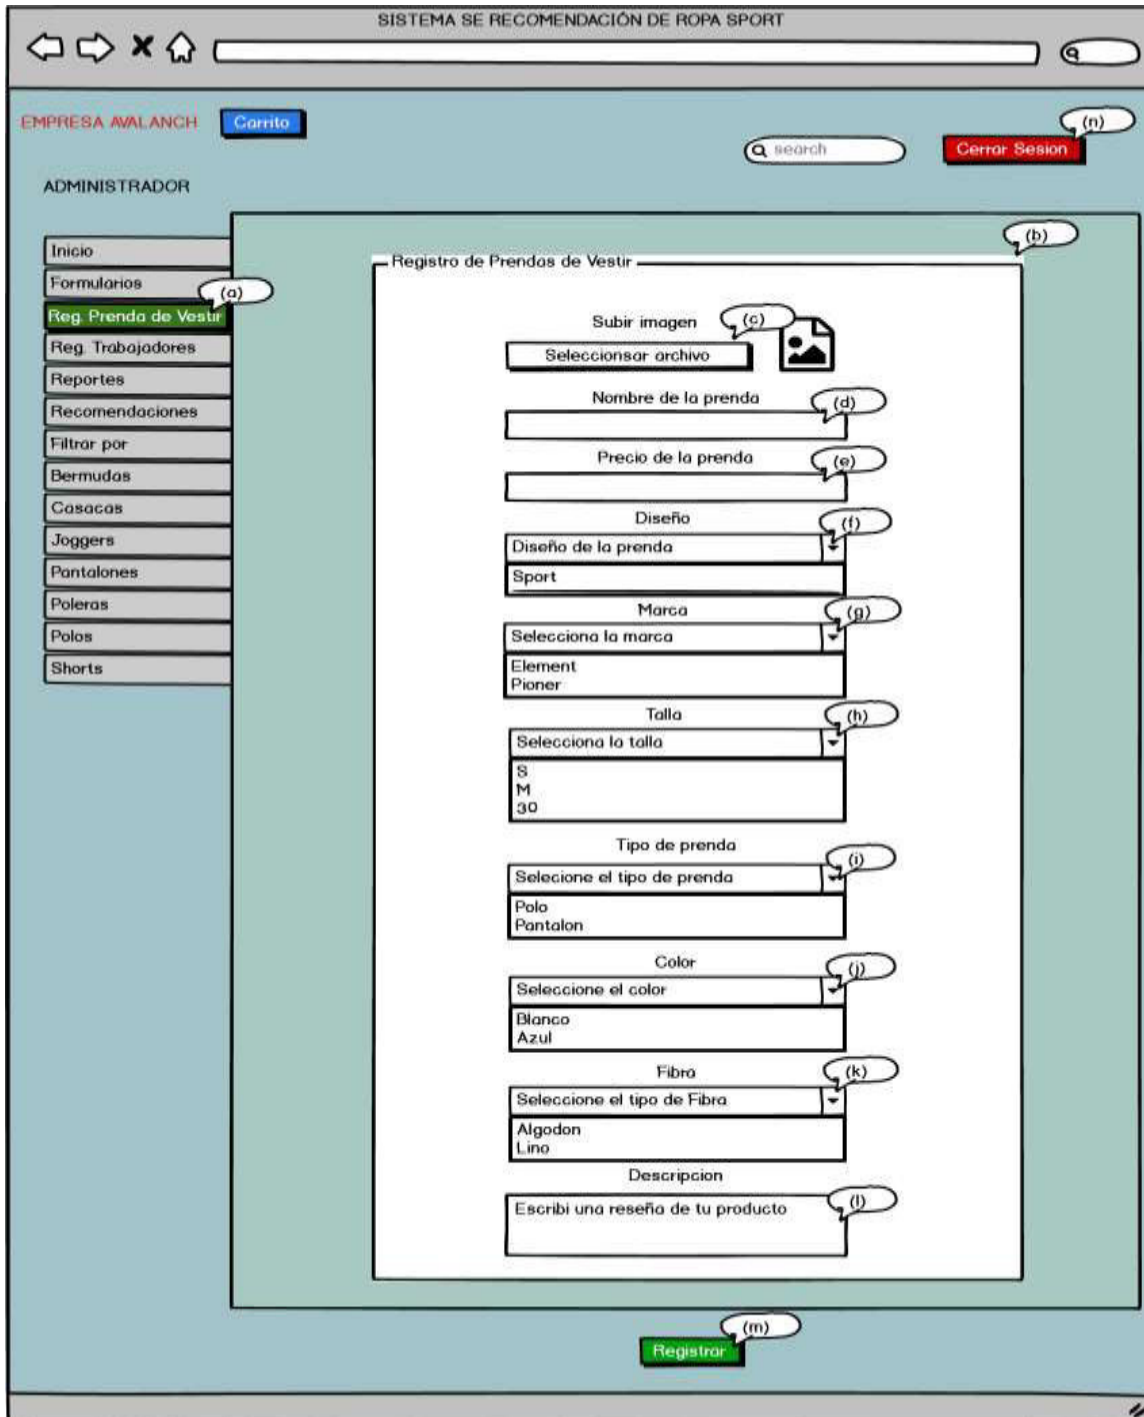
Crear Cuenta (p)

Nota. Elaboración Propia

Prototipo de registrar ropa

Figura 19

Prototipo de Registro de ropa



Nota. Elaboración Propia

Prototipo de registrar cliente

Figura 20

Prototipo de Registrar Cliente

SISTEMA DE RECOMENDACIÓN DE ROPA SPORT

EMPRESA AVALANCH

INICIO DE SESION

Usuario

Contraseña

Iniciar Sesión (a)

[Deseo crear mi cuenta](#)

CREAR CUENTA (b)

Datos Personales (c)

Nombres (d) Apellido Paterno (e) Apellido Materno (f)

DNI (g) Fecha de Nacimiento (h) Sexo (i)

 / Seleccione

Estado Civil (j) Celular (k) Dirección (l)

Seleccione su est.

Datos de la cuenta (m)

Usuario (n)

Contraseña (o)

Confirma tu contraseña (p)

Crear Cuenta (k)

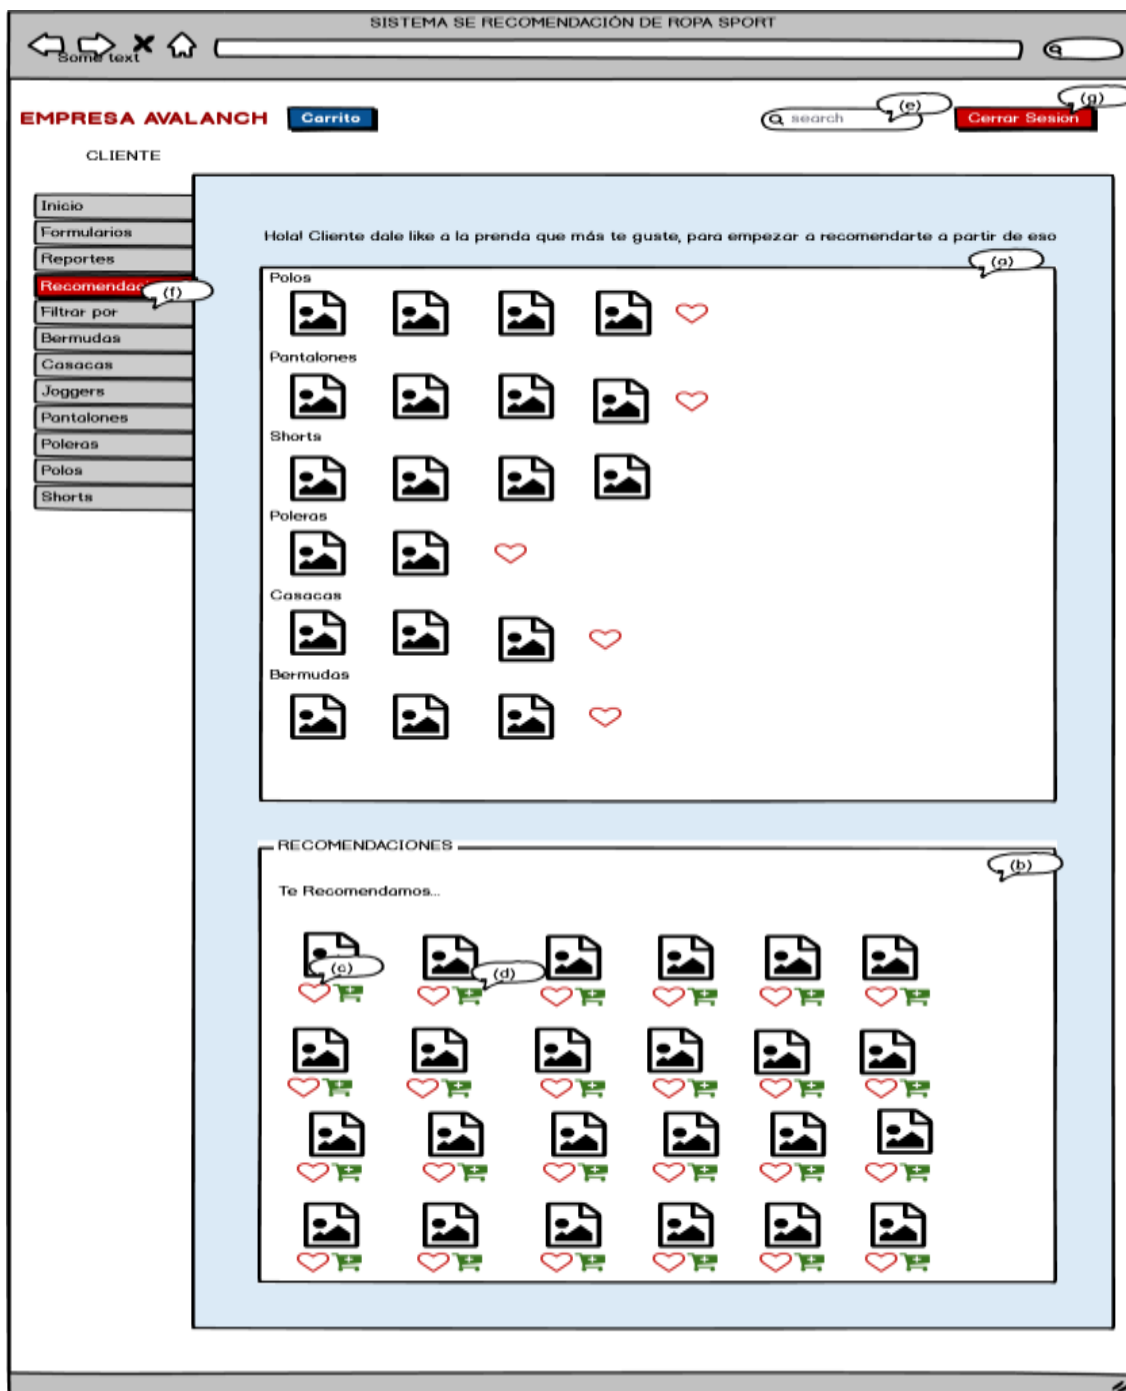
Cerrar (r)

