

**Desarrollo de un prototipo de aplicación web para la implementación de un sistema de
recomendación de ropa basado en el bienestar emocional del usuario mediante la
integración de la economía conductual**

**Diego Fernando Llanos Mondragon
Jordi Santiago Ledesma Arboleda**

**Universidad del Valle
Escuela de Ingeniería en Sistemas y Computación
Ingeniería de Sistemas
Sede Tuluá
2025-I**

**Desarrollo de un prototipo de aplicación web para la implementación de un sistema de
recomendación de ropa basado en el bienestar emocional del usuario mediante la
integración de la economía conductual**

Diego Fernando Llanos Mondragon
Código 202060029
diego.llanos@correounivalle.edu.co

Jordi Santiago Ledesma Arboleda
Código 202059994
jordi.ledesma@correounivalle.edu.co

Director
Ph.D. William Roldan Piedrahita

Universidad del Valle
Escuela de Ingeniería en Sistemas y Computación
Ingeniería de Sistemas
Sede Tuluá
2025-I

Trabajo de Grado presentado por
Diego Fernando Llanos Mondragon
Jordi Santiago Ledesma Arboleda
Como requisito parcial para la obtención del título de Ingeniería de Sistemas

Ph.D. William Roldan Piedrahita
Director

Jurado

Jurado

Queremos expresar nuestro agradecimiento a todas las personas que han sido fundamentales en el desarrollo de este proyecto. A nuestros padres, por su apoyo incondicional y su confianza constante, que nos han dado la fuerza para seguir adelante, incluso en los momentos más difíciles. Su amor y ejemplo han sido una fuente continua de motivación. A nuestro director, el Profesor William Roldan Piedrahita, por su guía y paciencia en cada etapa del proyecto. Su disposición para compartir sus conocimientos y su crítica constructiva nos permitió mejorar y alcanzar nuestros objetivos con rigor. Finalmente, agradecemos a nuestra universidad, Universidad del Valle, por proporcionarnos un entorno académico que favoreció nuestro crecimiento profesional y personal, brindándonos las herramientas necesarias para llevar a cabo esta investigación.

Tabla de Contenido

1. Introducción	2
1.1. Formulación del problema	2
1.2. Descripción del problema	2
1.3. Objetivos	4
1.3.1. Objetivo general	4
1.3.2. Objetivos específicos	4
1.4. Resultados esperados	4
1.5. Metodología	5
1.6. Información sobre los capítulos	7
2. Alcance del proyecto	8
2.1. Alcance	8
3. Marco referencial	10
3.1. Marco Teórico	10
3.1.1. Computación Afectiva	10
3.1.2. Inteligencia Emocional	10
3.1.3. Economía Conductual	11
3.1.4. Sistemas de Recomendación	11
3.1.5. Análisis de Sentimientos	11
3.1.6. Modelado de Emociones	11
3.1.7. Interacción Humano-Computadora	12
3.1.8. Psicología del Usuario	12
3.2. Marco Conceptual	13
3.2.1. Diseño de la Aplicación Web de Recomendación de Ropa	13
3.2.2. Evaluación de la Experiencia del Usuario	13
3.2.3. Diseño de Algoritmos de Análisis de Emociones	13
3.2.4. Personalización de Recomendaciones Basadas en Emociones	13
3.2.5. Evaluación de la Eficacia del Sistema	13
3.2.6. Diseño de Interfaces de Usuario Emocionalmente Inteligentes	14
3.2.7. Implementación de Principios de Economía Conductual	14
4. Diseño de aplicación web y modelo emocional	15
4.1. Modelo emocional y detección afectiva	15
4.2. Asociación entre emociones y colores	16
4.3. Flujo de funcionamiento del sistema	17
4.4. Dataset de prendas y selección de categorías	19