Nota. Elaboración propia.

Prototipo generar recomendación

Figura 21

Prototipo de Generar Recomendación



Nota. Elaboración propia.

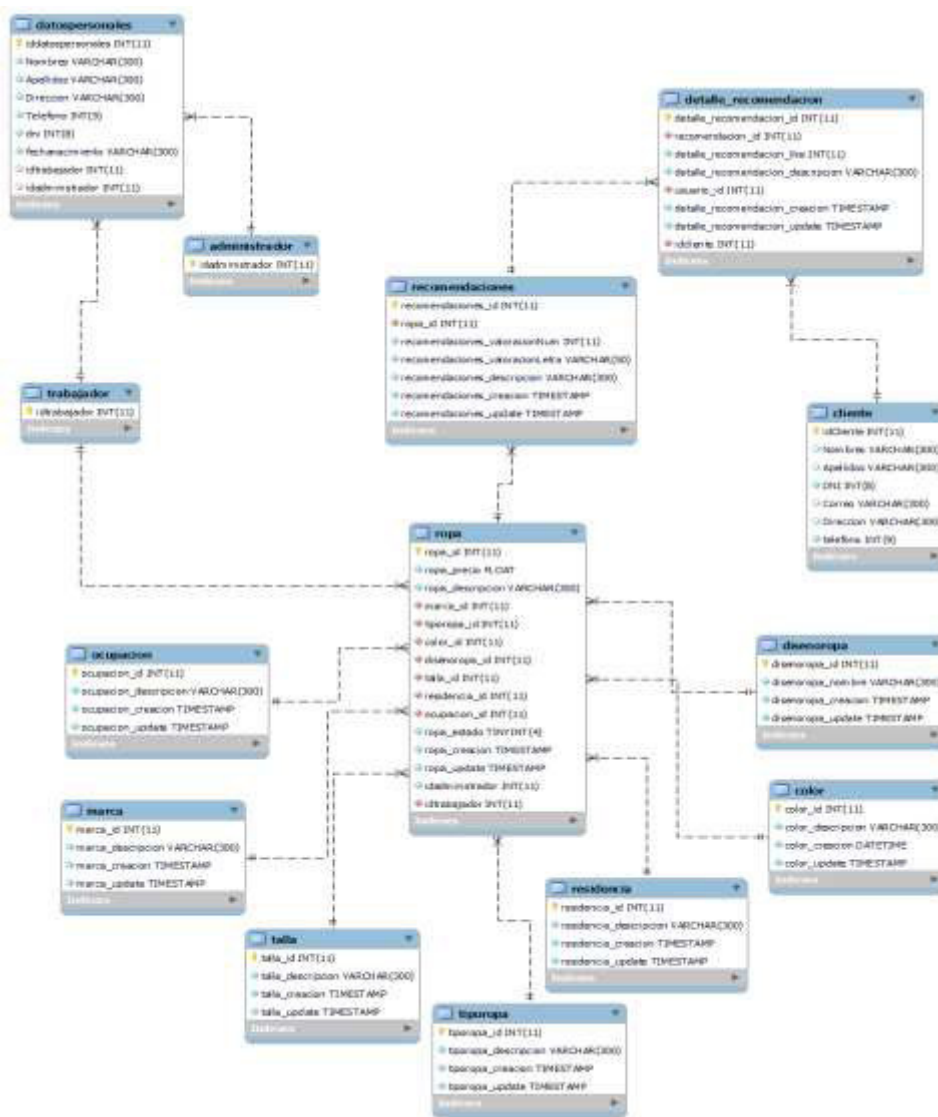
Modelo de datos

El modelo de datos que hace referencia a la base de datos muestra la estructura lógica en donde también se muestran las relaciones que determinan como se almacenan los datos y de qué manera se acceden a ellas.

Modelo físico

Figura 22

Modelo Físico



Nota. Elaboración Propia.

Alcance del Prototipo del Sistema de Información a Desarrollar

El sistema de recomendación de prendas de vestir se encarga de mostrar la ropa adecuada según las preferencias y necesidades del usuario. El proceso comienza cuando el cliente se registra en la plataforma, ingresando sus datos personales para poder crearse una cuenta. Una vez completado este paso, el usuario debe seleccionar sus gustos y requerimientos personales (tales como estilo, talla, colores, tipo de tela, entre otros), lo que permitirá al sistema poder ofrecerle diversas sugerencias de ropa que se ajusten a su perfil.

Además de recibir recomendaciones personalizadas, el usuario puede consultar la información de cada prenda sugerida. Si alguna le interesa, tiene la opción de añadirla a su lista de prendas favoritas. Por otro lado, desde el lado del administrador, es posible registrar nuevas prendas de vestir, visualizar el catálogo existente, subir imágenes de las prendas actualizadas y modificar el estado de disponibilidad de los artículos ofrecidos.

Implementación

Para su implementación del sistema, se utilizó el lenguaje de programación PHP junto a una base de datos en MySQL con la arquitectura MVC (Modelo Vista Controlador), contando con un servidor local Apache instalado desde el software XAMPP, para el tema de las vistas se utilizó HTML y CSS, agregar que para algunas funcionalidades se utilizó el lenguaje de programación JavaScript. Como editor de código se utilizó el software Visual StudioCode, al ser un programa de licencia gratuita, de fácil entendimiento y cuenta con diversas extensiones que facilitan el desarrollo.

Pruebas

Figura 23

Inicio de sesión tienda de ropa AVALANCH

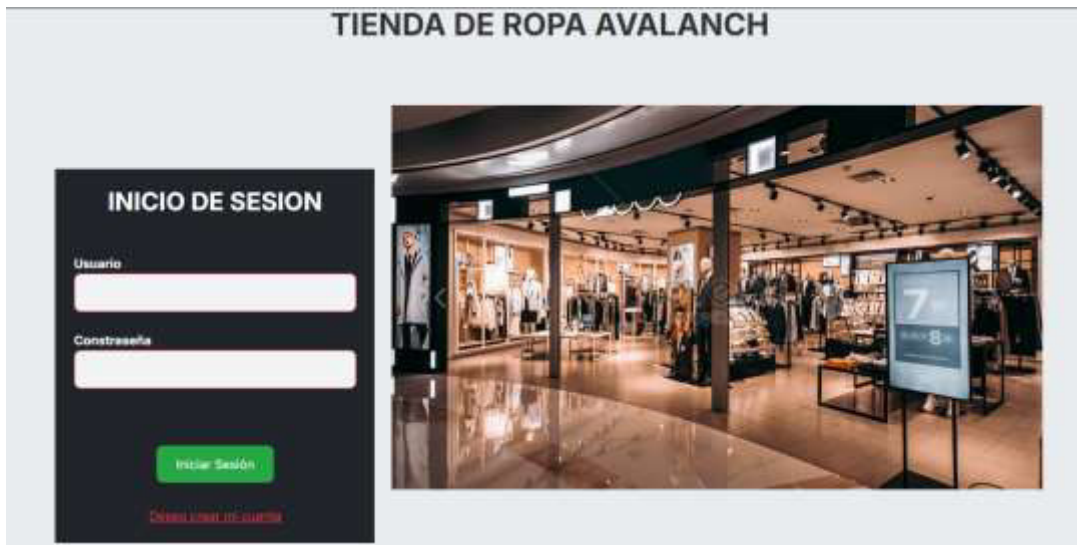


Figura 24

Crear cuenta tienda de ropa AVALANCH

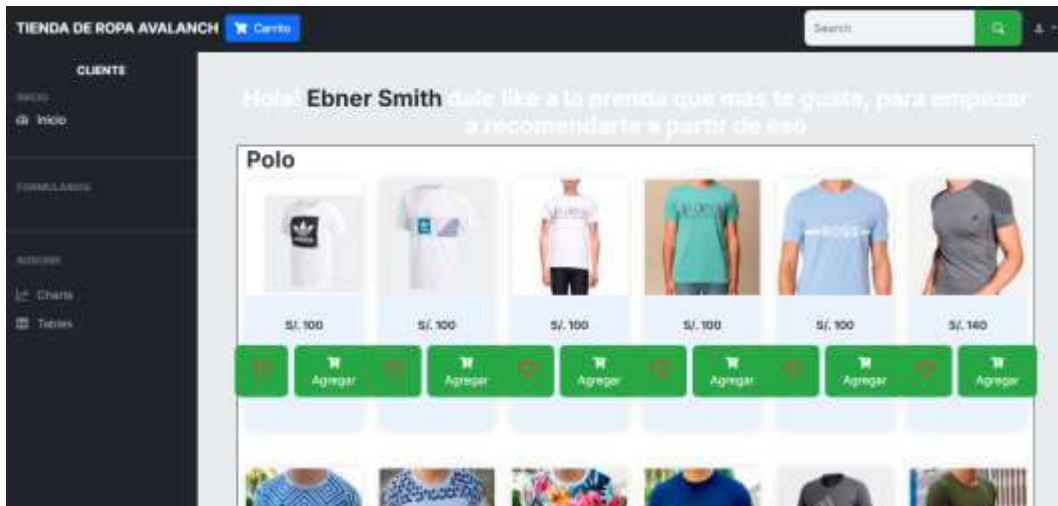
The image displays a 'CREAR CUENTA' (Create Account) form. The form is titled 'CREAR CUENTA' and has a close button (X) in the top right corner. The main section is titled 'Datos Personales' and contains several input fields arranged in a grid:

- Nombres ***: Text input field.
- Apellido Paterno ***: Text input field.
- Apellido Materno ***: Text input field.
- DNI ***: Text input field.
- Fecha Nacimiento ***: Date input field with a calendar icon.
- Sexo ***: Dropdown menu with the option 'Selecciona el sexo'.
- Estado Civil ***: Dropdown menu with the option 'Selecciona el estado civil'.
- Celular ***: Text input field.
- Dirección ***: Text input field.
- Preferencia de Marca ***: Dropdown menu with the option 'Selecciona el tipo de Usuario'.
- Ubicación ***: Dropdown menu with the option 'Selecciona una ubicación'.
- Genero de Prenda ***: Dropdown menu with the option 'Selecciona un genero de prenda'.
- Personalidad ***: Dropdown menu with the option 'Selecciona un personalidad'.
- Nivel de Exclusividad ***: Dropdown menu with the option 'Selecciona el nivel de exclusividad'.
- Tendencia de moda ***: Dropdown menu with the option 'Selecciona una tendencia'.

A 'Cerrar' button is located at the bottom right of the form.

Figura 25

Cliente - tienda de ropa AVALANCH

**Figura 26**

Carrito - tienda de ropa AVALANCH

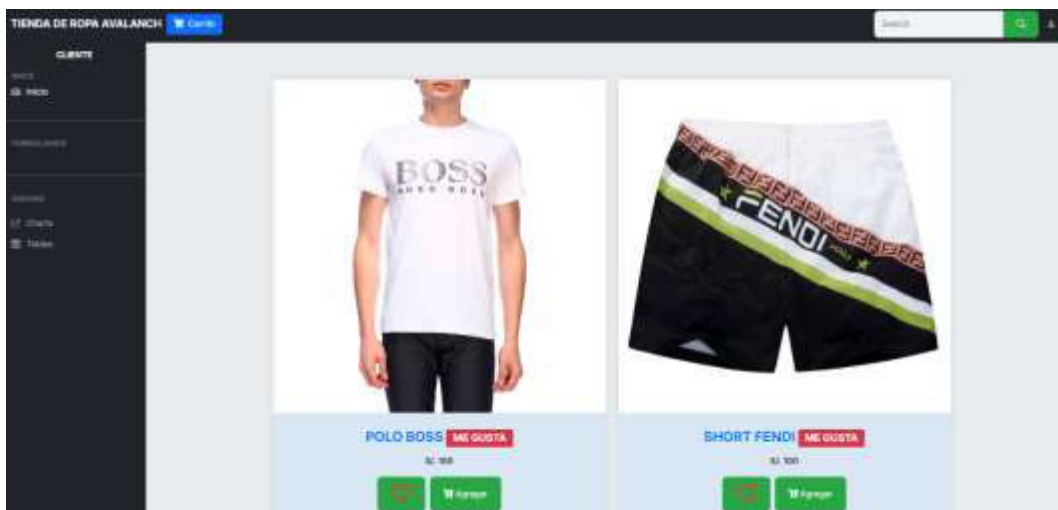


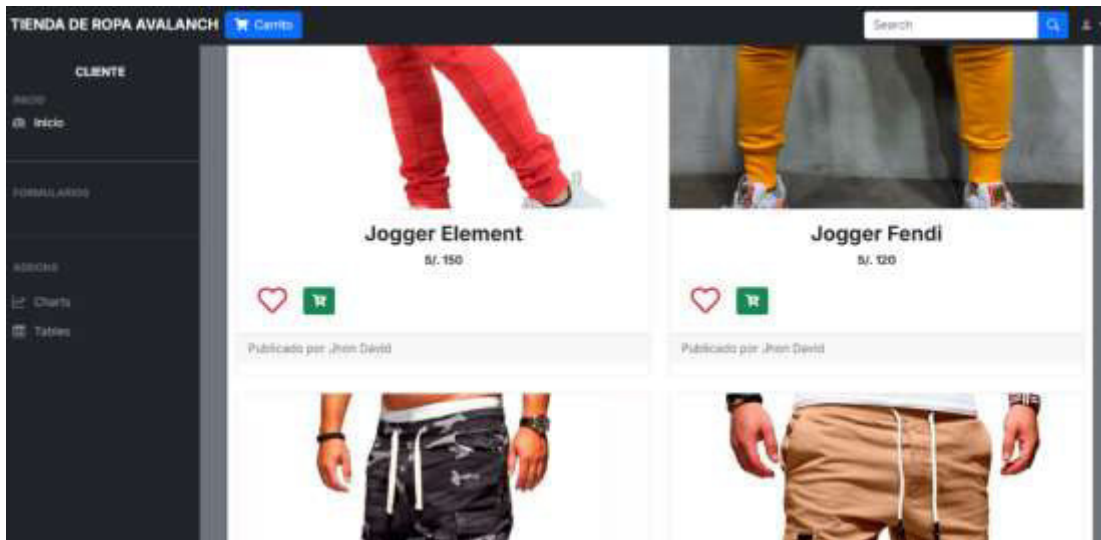
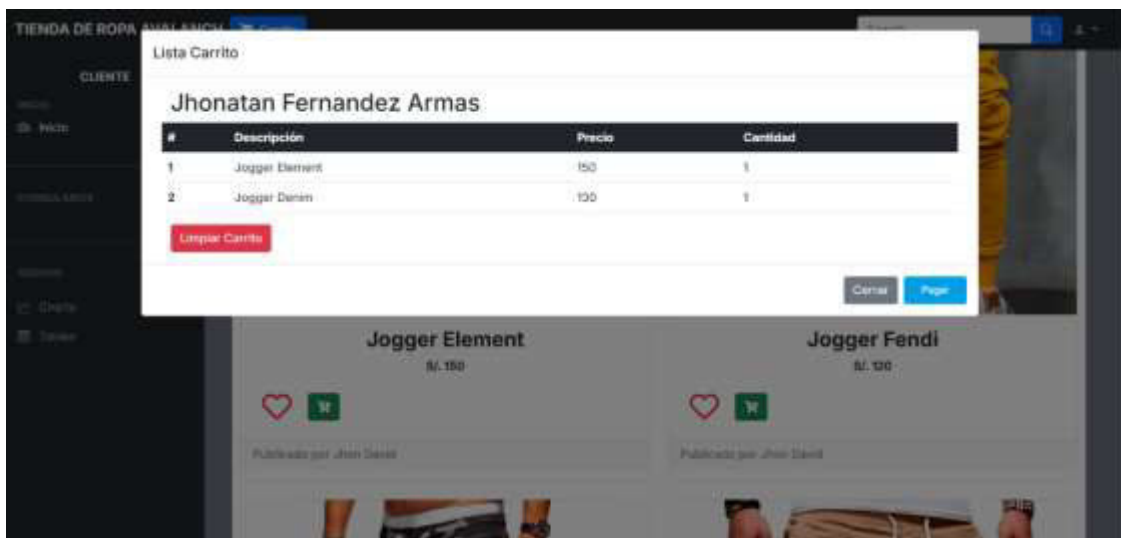
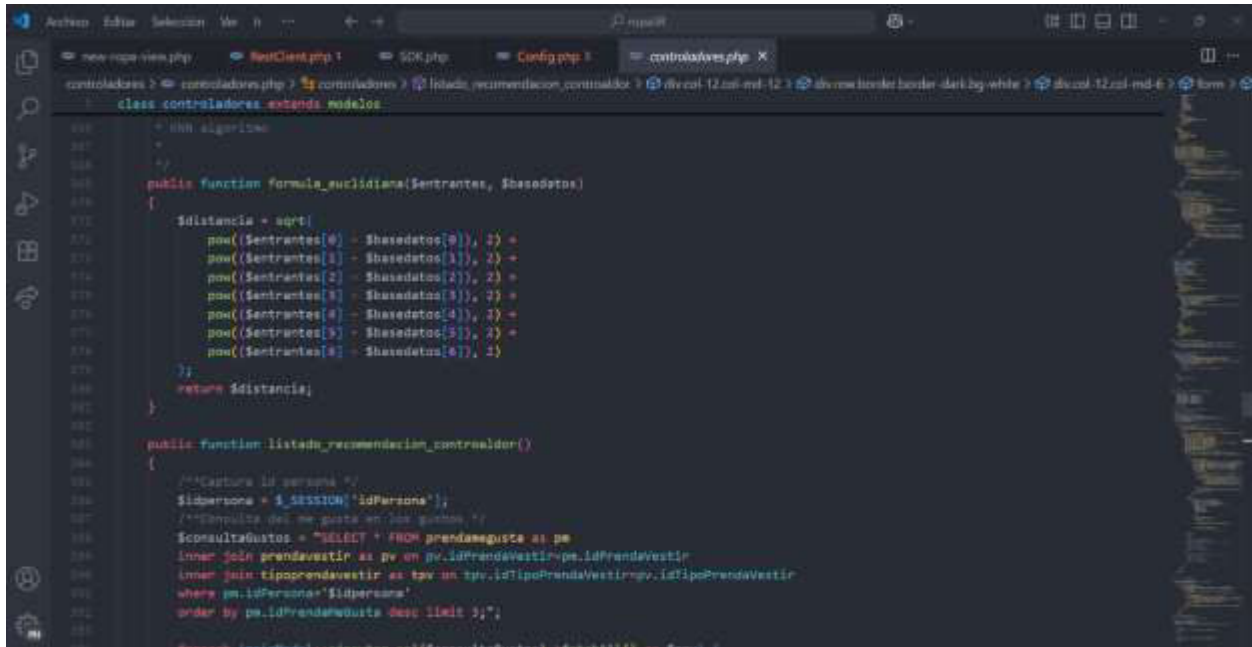
Figura 27*Carrito - tienda de ropa AVALANCH***Figura 28***Lista carrito tienda de ropa AVALANCH*