4.5. Prototipo	20
4.5.1. Herramientas utilizadas para el diseño del prototipo	20
4.5.2. Flujo general de navegación	20
4.5.3. Descripción de pantallas	20
4.5.4. Observaciones sobre el diseño del prototipo	27
5. Implementación del sistema de recomendación y desarrollo del prototipo web	28
5.1. Implementación del Frontend	28
5.1.1. Contexto de ejecución del frontend	28
5.1.2. Reconocimiento de emociones faciales en tiempo real	29
5.1.3. Interfaz de usuario y flujo de interacción	30
5.2. Conectividad y servicios en la nube con Firebase	34
5.2.1. Servicios utilizados	35
5.2.2. Ventajas de la integración con Firebase	35
5.2.3. Relación con el sistema de recomendación	35
5.3. Implementación del Backend y Entrenamiento del Modelo	36
5.3.1. Contexto de Ejecución	36
5.3.2. Funcionamiento General del Backend	36
5.3.3. Funcionamiento del sistema de recomendación emocional de prendas	37
5.3.4. Red Neuronal Basada en Multi-Armed Bandit	38
5.3.5. Funcionamiento del Algoritmo Multi-Armed Bandit	38
5.3.6. Evaluación de Corridas del Modelo BanditNet	41
5.3.7. Integración con el Frontend: Sistema de Recomendación Interactiva	45
6. Pruebas	47
6.1. Diseño de la Evaluación	47
6.1.1. Objetivo de la evaluación	47
6.1.2. Instrumento de evaluación: Encuesta estructurada	47
6.1.3. Revisión y depuración del cuestionario	48
6.1.4. Contenido de la Encuesta	48
6.2. Ejecución y Resultados de las Pruebas	49
6.2.1. Pregunta 1: ¿Cuál es tu género?	49
6.2.2. Pregunta 2: ¿Cuál es tu edad?	50
6.2.3. Pregunta 3: ¿Con qué dispositivo accediste a la app?	51
6.2.4. Pregunta 4: ¿Con qué frecuencia usas aplicaciones de recomendación o compras en línea?	52
6.2.5. Pregunta 5: ¿Sentiste que la aplicación comprendió correctamente tu estado emocional?	53
6.2.6. Pregunta 6: ¿Las recomendaciones de ropa que viste te parecieron adecuadas para tu estado de ánimo?	54
6.2.7. Pregunta 7: ¿Consideras que la cantidad de prendas mostradas fue suficiente para elegir?	55
6.2.8. Pregunta 8: ¿Encontraste llamativa al menos una prenda recomendada durante el uso de la app?	56
6.2.9. Pregunta 9: ¿Qué tan clara te pareció la aplicación al momento de empezar a usarla?	57
6.2.10. Pregunta 10: ¿La experiencia de "me gusta / no me gusta" fue intuitiva para ti?	58
6.2.11. Pregunta 11: En una escala del 1 al 5, ¿cómo calificarías tu experiencia general?	59
6.2.12. Pregunta 12: ¿Tienes algún comentario o sugerencia para mejorar la aplicación?	60

7. Conclusiones	61
7.1. Conclusiones	61
8. Trabajos futuros	63
8.1. Trabajos futuros	63
9. Bibliografía	68
Anexos	71

Lista de Figuras

4.1. Diagrama de flujo de interacción con el sistema	18
4.2. Pantalla de inicio de sesión	21
4.3. Pantalla de captura de emociones y selección de color emocional	22
4.4. Pantalla de selección de categoría	23
4.5. Pantalla de selección de género	24
4.6. Pantalla de recomendaciones tipo Tinder	25
4.7. Pantalla final y feedback del usuario	26
5.1. Flujo de captura y análisis de emociones con <code>face-api.js</code>	29
5.2. Pantalla de inicio de sesión	30
5.3. Pantalla de captura emocional y selección de color	31
5.4. Pantalla de inicio: selección de categoría de prenda	32
5.5. Pantalla de selección de género estético de las prendas	32
5.6. Pantalla de recomendaciones con tarjetas interactivas tipo Tinder	33
5.7. Pantalla final con animación positiva y formulario de retroalimentación	34
5.8. Error final por corrida del modelo BanditNet	41
5.9. Promedio del MSE en las últimas 100 épocas	42
5.10. Error total de la red neuronal Bandit - Ejecución inicial	43
5.11. Comparativa del desempeño del modelo ante distintos niveles de ruido	44
5.12. Mapa de calor del espacio de decisión del modelo (emociones vs colores)	44
5.13. Reducción progresiva del error durante entrenamiento Bandit	45
5.14. Flujo de comunicación entre usuario, frontend y backend en el sistema de recomendación.	46
6.1. Resultados de la pregunta 1 de la encuesta	49
6.2. Resultados de la pregunta 2 de la encuesta	50
6.3. Resultados de la pregunta 3 de la encuesta	51
6.4. Resultados de la pregunta 4 de la encuesta	52
6.5. Resultados de la pregunta 5 de la encuesta	53
6.6. Resultados de la pregunta 6 de la encuesta	54
6.7. Resultados de la pregunta 7 de la encuesta	55
6.8. Resultados de la pregunta 8 de la encuesta	56
6.9. Resultados de la pregunta 9 de la encuesta	57
6.10. Resultados de la pregunta 10 de la encuesta	58
6.11. Resultados de la pregunta 11 de la encuesta	59