Figura 29

Configuración tienda ropa AVALANCH



```
class controladores extends modelos
{
    /**
     * @var algebraico
     */
    public function formula_euclidiana($entradas, $susedatos)
    {
        $distancia = sqrt(
            pow(($entradas[0] - $susedatos[0]), 2) +
            pow(($entradas[1] - $susedatos[1]), 2) +
            pow(($entradas[2] - $susedatos[2]), 2) +
            pow(($entradas[3] - $susedatos[3]), 2) +
            pow(($entradas[4] - $susedatos[4]), 2) +
            pow(($entradas[5] - $susedatos[5]), 2) +
            pow(($entradas[6] - $susedatos[6]), 2)
        );
        return $distancia;
    }

    public function listado_recomendacion_controlador()
    {
        /**Captura id persona */
        $idpersona = $_SESSION['idPersona'];
        /**Consulta de los gustos en las guetas */
        $consultaGustos = "SELECT * FROM prendasagusto as pg
        inner join prendasavestir as pv on pv.idPrendaVestir=pg.idPrendaVestir
        inner join tiposprendavestir as tpv on tpv.idTipoPrendaVestir=pg.idTipoPrendaVestir
        where pg.idPersona=$idpersona"
        order by pg.idPrendaAgusto desc limit 3;";
    }
}
```

CAPÍTULO VI: ASPECTOS ECONÓMICOS FINANCIEROS

Presupuesto y Financiamiento de Inversiones y capital de trabajo inicial

Para la ejecución del proyecto se debe contar con presupuesto total de S/. 137,400.00, el financiamiento del proyecto será cubierto con capital propio para el desarrollo e implementación del sistema de recomendación, en la siguiente tabla se muestra los costos.

Tabla 24

Inversiones y capital de trabajo inicial

RECURSOS	MES	COSTO	TOTAL
HUMANOS			
Investigador	2 meses	S/. 3,000.00	S/. 6,000.00
Analista de sistemas	2 meses	S/. 2,500.00	S/. 5,000.00
Programador	6 meses	S/. 2,500.00	S/. 15,000.00
SUBTOTAL			S/. 26,000.00
MATERIAL			
	PERIODO	PAGO	TOTAL
LOGISTICO			
Hosting	Anual	S/. 1,200.00	S/. 1,200.00
Mitigación de riesgos	Una sola vez	S/. 10,000.00	S/. 10,000.00
TOTAL			S/. 37,200.00

Nota. Elaboración Propia.

Con el costo del hosting establecido en la tabla 24 se puede cubrir la infraestructura adecuada para que el sistema de recomendación pueda funcionar con miles de usuarios, el hosting que se necesita incluye servidores VPS de media gama, una base de datos gestionada, almacenamiento y CDN. En el Perú tenemos muchos proveedores de hosting como son: HostingPerú, FussionHost, VPS.com.pe, etc.

Respecto al cálculo presupuestal de la mitigación de riesgos, se está colocando un pago único, la mitigación permite proteger al sistema de ataques, fallas y si es que se tiene pérdida de

información, el costo establecido en el presupuesto incluye backups (NAS + discos), firewall, certificado SSL, etc. Esta inversión es por única vez y garantiza la seguridad del sistema de recomendación que se va alojar.

Presupuesto de Ingresos y Egresos

Tabla 25

Presupuesto de Ingresos y Egresos

Mes	Ingresos (S/.)	Egresos (S/.)	Inversión (S/.)	Flujo de Caja Mensual (S/.)	Flujo Neto Acumulado (S/.)
0	0	0	37,200.00	-37,200.00	-37,200.00
1	6,000.00	2,000.00	0	4,000.00	-33,200.00
2	7,000.00	2,000.00	0	5,000.00	-28,200.00
3	8,500.00	2,000.00	0	6,500.00	-21,700.00
4	10,000.00	2,000.00	0	8,000.00	-13,700.00
5	12,000.00	2,000.00	0	10,000.00	-3,700.00
6	14,000.00	2,000.00	0	12,000.00	8,300.00
7	16,000.00	2,000.00	0	14,000.00	22,300.00
8	18,000.00	2,000.00	0	16,000.00	38,300.00
9	20,000.00	2,000.00	0	18,000.00	56,300.00
10	22,000.00	2,000.00	0	20,000.00	76,300.00
11	24,000.00	2,000.00	0	22,000.00	98,300.00
12	26,000.00	2,000.00	0	24,000.00	122,300.00

Nota. Elaboración propia.

Según la tabla 25 tenemos que la inversión de S/. 37,200.00 se logrará recuperar en el sexto mes ya que a partir de allí el sistema genera ganancias y para un año se tendría acumulado un total de S/. **122,300.00** la cual es muy adecuado la implementación del sistema de recomendación para la empresa Avalanch. Además, la empresa tendría un impacto social adecuado ya que sería la primera empresa en la región San Martín que cuenta con un sistema inteligente que ayuda a generar mejores tomas de decisiones por los usuarios.

Análisis de Riesgos

Determinación de Riesgos del Proyecto

Tabla 26

Riesgos del proyecto

Riesgo	Descripción
R1	Error de conexión del servidor al momento de usar el sistema de recomendación.
R2	Cortes eléctricos, lo cual puede perjudicar los equipos en donde se utiliza el sistema de recomendación.
R3	No contar con servidores en otros países por lo que no se podrá hacer uso del sistema de recomendación.
R4	Riesgo intrusión en el sistema de recomendación
R5	Falta de conexión a Internet, lo que impide el acceso al sistema de recomendación.

Nota. Elaboración Propia.

Propuestas para la Mitigación de Riesgos

Tabla 27

Propuestas para mitigar los riesgos

Riesgo	Descripción de la Propuesta de Mitigación del Riesgo
R1	Verificar los servidores con la finalidad de dar solución a posibles errores de conexión.
R2	Comprar o adquirir un generador de energía eléctrica permitiendo que el sistema funcione sin problemas.
R3	Alquilar servidores en otros países para que el sistema funcione correctamente.
R4	Encriptar campos vulnerables de información vulnerable.
R5	Implementar un modo offline que permita seguir recomendando ropa sin conexión y sincronizar los datos automáticamente al restablecer el servicio.

Nota. Elaboración Propia.

*Presupuesto de Mitigación de Riesgos***Tabla 28***Presupuesto de Mitigación de Riesgos*

RIESGO	ACCIÓN DE MITIGACIÓN	COSTO ESTIMADO	JUSTIFICACIÓN
R1	Verificar y dar mantenimiento preventivo a los servidores para evitar fallas de conexión.	S/. 1,200.00	Tener un servicio técnico adecuado y herramientas de monitoreo.
R2	Adquirir un generador eléctrico de respaldo.	S/. 3,000.00	Permitirá la continuidad del sistema.
R3	Alquilar servidores en otros países para redundancia geográfica	S/. 1,800.00	Se tendrá acceso desde cualquier lugar.
R4	Colocar encriptaciones a los campos vulnerables e implementar más seguridad al sistema.	S/. 2,000.00	Contar con un cifrado de datos como también medidas de intrusión.
R5	Implementar el modo offline y que se sincronice de manera automática.	S/. 2,000.00	Ayuda al usuario a ingresar sin conexión y que se pueda actualizar la información automáticamente.