Lista de tablas

1.1. Objetivos específicos y Resultados esperados	4
1.2. Estructura de capítulos	7
4.1. Asociaciones entre emociones, colores y sensaciones percibidas	16
5.1. Resumen de 10 corridas del modelo BanditNet.	41
5.2. Evaluación de combinaciones de parámetros: learning rate y epsilon	42
5.3. Resultados con diferentes niveles de ruido en la entrada	43
6.1. Tabla de Preguntas y Categorías	48

Resumen

En el contexto de la ingeniería de sistemas, el diseño y desarrollo de aplicaciones web enfrenta un desafío crucial: la falta de consideración de las emociones del usuario y su impacto en la interacción con los sistemas digitales. Esta omisión, particularmente evidente en el ámbito de las plataformas de recomendación de ropa, ha contribuido al desarrollo de experiencias que resultan impersonales, poco empáticas y carentes de conexión emocional con los usuarios. Como consecuencia, muchas de estas plataformas no logran satisfacer plenamente las necesidades afectivas de las personas, afectando la toma de decisiones, la fidelización y la satisfacción general con el uso de la tecnología.

Frente a esta problemática, el presente trabajo de grado se planteó como objetivo principal el desarrollo de un prototipo de aplicación web que incorporara el análisis emocional del usuario y los principios de la Economía Conductual como base para ofrecer recomendaciones de ropa más significativas, humanas y personalizadas. La intención no fue únicamente facilitar la elección de una prenda, sino también comprender y atender el estado emocional de cada individuo, reconociendo que sus emociones influyen profundamente en cómo interactúan, eligen y se relacionan con la tecnología.

La propuesta se construyó desde una perspectiva interdisciplinaria, integrando fundamentos de psicología del usuario, interacción humano-computadora y bienestar digital. Se exploraron conceptos como la inteligencia emocional, el modelado de estados afectivos y la toma de decisiones influenciada por emociones, con el fin de crear un entorno digital que reconociera al usuario no solo como un agente racional, sino también como un ser emocional. De esta manera, se buscó diseñar una experiencia de uso más empática, centrada en el ser humano y orientada al fortalecimiento de su bienestar emocional a través de su interacción con el sistema.

El desarrollo del prototipo permitió evidenciar cómo la incorporación de elementos emocionales en el diseño de sistemas puede enriquecer profundamente la experiencia digital, promoviendo no solo la personalización, sino también la construcción de plataformas más sensibles, respetuosas y alineadas con las verdaderas necesidades de los usuarios. Este trabajo se convierte así en una contribución a una visión más humana de la tecnología, que busca equilibrar la funcionalidad con el bienestar, y plantea nuevas posibilidades para el futuro del diseño de experiencias digitales en el sector de la moda y más allá.

Palabras clave: Clothing recommendation system, Prototype web application, Behavioral economics, User interfaces, Sentiment analysis, Image recognition, Emotion recognition, Emotional responses, User experience, Quality of experience, Human computer interaction, User interfaces, Recommender systems, Affective computing, Consumer behavior, Persuasive systems.

Capítulo 1

Introducción

1.1. Formulación del problema

¿Cómo puede desarrollarse un enfoque que integre el reconocimiento y comprensión de las emociones del usuario en las aplicaciones web de moda para proporcionar recomendaciones personalizadas y evaluar su impacto en la experiencia de usuario, considerando la influencia de las emociones en el comportamiento de compra?

1.2. Descripción del problema

En el ámbito de la ingeniería en sistemas, el diseño y desarrollo de aplicaciones web se enfrenta a un desafío central, particularmente en el contexto de la moda en línea: cómo crear experiencias digitales que no solo fueran funcionales y eficientes, sino también emocionalmente satisfactorias para los usuarios al seleccionar prendas de vestir. A pesar de los avances en la interacción humano-computadora, muchas aplicaciones aún carecían de una comprensión profunda de las emociones humanas y su influencia en el comportamiento del usuario, especialmente en el contexto específico de la moda y la selección de ropa.

La falta de consideración de las emociones en el diseño de sistemas informáticos para la selección de ropa condujo a experiencias frustrantes, desmotivadoras o incluso perjudiciales para la salud emocional de los usuarios. Las aplicaciones que no tienen en cuenta el estado emocional de los usuarios corren el riesgo de generar estrés, ansiedad o insatisfacción, lo que resultaba en una baja retención de usuarios, menor compromiso con la plataforma y una reputación negativa para las marcas de moda en línea [1].