Nota. Elaboración Propia.

La tabla 28 se detalla el presupuesto para la mitigación de riesgos que se tendrá en cuenta para el sistema de recomendación de ropa, Se muestran las acciones preventivas como también las correctivas para los 5 riesgos identificados con sus costos estimados además este presupuesto ayudará con la continuidad, seguridad y la disponibilidad del sistema de recomendación, aunque no se tenga internet y demás riesgos.

CAPÍTULO VII: ANÁLISIS COSTO-BENEFICIO

Beneficios no financieros

El sistema de recomendación permitirá la optimización en el proceso de recomendación que hacen los trabajadores de la empresa a los clientes, debido a que la recomendación se hará de una manera personalizada, precisa, rápida, etc. La empresa Avalanch podrá ser conocida por los clientes y por ende tener un desarrollo como empresa, otro de los beneficios no financieros es que la empresa utilizando el sistema de recomendación atraerá más clientela porque los clientes se sentirán satisfechos con las recomendaciones brindadas por parte del sistema.

Impacto Social

Contar con un sistema de recomendación de ropa genera un gran impacto social porque ofrece a los clientes sugerencias que son personalizadas de acuerdo a los gustos y preferencias de cada usuario, esto conduce a tener un tiempo de búsqueda menor que lo tradicional mejorando la experiencia de adquisición de un producto. Este tipo de tecnología permite la inclusión al contemplar una diversidad de tallas, colores, diseños, marcas entre otras cosas, permitiendo a que más usuarios encuentren las mejores opciones para ellos.

Con un sistema de recomendación una empresa dedicada a la venta de ropa puede influir de manera positiva en la comunicad porque al ayudar a las personas con la selección de ropa desde su comodidad hará que exista inclusión, ya que se tiene todo tipo de clientes con diferentes gustos y también con limitaciones en tiempo, con el sistema podrán acceder rápido y fácil evitando que los clientes realicen compras innecesarias como disgustos.

Beneficio tecnológico

La implementación de este sistema de recomendación de ropa promueve una mejora tecnológica en los procesos normales de elección de ropa y en las ventas. Esta innovación tecnológica permitirá establecer más beneficio y ventajas en el proceso de ventas, con el fin de atraer a más clientes y de esa forma ampliar el alcance en la comunidad.

Beneficio económico

La implementación del sistema de recomendación de prendas de vestir no solo mejorará de forma significativa la experiencia de compra del cliente, al mismo tiempo tendrá un impacto positivo en el rendimiento económico de la empresa. A medida que se optimiza la personalización y se incrementan las ventas gracias al sistema de recomendación más precisa, se generará un flujo de ingresos adicionales que permitirán reinvertir en áreas claves como marketing, innovación o expansión del catálogo. Este ciclo no solo garantiza una mayor satisfacción del cliente, sino que también fortalece la sostenibilidad financiera de la empresa, asegurando la competitividad en el mercado a mediano y largo plazo.

La inversión realizada para el desarrollo del proyecto, detallada en el capítulo anterior, se recuperará en un plazo estimado de 5 meses.

Evaluación Económica-Financiera

Para realizar el análisis de la viabilidad del proyecto se utilizó el VAN y TIR, Simisterra Quiñonez et al. (2018) mencionan que el VAN mide la viabilidad de un proyecto a desarrollar, es un método más utilizado que permite determinar si la inversión que se desea hacer para un proyecto cumple con el objetivo financiero (maximizar la inversión), la fórmula del Valor Actual Neto es:

$$VAN = \sum_{t=1}^n \frac{F_t}{(1+r)^t} - I_0$$

Donde:

VAN: Valor Actual Neto

F_t : Flujo de cada en el periodo t

r: Tasa de descuento

t: Año o periodo del flujo

n: Número total de periodos (años)

I_0 : Inversión inicial

Supongamos que se tiene los siguientes datos: Inversión inicial es de S/. 137,400.00, la duración se da para 1 año, el flujo de cada esperado al finalizar el año S/. 180.000.00 y la tasa de descuento trabajaremos con el 10 %.

$$VAN = \frac{180,000}{(1 + 0.10)} - 137,400 = \frac{180,000}{1.10} - 137,400$$

$$VAN = 163,636.36 - 137,400 = S/.26,236.36$$

Realizando el cálculo del Van se obtiene S/. 26,236.36, por lo que la inversión producirá ganancias por encima de la rentabilidad y que el proyecto puede ser aceptable.

Vaca et al. (2019) mencionan que el TIR (Tasa Interna de Retorno) es la tasa que hace que el VAN sea igual a cero, es decir es la tasa que iguala a la suma de los flujos descontando la inversión inicial, midiendo la rentabilidad que tiene una inversión en términos porcentuales. Cuando la tasa de rentabilidad de la inversión está por encima de lo exigido la inversión es aceptable (Jeklin, 2016).

$$TIR \frac{180.000}{137,400} - 1 = 0.3101 = 31.01 \%$$

El TIR tiene como resultado el 31.01% concluyendo que el proyecto es viable y que se tendrá ganancias con la implementación del sistema de recomendación de ropa en la empresa Avalanch.

CAPÍTULO VIII. DETERMINACIÓN DE LA VIABILIDAD DEL PROYECTO

Para determinar la viabilidad del sistema de recomendación de ropa en la empresa Avalanch se calcularon los ingresos como también los egresos por un periodo de 12 meses. La inversión inicial fue de S/137,400.00 del cual se analizó el flujo de caja mes a mes. Los resultados demuestran que la empresa podrá generar sus ganancias en el mes 5, cuando el flujo neto pasa del punto negativo al positivo con un total de S/8,640.00, demostrándose un periodo de recuperación adecuado siendo este un indicador debidamente favorable para la ejecución del proyecto en la empresa.

A partir del punto señalado, los ingresos aumentan de manera constante brindando un flujo neto acumulado de S/ 456,116.00 en el mes 12 evidenciándose un crecimiento sostenido de rentabilidad. Asimismo, se desarrolló un cálculo de dos indicadores financieros como son VAN (Valor Actual Neto) con un total de S/. 26,236.36 siendo positivo. TIR (Tasa Interna de Retorno) dando como resultado 31.01 % siendo muy adecuada sabiendo que la tasa mínima esperada esta entre el 15 % y el 20 %, demostrándose que el proyecto es adecuado y financieramente bueno.

Los resultados del VAN y el TIR son positivos lo que indica que la inversión es rentable incluyendo situaciones menos favorables. Estos resultados afirman que la implementación que se plantea en el proyecto sobre un sistema de recomendación no solo es rentable en lo financiero, sino que generará un impacto positivo en los clientes, fidelizándolos y brindándoles una mejor experiencia de tal manera la empresa Avalanch tendrá una mejor consolidación dentro del mercado competitivo.

CAPÍTULO IX CONCLUSIONES Y RECOMENDACIONES

Conclusiones

En conclusión, la implementación de un sistema de recomendación personalizada haciendo uso del algoritmo K-Vecinos Más Cercanos (KNN) ha mostrado ser un algoritmo eficaz para el análisis del comportamiento de compra que realizan los clientes en la empresa Avalanch, teniendo en cuenta los gustos y preferencias de manera individual. Este planteamiento ayuda significativamente la experiencia de realizar una compra porque ofrece opciones que son relevantes y de acuerdo a las necesidades de cada usuario, permitiendo el incremento de ventas, la fidelización de clientes y la atracción de nuevos clientes.

Además, la formación de indicadores de desempeño ayudó a verificar de manera objetiva el impacto del sistema de recomendación. Se logró observar el crecimiento en la tasa de conversión, también la frecuencia de compra, la atracción de nuevos clientes y la satisfacción de los clientes de la empresa, con ello podemos evidenciar que las recomendaciones generadas no solo ayudan al factor económico de la empresa o a las ventas, sino que también mejoran la percepción y compromiso del cliente en la empresa Avalanch.

Finalmente, el algoritmo KNN ha demostrado tener una precisión al momento de realizar una recomendación además si se establece un ciclo de aprendizaje continuo, el sistema se podrá adaptar adecuadamente a las preferencias cambiantes de los clientes, ayudando que las sugerencias que brinde el sistema de recomendación sean más precisa y personalizada lo que favorece la sostenibilidad como también el éxito del proyecto a un largo plazo.

Recomendaciones

Se recomienda que se brinde capacitaciones continuas al personal de la empresa Avalanch sobre el uso del sistema de recomendación, para que puedan tener profundo conocimientos de todas las funciones y sus beneficios, ayudando con el uso correcto y evitar errores operativos.

Se recomienda realizar campañas de difusión utilizando las redes sociales con el propósito de promover el uso del sistema de tal modo se logre fomentar la interacción con los usuarios o clientes.

Se recomienda contar con un monitoreo y mejora constante del sistema para revisar de manera periódica que resultados se está obteniendo, ya sea en las ventas, en las preferencias que tienen los clientes, etc. Ya que de esa manera se podrá brindar ajustes oportunos y tener una mejor precisión de las recomendaciones que el sistema genere.