Además, los sistemas de recomendación de moda, una herramienta omnipresente en aplicaciones web modernas de moda, enfrentan desafíos adicionales en cuanto a la personalización y relevancia de las sugerencias proporcionadas. A menudo, estos sistemas se basaban únicamente en datos demográficos o patrones de comportamiento histórico, lo que lleva a recomendaciones genéricas o inadecuadas para el estado emocional actual del usuario en el contexto de la selección de prendas de vestir [2].

Por lo tanto, existe una necesidad apremiante de abordar este problema mediante el desarrollo de aplicaciones web de moda que integraran el análisis de las diversas emociones del usuario y la implementación de los principios de la Economía Conductual específicamente en la recomendación de ropa. Este enfoque no solo busca mejorar la experiencia del usuario y la efectividad de los sistemas de recomendación de moda, sino que también aspira a contribuir al bienestar emocional general de los individuos que interactúan con estas plataformas al elegir su vestimenta [3].

En este proyecto, se exploró en detalle cómo el desarrollo de un prototipo de aplicación web que tuviera en cuenta las emociones del usuario podía abordar estos desafíos específicos en el contexto de la moda en línea, ofreciendo recomendaciones de ropa personalizadas y contextualizadas que promovieran un mayor bienestar emocional. Se analizaron enfoques teóricos y técnicas de computación afectiva, Economía Conductual y análisis de sentimientos para diseñar e implementar un sistema de recomendaciones de moda personalizadas que considerara activamente el bienestar emocional del usuario.

1.3. Objetivos

1.3.1. Objetivo general

Desarrollar un prototipo de aplicación web que implemente un sistema de recomendación de ropa basado en el bienestar emocional del usuario mediante la integración de la computación afectiva y los principios de la Economía Conductual.

1.3.2. Objetivos específicos

1. Identificar las necesidades emocionales y las preferencias de estilo del usuario en el contexto de la selección de prendas de vestir.
2. Diseñar un modelo de sistema de recomendación de ropa que se ajuste a las necesidades emocionales y preferencias de estilo del usuario.
3. Implementar el prototipo de aplicación web de acuerdo con las diferentes fases de desarrollo, integrando herramientas de análisis de emociones y principios de la Economía Conductual.
4. Realizar pruebas del prototipo para verificar su funcionamiento y que cumpla con los requerimientos planteados en términos de personalización emocional y recomendaciones de prendas de vestir.

1.4. Resultados esperados

Objetivo	Resultado Esperado
Identificar las necesidades emocionales y las preferencias de estilo del usuario en la selección de prendas de vestir.	Un entendimiento claro de las emociones y preferencias de estilo de los usuarios mediante técnicas de investigación y análisis de datos.
Diseñar un modelo de sistema de recomendación de ropa que se ajuste a las necesidades emocionales y preferencias de estilo del usuario.	Un modelo de sistema de recomendación de moda que incorpore eficazmente las necesidades emocionales y las preferencias de estilo de los usuarios en la selección de prendas de vestir.
Implementar el prototipo de aplicación web de acuerdo con las diferentes fases de desarrollo, integrando herramientas de análisis de emociones y principios de la Economía Conductual.	Un prototipo funcional de una aplicación web que integre herramientas de análisis de emociones y principios de la Economía Conductual para proporcionar recomendaciones personalizadas de prendas de vestir.
Realizar pruebas del prototipo para verificar su funcionamiento y que cumpla con los requerimientos planteados en términos de personalización emocional y recomendaciones de prendas de vestir.	El prototipo mediante pruebas proporcione recomendaciones personalizadas que tengan en cuenta necesidades de estilo del usuario en la selección de prendas de vestir.

Tabla 1.1: Objetivos específicos y Resultados esperados

1.5. Metodología

En este proyecto se utilizó una metodología inductiva, dado que en el área de los sistemas de recomendación, el bienestar emocional y la economía conductual (*ejes centrales de este trabajo*), se cuenta con diversas investigaciones previas a nivel internacional, las cuales se tomaron como referencia para obtener conclusiones propias y realizar comparaciones que permitieran establecer generalizaciones sobre el uso de modelos recomendadores basados en el estado emocional del usuario. Es importante señalar que, debido a la naturaleza interdisciplinaria de este proyecto, muchas investigaciones anteriores han abordado parcialmente alguno de los componentes utilizados, pero no su integración completa, por lo que las fuentes pueden ser diversas en enfoque pero complementarias en contenido.

Las fuentes de información utilizadas durante el desarrollo del proyecto fueron tanto primarias como secundarias, incluyendo artículos científicos, libros, documentos técnicos, sitios especializados, y proyectos similares. A partir del análisis de la información recolectada, se diseñó e implementó un sistema de recomendación de ropa apoyado en un cuestionario emocional y en principios de economía conductual, el sistema utiliza como base una red neuronal entrenada con características de prendas de vestir y preferencias del usuario, asociando emociones específicas con colores y tipos de ropa. Este proyecto no pretende replicar otros sistemas de recomendación, sino proponer una solución innovadora que integre emociones, comportamiento y preferencias personales con el objetivo de mejorar la experiencia del usuario al elegir su vestimenta.

Esta tesis tiene un enfoque investigativo con aplicación tecnológica, más que un desarrollo puramente técnico o comercial, por lo que no se aplicó una metodología de desarrollo de software tradicional. Sin embargo, el proyecto fue dividido en fases según los objetivos específicos planteados, permitiendo un abordaje estructurado de cada componente clave.

Definir los criterios de evaluación del sistema de recomendación propuesto en función del bienestar emocional del usuario y la calidad de las recomendaciones realizadas:

- **Análisis y planeación:** en esta etapa se llevó a cabo una revisión bibliográfica sobre sistemas de recomendación, técnicas de detección emocional, cuestionarios de autopercepción y modelos de economía conductual aplicados a la toma de decisiones. A partir de esta información, se definieron los criterios para evaluar la calidad de las recomendaciones (precisión, relevancia, satisfacción percibida) y se delineó el enfoque de integración emocional y conductual.

Esta etapa tuvo una duración de **6 semanas**.

Seleccionar o diseñar un cuestionario emocional y una arquitectura adecuada para la red neuronal que procese imágenes de ropa y datos de usuario:

- **Diseño:** Durante esta etapa, se diseñó la estructura del prototipo, que incluye una interfaz de usuario para registrar las emociones y preferencias del usuario, una base de datos con prendas etiquetadas según características como tipo de prenda, material y color, y una red neuronal que procesa las emociones y ajusta las recomendaciones de ropa. La red neuronal, implementada dentro de un sistema de **Multi-Armed Bandit**, ajusta las recomendaciones mediante un proceso de exploración y explotación, donde se "premian" las elecciones de ropa que mejor coinciden con el estado emocional del usuario.

Esta fase tuvo una duración de **8 semanas**.

Codificar el sistema web y las funcionalidades del prototipo para registrar emociones, mostrar recomendaciones y permitir retroalimentación del usuario:

- **Codificación:** en esta etapa se desarrolló la aplicación web utilizando React para el frontend, Firebase para la autenticación y almacenamiento, y un backend en FastAPI que conecta con el modelo de red neuronal entrenado. También se implementó la lógica del sistema de recomendación, así como la funcionalidad para almacenar y mostrar las prendas seleccionadas por el usuario.

Esta etapa tuvo una duración de **8 semanas**.

Evaluar la utilidad del sistema de recomendación mediante pruebas con usuarios reales, midiendo su satisfacción y comparando los resultados con los objetivos esperados:

- **Pruebas:** durante esta fase se realizaron pruebas controladas con un grupo de usuarios, quienes interactuaron con el prototipo y respondieron un formulario de satisfacción al final del proceso. Se recopilaron datos sobre la precisión de las recomendaciones, el nivel de coincidencia con el estado emocional del usuario y la experiencia general con el sistema. Los resultados obtenidos se analizaron para establecer conclusiones sobre la efectividad del enfoque propuesto.

Esta etapa tuvo una duración de **4 semanas**.

1.6. Información sobre los capítulos

En la siguiente tabla se muestra una corta descripción de cada capítulo del documento y se explica qué objetivos específicos aborda.