REFERENCIAS

- Ahuja, R., Solanki, A., & Nayyar, A. (2019). Movie recommender system using k-means clustering and k-nearest neighbor. *Proceedings of the 9th International Conference On Cloud Computing, Data Science and Engineering, Confluence 2019*, 263–268. <https://doi.org/10.1109/CONFLUENCE.2019.8776969>
- Alamdari, P. M., Navimipour, N. J., Hosseinzadeh, M., Safaei, A. A., & Darwesh, A. (2020). A Systematic Study on the Recommender Systems in the E-Commerce. *IEEE Access*, 8, 115694–115716. <https://doi.org/10.1109/ACCESS.2020.3002803>
- Alian, S., Li, J., & Pandey, V. (2018). A Personalized Recommendation System to Support Diabetes Self-Management for American Indians. *IEEE Access*, 6, 73041–73051. <https://doi.org/10.1109/ACCESS.2018.2882138>
- Arroyo-Paz, A., Alemán-Gonzales, L., Ingaluque-Arapa, M., Tapia-Catacora, P., Jiménez-Chura, A., Marca-Maquera, H., & Rodríguez-Aburto, C. (2024). Modelo clasificador de prendas de vestir basado en redes neuronales. 22nd LACCEI International Multi-Conference for Engineering, Education, and Technology: Sustainable Engineering for a Diverse, Equitable, and Inclusive Future at the Service of Education, Research, and Industry for a Society 5.0. San José, Costa Rica. <https://doi.org/10.18687/LACCEI2024.1.1.1293>
- Batmaz, Z., Yurekli, A., Bilge, A., & Kaleli, C. (2019). A review on deep learning for recommender systems: challenges and remedies. *Artificial Intelligence Review*, 52(1). <https://doi.org/10.1007/s10462-018-9654-y>
- Beheshti, A., Yakhchi, S., Mousaeirad, S., Ghafari, S. M., Goluguri, S. R., & Edrisi, M. A. (2020). Towards cognitive recommender systems. *Algorithms*, 13(8). <https://doi.org/10.3390/A13080176>

- Bron Fonseca, B., & Mar Cornelio, O. (04 de 2022). SISTEMAS DE RECOMENDACIÓN PARA LA TOMA DE DECISIONES. ESTADO DEL ARTE. *UNESUM-Ciencias: Revista Científica Multidisciplinaria*, 6(1), 16. doi:<https://orcid.org/0000-0001-9463-8408>
- Cai, Y., & Zhu, D. (2019). Trustworthy and profit: A new value-based neighbor selection method in recommender systems under shilling attacks. *Decision Support Systems*, 124(March), 113112. <https://doi.org/10.1016/j.dss.2019.113112>
- Chakraborty, S., Hoque, M. S., Rahman Jeem, N., Biswas, M. C., Bardhan, D., & Lobaton, E. (2021). Fashion Recommendation Systems, Models and Methods: A Review. *Informatics*, 8(3), 49. <https://doi.org/10.3390/informatics8030049>
- Chen, J., Li, K., Rong, H., Bilal, K., Yang, N., & Li, K. (2018). A disease diagnosis and treatment recommendation system based on big data mining and cloud computing. *Information Sciences*, 435, 124–149. <https://doi.org/10.1016/j.ins.2018.01.001>
- Ccoyccosi Choque, R. A., Huanay Palomino, L. E., Huayllasco Chafloque, E. D., Loayza Díaz, V., & Mayorga López, K. F. (2021). *Propuesta de un modelo de Machine Learning para el pronóstico de la demanda de prendas de vestir en la Corporación Brusko S.A.C.* Trabajo de suficiencia profesional, Universidad ESAN. Repositorio institucional ESAN.
- Chowdhury, K., Chaudhuri, D., & Pal, A. K. (2021). An entropy-based initialization method of K-means clustering on the optimal number of clusters. *Neural Computing and Applications*, 33(12), 6965–6982. <https://doi.org/10.1007/s00521-020-05471-9>
- Cruz Chamorro, R. (2025). Sistema web para la gestión de asistencia del personal administrativo en el hospital Rezola Cañete ;2024. *ULADECH*. Recuperado el 20 de 04 de 2025, de <https://repositorio.uladech.edu.pe/handle/20.500.13032/39088>
- Das, N., Borra, S., Dey, N., & Borah, S. (2018). Social Networking in Web Based Movie

- Recommendation System. *Social Networks Science: Design, Implementation, Security, and Challenges*, 25–45. https://doi.org/10.1007/978-3-319-90059-9_2
- del Carmen Rodríguez-Hernández, M., Ilarri, S., Hermoso, R., & Trillo-Lado, R. (2017). DataGenCARS: A generator of synthetic data for the evaluation of context-aware recommendation systems. *Pervasive and Mobile Computing*, 38, 516–541. <https://doi.org/10.1016/j.pmcj.2016.09.020>
- Fayyaz, Z., Ebrahimian, M., Nawara, D., Ibrahim, A., & Kashef, R. (2020). Recommendation systems: Algorithms, challenges, metrics, and business opportunities. *Applied Sciences (Switzerland)*, 10(21), 1–20. <https://doi.org/10.3390/app10217748>
- Felfernig, A., Polat-Erdeniz, S., Uran, C., Reiterer, S., Atas, M., Tran, T. N. T., Azzoni, P., Kiraly, C., & Dolui, K. (2019). An overview of recommender systems in the internet of things. *Journal of Intelligent Information Systems*, 52(2), 285–309. <https://doi.org/10.1007/s10844-018-0530-7>
- Ferrando Huertas, J. (2021). *Sistemas de recomendación en la industria de la moda con especial enfoque en el tiempo y la estacionalidad*. Tesis de maestría, Universidad Politécnica de Valencia. Repositorio Institucional UPV.
- Frederick Hayes, R., & Neil, J. (1994). The State of Knowledge-Based Systems. *knowledge engineering systems*, 14.
- Freund, Y., Iyer, R., Schapire, R. E., & Singer, Y. (2004). An efficient boosting algorithm for combining preferences. *Journal of Machine Learning Research*, 4(6), 933–969. <https://doi.org/10.1162/1532443041827916>
- Fuster Olivera, G. (2023). Desarrollo de un sistema recomendador para la compra de ropa online. Trabajo de fin de grado, Universidad Pontificia Comillas. Repositorio Institucional ICAI.

- Galán, S. M. (2007). Filtrado Colaborativo y Sistemas de Recomendación. *IRC 2007, Universidad Carlos III de Madrid*, 1–8.
- Garriga Domínguez, A. (07 de 07 de 2023). Las exigencias de transparencia para los sistemas algorítmicos de recomendación, selección de contenidos y publicidad en línea en el nuevo Reglamento Europeo de Servicios Digitales. *Revista Española de la Transparencia*(17), 28. doi:DOI: <https://doi.org/10.51915/ret.309>
- George, G., & Lal, A. M. (2019). Review of ontology-based recommender systems in e-learning. *Computers and Education*, 142(July 2018), 103642. <https://doi.org/10.1016/j.compedu.2019.103642>
- Germain Ramirez, C. (2020). *Desarrollo de aplicaciones web utilizando JavaScript*. Tesina, Universidad Politécnica de Sinaloa Programa Académico de Ingeniería en Informática, Mazatlán, Sinaloa. Recuperado el 20 de 04 de 2025, de <http://repositorio.upsin.edu.mx/formatos/A064GERMAINRAMIREZCRISTALESMERALDA7569.pdf>
- González Velásquez, C., Vásquez Bernal, B., De las Heras Pérez, M., Mena Salcedo, J., Osorio Higuera, M., & Murillo Escobar, J. (2025). La actividad electroencefalográfica asociada a la relación entre carga cognitiva, estrés y reconocimiento de emociones en un grupo focal de profesores universitarios de ciencias experimentales. *Journal of Neuroeducation*, 20. Recuperado el 21 de 04 de 2025, de <https://revistes.ub.edu/index.php/joned/article/view/46837/43193>
- Hamid, R. A., Albahri, A. S., Alwan, J. K., Al-Qaysi, Z. T., Albahri, O. S., Zaidan, A. A., Alnoor, A., Alamoodi, A. H., & Zaidan, B. B. (2021). How smart is e-tourism? A systematic review of smart tourism recommendation system applying data management. *Computer Science*

Review, 39, 100337. <https://doi.org/10.1016/j.cosrev.2020.100337>

Harikumar, S., & Dilipkumar, D. U. (2017). Apriori algorithm for association rule mining in high dimensional data. *Proceedings of the 2016 International Conference on Data Science and Engineering, ICDSE 2016*. <https://doi.org/10.1109/ICDSE.2016.7823952>

Holguera, F. P., G, J. A., & Dur, A. (2018). Computación empotrada de funciones de los sistemas de recomendación mediante FPGAs. *Jornadas Sarteco 2018*.

Horton, E., & Parnin, C. (2018). Gistable: Evaluating the executability of python code snippets on github. *Proceedings - 2018 IEEE International Conference on Software Maintenance and Evolution, ICSME 2018*, 217–227. <https://doi.org/10.1109/ICSME.2018.00031>

James and others, M. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1(14), 281–297.