Capítulo	Descripción	Objetivo específico
Capítulo 2: Alcance del proyecto	En este capítulo se expone el contexto general del proyecto, su justificación, y la relevancia del bienestar emocional en la recomendación de ropa, así como la integración de la economía conductual.	Ninguno
Capítulo 3: Marco Teórico	En este capítulo se presentan los conceptos clave sobre el bienestar emocional, preferencias de estilo de ropa, economía conductual y sistemas de recomendación.	Ninguno
Capítulo 4: Diseño del Sistema de Recomendación	Se describen los modelos de recomendación de ropa basados en el bienestar emocional y preferencias del usuario. Se discuten los algoritmos a utilizar, la selección de los datos y las herramientas de análisis emocional.	1, 2 y 3
Capítulo 5: Desarrollo e Implementación	En este capítulo se documenta la fase de desarrollo del prototipo de aplicación web, incluyendo la implementación del sistema de recomendación y la integración de herramientas de análisis emocional y principios de la economía conductual.	3
Capítulo 6: Pruebas	Aquí se documentan las pruebas realizadas al prototipo, tanto en términos de funcionalidad como de efectividad en la personalización emocional y las recomendaciones de prendas de vestir.	4
Capítulo 7: Conclusiones	En este capítulo se presentan los resultados obtenidos en las pruebas, su análisis y las conclusiones sobre el funcionamiento del prototipo, su aplicabilidad y efectividad.	4
Capítulo 8: Trabajos Futuros	Se presentan las posibles líneas de mejora del sistema propuesto, así como futuras aplicaciones del sistema de recomendación y la integración de nuevos elementos basados en economía conductual.	4
Capítulo 9: Bibliografía	Se presentan las referencias y fuentes de información utilizadas para la realización de este trabajo de investigación.	Ninguno

Tabla 1.2: Estructura de capítulos

Capítulo 2

Alcance del proyecto

2.1. Alcance

El desarrollo de este proyecto requirió una investigación profunda en las áreas de Computación Emocional, Sistemas de Recomendación, Psicología Emocional y Economía Conductual. La principal motivación fue crear una aplicación web capaz de recomendar ropa adaptada al bienestar emocional del usuario, integrando principios de economía conductual para optimizar la experiencia de compra en línea.

El sistema de recomendación se basó en un modelo de análisis emocional que considera las emociones fundamentales del usuario, tales como feliz, molesto, miedoso, neutral, triste, sorprendido y disgustado, con el fin de ajustar las sugerencias de ropa de acuerdo a su estado emocional. Este enfoque teórico se fundamentó en investigaciones previas sobre cómo las emociones influyen en las decisiones de compra y en el bienestar general de los individuos [4] [5]. Se seleccionaron variables emocionales relevantes que podrían afectar la preferencia de ropa, como la comodidad emocional, la autoestima y la percepción de estilo.

Diversos estudios previos demostraron que los sistemas de recomendación personalizados, especialmente aquellos que integran el bienestar emocional, mejoran la satisfacción del usuario, ya que ajustan las sugerencias de productos de acuerdo con sus estados afectivos [6] [7]. Este proyecto se inspiró en tales investigaciones, proponiendo un sistema que modula las recomendaciones de ropa en función del análisis emocional de cada usuario, con el objetivo de aumentar tanto la satisfacción emocional como la compra efectiva.

El prototipo de la aplicación web fue diseñado para ser una herramienta dinámica, donde los usuarios puedan recibir recomendaciones de ropa según sus estados emocionales y preferencias de estilo. Se utilizó un enfoque centrado en el diseño de experiencia del usuario (UX), con una interfaz simple y amigable, permitiendo la personalización emocional de las sugerencias.

Para identificar los requisitos funcionales de la aplicación, se llevó a cabo una exhaustiva revisión de literatura en los campos de sistemas de recomendación, computación emocional y economía conductual. Además, se realizaron entrevistas con usuarios de plataformas de compra online. Se analizaron las mejores prácticas de personalización en plataformas de e-commerce para aplicar las lecciones aprendidas en el diseño del sistema de recomendación.

El modelo de recomendación se basó en una red neuronal, donde el sistema fue entrenado utilizando datos sobre las emociones del usuario, sus preferencias de estilo y las interacciones previas con la pla-

taforma. Los datos emocionales fueron recopilados mediante una herramienta de análisis facial, lo que permitió afinar las recomendaciones según los cambios emocionales del usuario. El sistema fue probado y optimizado continuamente a lo largo del desarrollo, asegurando que las recomendaciones fueran precisas y útiles.

La implementación del prototipo de la aplicación web se desarrolló utilizando tecnologías de vanguardia, como React para el frontend, acompañada de un backend desarrollado en FastAPI, que sirve de intermediario con los modelos de inteligencia artificial y los servicios de almacenamiento y autenticación (Firebase). Además, se integraron herramientas de análisis emocional en tiempo real, basadas en tecnologías de reconocimiento facial y monitoreo de las respuestas fisiológicas del usuario, para adaptar las recomendaciones en función de su bienestar emocional.

Para evaluar la efectividad del prototipo, se llevaron a cabo pruebas de usabilidad y pruebas con usuarios reales. Se midió la satisfacción emocional del usuario antes y después de recibir las recomendaciones, con el objetivo de determinar si las sugerencias de ropa eran acorde a el estado de ánimo y aumentar la confianza del usuario en sus decisiones de compra. Los resultados fueron analizados para identificar patrones emocionales y mejorar la precisión de las recomendaciones.

Este enfoque innovador permitió crear una plataforma que no solo recomienda ropa basada en preferencias estéticas, sino que también ajusta las sugerencias de acuerdo con el bienestar emocional del usuario. Así, se consiguió ofrecer una experiencia online que fomenta la conexión emocional con la ropa, mejorando el bienestar general del usuario y optimizando la toma de decisiones en un entorno digital.

Capítulo 3

Marco referencial

En este capítulo se describen los conceptos y definiciones necesarias para el entendimiento de las estrategias a implementar en el desarrollo del proyecto.

3.1. Marco Teórico

3.1.1. Computación Afectiva

La computación afectiva se define como “el estudio y desarrollo de sistemas y dispositivos computacionales que pueden reconocer, interpretar, procesar y simular afectos humanos” [1]. En esta área, se emplean diversas técnicas para capturar y analizar las señales emocionales de los usuarios, como el reconocimiento facial, el análisis de voz y la detección de patrones de interacción. Estos avances han llevado a aplicaciones más sensibles a las emociones humanas, lo que mejora la calidad de la interacción humano-computadora [8].

Estudios recientes también han demostrado que el análisis emocional multimodal, utilizando señales como voz, imagen y texto, puede mejorar significativamente la detección del estado emocional del usuario. Por ejemplo, Liu et al. propusieron un modelo transformer multimodal basado en lógica difusa que logra una alta precisión en la identificación de emociones complejas, gracias a la combinación de datos visuales, auditivos y textuales [9].

3.1.2. Inteligencia Emocional

La inteligencia emocional se refiere a la capacidad de reconocer, comprender y gestionar las propias emociones y las de los demás [10]. En el contexto de la interacción humano-computadora, la inteligencia emocional se utiliza para diseñar sistemas que sean sensibles a las necesidades emocionales de los usuarios, lo que puede mejorar la experiencia del usuario y la efectividad de las aplicaciones [11].

Además, el concepto de empatía artificial ha tomado relevancia en este campo. Hashim y Ashad discuten cómo las máquinas pueden simular empatía mediante la adaptación del comportamiento del sistema a las emociones del usuario, fortaleciendo así la relación humano-IA en contextos como el marketing digital o los sistemas de recomendación sensibles al estado emocional [12].

3.1.3. Economía Conductual

La Economía Conductual es una rama de la economía que estudia cómo las decisiones humanas están influenciadas por factores psicológicos, sociales y emocionales [3]. En el diseño de sistemas interactivos, los principios de la Economía Conductual se utilizan para influir en el comportamiento del usuario, como mediante la implementación de “empujones” (nudges) que guíen las decisiones hacia resultados deseados [13].

Investigaciones recientes, como la de Al Ahbabi et al, evidencian cómo los sesgos cognitivos pueden incorporarse estratégicamente en entornos de comercio electrónico para mejorar la experiencia del usuario y aumentar la probabilidad de conversión. Estos principios se pueden adaptar al diseño de interfaces de recomendación para influir positivamente en las decisiones de los usuarios al elegir prendas de vestir [14].

3.1.4. Sistemas de Recomendación

Los sistemas de recomendación son herramientas que sugieren elementos de interés para los usuarios, como películas, música o productos, basándose en sus preferencias y comportamientos pasados [15]. Estos sistemas utilizan algoritmos de aprendizaje automático para analizar grandes conjuntos de datos y generar recomendaciones personalizadas, lo que puede mejorar la experiencia del usuario y aumentar la satisfacción del cliente en aplicaciones web y móviles [16].

En línea con esta perspectiva, Jing et al proponen un sistema de recomendación musical que incorpora explícitamente el estado emocional del usuario mediante redes bayesianas profundas. Aunque centrado en la música, su arquitectura para modelar la relación emoción-preferencia puede ser transferida al ámbito de la moda personalizada, mejorando la sensibilidad emocional del sistema [17].

3.1.5. Análisis de Sentimientos

El análisis de sentimientos es una técnica que se utiliza para determinar la actitud emocional de un usuario hacia un determinado tema o contenido, generalmente a partir de texto escrito [18]. Este enfoque es fundamental para comprender las emociones expresadas por los usuarios en plataformas digitales, lo que puede ser útil para personalizar recomendaciones de moda basadas en las preferencias y el estado emocional del usuario.