[http://books.google.de/books?hl=de&lr=&id=IC4Ku_7dBFUC&oi=fnd&pg=PA281&dq=MacQueen+some+methods+for+classification&ots=nNTcK1IdoQ&sig=fHzdVcbvmYJ-ITNHu1HncmOFOkM#v=onepage&q=MacQueen some methods for classification&f=false](http://books.google.de/books?hl=de&lr=&id=IC4Ku_7dBFUC&oi=fnd&pg=PA281&dq=MacQueen+some+methods+for+classification&ots=nNTcK1IdoQ&sig=fHzdVcbvmYJ-ITNHu1HncmOFOkM#v=onepage&q=MacQueen+some+methods+for+classification&f=false)

Jeklin, A. (2016). 済無 No Title No Title No Title. *July*, 1–23.

Kurniawan. (2017). No Title 日本の国立公園に関する3拙著に対する土屋俊幸教授の批評に答える. *経済志林*, 87(1,2), 149–200.

Li, W., Gong, G., Fan, H., Peng, P., & Chun, L. (2020). Meta-learning strategy based on user preferences and a machine recommendation system for real-time cooling load and COP forecasting. *Applied Energy*, 270(April), 115144. <https://doi.org/10.1016/j.apenergy.2020.115144>

- Liberati, A., Altman, D., Tetzlaff, J., Mulrow, C., Gotzsche, P., Loannidis, J., Clarke, M., Devereaux, P., Kleijnen, J., & Moher, D. (2018). Enhanced Reader.pdf. In *Nature* (Vol. 388, pp. 539–547).
- Llosá Cea, G. (2023). Sistema de recomendación de moda basado en atributos multimodales. Trabajo de fin de grado, Universidad Politécnica de Madrid. Repositorio institucional.
- Lops, P., Jannach, D., Musto, C., Bogers, T., & Koolen, M. (2019). Trends in content-based recommendation: Preface to the special issue on Recommender systems based on rich item descriptions. *User Modeling and User-Adapted Interaction*, 29(2), 239–249. <https://doi.org/10.1007/s11257-019-09231-w>
- Lynch, R. L. (2014). *Journal of Vocational and Technical Education*. 1, 1–9.
- Melgarejo Paucar, R. A. (2023). Sistema de recomendación de prendas basado en reconocimiento corporal (SISCORP). Trabajo de suficiencia profesional, Universidad de Lima. Repositorio institucional de la Universidad de Lima.
- Mendoza Olguín, G., Laureano De Jesús, Y., & Pérez de Celis Herrero, M. C. (2019). Métricas de similitud y evaluación para sistemas de recomendación de filtrado colaborativo. *Revista de Investigación En Tecnologías de La Información*, 7(14), 224–240. <https://doi.org/10.36825/riti.07.14.019>
- Misilmani, H. M. E., & Naous, T. (2019). Machine Learning in Antenna Design: An Overview on Machine Learning Concept and Algorithms. *2019 International Conference on High Performance Computing and Simulation, HPCS 2019*, 600–607. <https://doi.org/10.1109/HPCS48598.2019.9188224>
- Mohamed, M. H., Khafagy, M. H., & Ibrahim, M. H. (2019). Recommender Systems Challenges and Solutions Survey. *Proceedings of 2019 International Conference on Innovative Trends*

in *Computer Engineering, ITCE 2019, February*, 149–155.
<https://doi.org/10.1109/ITCE.2019.8646645>

Muslim Sinaga, R., Sovantri Putra, P., & Dedy Kiswanto. (2025). IMPLEMENTASI CI/CD MENGGUNAKAN JENKINS PADA APLIKASI DI LINGKUNGAN PENGEMBANGAN FEDORA WORKSTATION40. *Jurnal Mahasiswa Teknik Informatika*, 9(1), 8. Recuperado el 20 de 04 de 2025, de <https://www.ejournal.itn.ac.id/index.php/jati/article/view/12624/7001>

Mustafa, N., Ibrahim, A. O., Ahmed, A., & Abdullah, A. (2017). Collaborative filtering: Techniques and applications. *Proceedings - 2017 International Conference on Communication, Control, Computing and Electronics Engineering, ICCCEE 2017*. <https://doi.org/10.1109/ICCCEE.2017.7867668>

Nathoo, A., Gangabissoon, T., & Bekaroo, G. (2019). Exploring the Use of Tangible User Interfaces for Teaching Basic Java Programming Concepts: A Usability Study. *2nd International Conference on Next Generation Computing Applications 2019, NextComp 2019 - Proceedings*, 1–5. <https://doi.org/10.1109/NEXTCOMP.2019.8883563>

Nichol, M. B., Knight, T. K., Dow, T., Wygant, G., Borok, G., Hauch, O., & O'Connor, R. (2008). Quality of anticoagulation monitoring in nonvalvular atrial fibrillation patients: Comparison of anticoagulation clinic versus usual care. *Annals of Pharmacotherapy*, 42(1), 62–70. <https://doi.org/10.1345/aph.1K157>

Orellana Cordero, M. P., & Cedillo, P. (2020). Detección de valores atípicos con técnicas de minería de datos y métodos estadísticos. *Enfoque UTE*, 11(1), 56–67. <https://doi.org/10.29019/enfoque.v11n1.584>

Palma, J. T., Paniagua, E., Martin, F., & Marin, R. (2000). Ingeniería del Conocimiento. De la

- Extracción al Modelado de Conocimiento. *Inteligencia Artificial*, 4(11).
<https://doi.org/10.4114/ia.v4i11.690>
- Patel, K., & Patel, H. B. (2020). A state-of-the-art survey on recommendation system and prospective extensions. *Computers and Electronics in Agriculture*, 178(June), 105779.
<https://doi.org/10.1016/j.compag.2020.105779>
- Patel, L., & Gaurav, K. A. (2029). Introduction to Machine Learning and Its Application. *Proceedings of 10th International Conference on Digital Strategies for Organizational Success*, 262–290. <https://doi.org/10.4018/978-1-7998-2718-4.ch014>
- Paudel, A., Bajracharya, B. R., Ghimire, M., Bhattarai, N., & Baral, D. S. (2018). Using Personality Traits Information from Social Media for Music Recommendation. *Proceedings on 2018 IEEE 3rd International Conference on Computing, Communication and Security, ICCCS 2018*, 116–121. <https://doi.org/10.1109/CCCS.2018.8586831>
- Phorasim, P., & Yu, L. (2017). Movies recommendation system using collaborative filtering and k-means. *International Journal of Advanced Computer Research*, 7(29), 52–59.
<https://doi.org/10.19101/IJACR.2017.729004>
- Pimenidis, E., Polatidis, N., & Mouratidis, H. (2019). Mobile recommender systems: Identifying the major concepts. *Journal of Information Science*, 45(3), 387–397.
<https://doi.org/10.1177/0165551518792213>
- Powell, C. (2003). The Delphi technique: Myths and realities. *Journal of Advanced Nursing*, 41(4), 376–382. <https://doi.org/10.1046/j.1365-2648.2003.02537.x>
- Rahimi, N., Eassa, F., & Elrefaei, L. (2020). An ensemble machine learning technique for functional requirement classification. In *Symmetry* (Vol. 12, Issue 10, pp. 1–26).
<https://doi.org/10.3390/sym12101601>

- Rawat, B., Samriya, J. K., Pandey, N., & Wariyal, S. C. (2020). A comprehensive study on recommendation systems their issues and future research direction in e-learning domain. *Materials Today: Proceedings*, *xxxx*. <https://doi.org/10.1016/j.matpr.2020.09.796>
- Razia Sulthana, A., & Ramasamy, S. (2019). Ontology and context based recommendation system using Neuro-Fuzzy Classification. *Computers and Electrical Engineering*, *74*, 498–510. <https://doi.org/10.1016/j.compeleceng.2018.01.034>
- Raziperchikolaei, R., Li, T., & Chung, Y. (2020). *Neural Representations in Hybrid Recommender Systems: Prediction versus Regularization. I*, 1743–1747. <http://arxiv.org/abs/2010.06070>
- Ren, Y., Hu, J., & Deng, W. (2018). Facial expression intensity estimation based on cnn features and RankBoost. *Proceedings - 4th Asian Conference on Pattern Recognition, ACPR 2017*, 494–499. <https://doi.org/10.1109/ACPR.2017.109>
- Rodríguez-Lora, V., & Valencia Arias, A. (2018). ¿Cómo se aplica la ingeniería del conocimiento en la investigación de mercados? Estudio de caso. *Ingeniare. Revista Chilena de Ingeniería*, *26*(3), 499–513. <https://doi.org/10.4067/s0718-33052018000300499>
- Romero, J. G., Riveros, O. A., & Herrera, J. F. (2017). Implementación de la Técnica de los K-Vecinos en un Algoritmo Recomendador para un Sistema de Compras Utilizando NFC y Android. *Inge Cuc*, *13*(1), 9–18. <https://doi.org/10.17981/ingecuc.13.1.2017.01>
- Rus Gómez, G. (2024). Sistemas de recomendación basados en aprendizaje automático aplicados al comercio electrónico [Trabajo de fin de máster, Universidad Politécnica de Madrid]. Repositorio Digital UPM.
- Rutkowski, T., Romanowski, J., Woldan, P., Staszewski, P., Nielek, R., & Rutkowski, L. (2018). A content-based recommendation system using neuro-fuzzy approach. *IEEE International Conference on Fuzzy Systems, 2018-July*. <https://doi.org/10.1109/Fuzz-Ieee.2018.8491543>

- Salgado Reyes, N., & Trujillo Moreno, G. E. (2024). Sistemas de recomendación personalizados: implementación de sistemas de recomendación utilizando técnicas de aprendizaje automático para mejorar la experiencia del usuario en plataformas en línea. *Polo del Conocimiento*, 9(1), 1986–1997. <https://doi.org/10.23857/pc.v9i1.6477>
- Shah, K., Salunke, A., Dongare, S., & Antala, K. (2018). Recommender systems: An overview of different approaches to recommendations. *Proceedings of 2017 International Conference on Innovations in Information, Embedded and Communication Systems, ICIECS 2017, 2018-Janua*, 1–4. <https://doi.org/10.1109/ICIECS.2017.8276172>
- Sharma, S., Koehl, L., Bruniaux, P., & Zeng, X. (2019). Garment Fashion Recommendation System for Customized Garment. *Proceedings of the 2019 International Conference on Industrial Engineering and Systems Management, IESM 2019*, 1–6. <https://doi.org/10.1109/IESM45758.2019.8948164>
- Shin, Y. G., Yeo, Y. J., Sagong, M. C., Ji, S. W., & Ko, S. J. (2019). Deep fashion recommendation system with style feature decomposition. *IEEE International Conference on Consumer Electronics - Berlin, ICCE-Berlin, 2019-Septe*, 301–305. <https://doi.org/10.1109/ICCE-Berlin47944.2019.8966228>
- Shokeen, J., & Rana, C. (2020). A study on features of social recommender systems. *Artificial Intelligence Review*, 53(2), 965–988. <https://doi.org/10.1007/s10462-019-09684-w>
- Simisterra Quiñonez, É. P., Rosa Monserrate, R. A., & Suárez López, S. C. (2018). La viabilidad de un proyecto, el valor actual neto (VAN) y la tasa interna de retorno (TIR). *Pro Sciences: Revista de Producción, Ciencias e Investigación*, 2(17), 9–15. <https://doi.org/10.29018/issn.2588-1000vol2iss17.2018pp9-15>

- Toga Abdi, H., Nurhidaya, A., Nirwana, Bambang Pramono, & Isnawaty. (01 de 06 de 2025). PERANCANGAN ULANG SISTEM INFORMASI BALAI PENJAMINAN MUTU PENDIDIKAN. *Jurnal Sistem Informasi dan Sistem Komputer*, 10(1), 13. doi:10.51717/simkom.v10i1.555
- Torres López, P. A. (2024). Sistema de recomendaciones inteligentes para la selección de productos en tiendas retail, Lima 2024. Tesis para optar el título profesional, Universidad César Vallejo. Repositorio institucional UCV.
- Torres Segovia, E. E. (2024). Sistema web basado en un modelo de recomendación de Machine Learning para apoyar el proceso de ventas en una ferretería. Tesis de título profesional, Universidad Católica Santo Toribio de Mogrovejo. Repositorio institucional USAT.
- Trampert, L., Weber, D., Gerlach, L., Rossow, C., & Shwarz, M. (2025). Cascading Spy Sheets: Exploiting the Complexity of Modern CSS for Email and Browser Fingerprinting. *Cispa*. doi:<https://doi.org/10.60882/cispa.27194472.v3>
- Vaca, L. M. F., Guerrero, M. F. G., Fajardo, C. E. V., Vaca, L. A. F., Santillán, X. L. Z., Granda, L. E. S., & Salazar, J. A. P. (2019). Valor actual neto y tasa interna de retorno como parámetros de evaluación de las inversiones. *Investigacion Operacional*, 40(4), 469–474.
- Vargas, P., & Leiva, J. L. (2015). Prototipo de sistema de recomendación grupal en un destino. *ROTUR, Revista de Ocio y Turismo*, 9, 62–81.
- Vega Moreno, B. (10 de 2021). Diseño y desarrollo de un sistema de recomendación basado en filtrado colaborativo utilizando datos secuenciales mediante redes neuronales recurrentes. Cuenca, Ecuador. Recuperado el 20 de 04 de 2025, de <https://dspace.ups.edu.ec/bitstream/123456789/21209/4/UPS-CT009318.pdf>
- Vizcarra Casas, C. A., & Medina Quevedo, G. A. (2020). Implementación de un asistente virtual

- de modas con el uso de una cámara Kinect v2 y procesamiento de imágenes. Universidad Peruana de Ciencias Aplicadas. Repositorio institucional UPC.
<http://hdl.handle.net/10757/653659>
- Walek, B., & Fojtik, V. (2020). A hybrid recommender system for recommending relevant movies using an expert system. *Expert Systems with Applications*, 158, 113452.
<https://doi.org/10.1016/j.eswa.2020.113452>
- Wang, C., Zheng, Y., Jiang, J., & Ren, K. (2018). Toward Privacy-Preserving Personalized Recommendation Services. *Engineering*, 4(1), 21–28.
<https://doi.org/10.1016/j.eng.2018.02.005>
- Wu, C. S. M., Garg, D., & Bhandary, U. (2019). Movie Recommendation System Using Collaborative Filtering. *Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS, 2018-Novem*, 11–15.
<https://doi.org/10.1109/ICSESS.2018.8663822>
- Zhang, G., Liu, Y., & Jin, X. (2020). A survey of autoencoder-based recommender systems. *Frontiers of Computer Science*, 14(2), 430–450. <https://doi.org/10.1007/s11704-018-8052-6>
- Zitouni, H., Meshoul, S., & Mezioud, C. (2020). New contextual collaborative filtering system with application to personalized healthy nutrition education. *Journal of King Saud University - Computer and Information Sciences*, xxxx. <https://doi.org/10.1016/j.jksuci.2020.04.012>

ANEXOS

Anexo 1

Requerimientos no funcionales del sistema

Requerimiento	Descripción de los RNF
RNF01	El Sistema deberá estar desarrollado en PHP.
RNF02	El Sistema deberá ser amigable para el usuario.
RNF03	El Sistema deberá adecuarse a otros dispositivos electrónicos sin perder su diseño (Responsive).
RNF04	El Sistema deberá generar reportes en formato PDF de la recomendación realizada al usuario.

Anexo 2

Interface del CUS Registrar Prendas de Vestir

The screenshot shows a web browser window with the URL 'localhost:3000/registro-prenda-ropa'. The page title is 'TIENDA DE ROPA AVALANCH' and the user is logged in as 'Carla'. The main content is a form titled 'Registro de prenda de vestir' with the following fields:

- Subir imagen ***: A file upload field with the text 'Ningún archivo seleccionado'.
- Nombre de la prenda ***: A text input field with the example 'Camiseta para hombre'.
- Precio de la prenda ***: A text input field with the example '120.000'.
- Diseño ***: A dropdown menu with the text 'Seleccione el diseño de la prenda'.
- Marca ***: A dropdown menu with the text 'Seleccione la marca de la prenda'.
- Talla ***: A dropdown menu with the text 'Seleccione la talla de la prenda'.
- Tipo de prenda ***: A dropdown menu with the text 'Seleccione el tipo de prenda'.
- Color ***: A dropdown menu with the text 'Seleccione el color de la prenda'.
- Fibra ***: A dropdown menu with the text 'Seleccione la fibra de la prenda'.
- Descripción ***: A rich text editor with a toolbar and a text area.

A green 'Registrar' button is located at the bottom of the form.

Anexo 3

Interface del CUS Registrar Trabajador

The screenshot shows the 'Registrar Trabajador' interface. The page title is 'TIENDA DE ROPA AVALANCH' and the user is logged in as 'ADMINISTRADOR'. The interface is divided into a sidebar menu and a main content area.

Datos Personales

Nombre	Apellido Paterno	Apellido Materno
DNI	Fecha Nacimiento	Sexo
Estado Civil	Celular	Direccion

Datos de la cuenta

Usuario	Tipo de usuario	Ingresa una contraseña
Confirma la contraseña	Selecciona el tipo de usuario	

A green button labeled 'Crear Cuenta' is located at the bottom of the form.

Anexo 4

Interface de Generar Reporte de Recomendación

The screenshot shows the 'Generar Reporte de Recomendación' interface. The page title is 'TIENDA DE ROPA AVALANCH' and the user is logged in as 'ADMINISTRADOR'. The interface is divided into a sidebar menu and a main content area.

Lista de Cliente

#	Cliente	Creado	Numero	Likees
1	Piero	2021-10-28 18:20:04	901234567	Reportes
2	Alexander	2021-10-28 18:22:48	916971819	Reportes
3	Darwin	2021-10-28 19:03:30	910433230	Reportes
4	Martin	2021-10-28 19:03:30	824567890	Reportes
5	Stray	2021-10-28 21:38:13	942345678	Reportes
6	Nikoli	2021-10-28 21:40:33	912309221	Reportes
7	Mia	2021-10-28 21:43:02	833456789	Reportes
8	Jorge	2021-10-28 21:25:17	886234443	Reportes
9	Jorge	2021-10-28 21:33:20	90598779	Reportes
10	Jonatan	2021-10-28 21:36:44	91009322	Reportes
11	Rene	2021-11-26 15:54:48	92767890	Reportes