3.1.6. Modelado de Emociones

El modelado de emociones es un área de investigación que se centra en desarrollar modelos computacionales para representar y simular el comportamiento emocional humano [19]. Estos modelos se utilizan para comprender cómo las emociones influyen en la toma de decisiones y el comportamiento del usuario, lo que es crucial para el diseño de sistemas interactivos que sean sensibles a las necesidades emocionales de los usuarios.

3.1.7. Interacción Humano-Computadora

La interacción humano-computadora es un campo interdisciplinario que estudia la forma en que las personas interactúan con las computadoras y los sistemas computacionales [20]. En el contexto de tu tesis, es importante comprender cómo diseñar interfaces de usuario intuitivas y efectivas que tengan en cuenta las emociones y preferencias del usuario al recomendar ropa.

3.1.8. Psicología del Usuario

La psicología del usuario se enfoca en comprender el comportamiento, las necesidades y las preferencias de los usuarios en entornos digitales [21]. En el contexto de tu investigación, la psicología del usuario puede proporcionar información valiosa sobre cómo las emociones influyen en las decisiones de compra y la experiencia del usuario en aplicaciones de moda en línea.

3.2. Marco Conceptual

3.2.1. Diseño de la Aplicación Web de Recomendación de Ropa

El marco conceptual se basa en el diseño de una aplicación web para la recomendación de ropa que integre la computación afectiva y los principios de la Economía Conductual [3]. Esto implica el desarrollo de algoritmos de análisis de emociones, la personalización de recomendaciones basadas en el estado emocional del usuario y el diseño de interfaces de usuario que fomenten la toma de decisiones informadas y emocionalmente inteligentes [21].

3.2.2. Evaluación de la Experiencia del Usuario

El marco conceptual también incluye la evaluación de la experiencia del usuario en la aplicación web de recomendación de ropa, utilizando métricas de usabilidad y satisfacción del usuario [20]. Esto implica la realización de pruebas de usabilidad y encuestas de satisfacción para identificar áreas de mejora y garantizar que la aplicación cumpla con las necesidades y expectativas del usuario [22].

3.2.3. Diseño de Algoritmos de Análisis de Emociones

El diseño de algoritmos de análisis de emociones es fundamental para la implementación de un sistema de recomendación emocional efectivo [23]. Estos algoritmos pueden utilizar técnicas de procesamiento de lenguaje natural, reconocimiento de voz, análisis de texto y reconocimiento de imágenes para identificar las emociones del usuario a partir de diferentes tipos de datos.

Como extensión, se pueden utilizar modelos multimodales como el propuesto por Liu et al, el cual permite integrar diversas fuentes de información emocional (expresión facial, tono de voz, texto) para lograr una detección más precisa y personalizada [9].

3.2.4. Personalización de Recomendaciones Basadas en Emociones

La personalización de recomendaciones basadas en emociones implica adaptar las sugerencias de moda de acuerdo con el estado emocional del usuario [2]. Esto puede lograrse mediante el desarrollo de algoritmos de recomendación que tengan en cuenta las emociones detectadas y ajusten las sugerencias de moda para satisfacer las necesidades y preferencias del usuario en ese momento específico, tal como se plantea en el trabajo de Jing et al [17].

3.2.5. Evaluación de la Eficacia del Sistema

La evaluación de la eficacia del sistema es crucial para garantizar que el sistema de recomendación de moda cumpla con sus objetivos [20]. Esto puede implicar la realización de pruebas de usabilidad, encuestas de satisfacción del usuario y análisis de datos para medir la precisión de las recomendaciones, la satisfacción del usuario y otros indicadores clave de rendimiento.

3.2.6. Diseño de Interfaces de Usuario Emocionalmente Inteligentes

El diseño de interfaces de usuario emocionalmente inteligentes es crucial para garantizar una interacción efectiva y satisfactoria con el sistema de recomendación de moda [22]. Esto implica crear interfaces que reconozcan y respondan a las emociones del usuario de manera sensible y empática, utilizando elementos de diseño como colores, tipografía y diseño de interacción adecuados.

Según Hashim y Ashad, estas interfaces deben incorporar elementos de empatía artificial para fortalecer la relación entre el usuario y el sistema, lo que puede traducirse en mayor lealtad y satisfacción [12].

3.2.7. Implementación de Principios de Economía Conductual

La implementación de principios de Economía Conductual en el diseño del sistema puede mejorar la efectividad de las recomendaciones de moda [3]. Esto puede incluir el uso de nudges y la presentación de opciones de manera que fomente decisiones informadas y beneficiosas para el usuario, lo que aumenta la probabilidad de que las recomendaciones sean aceptadas y seguidas.

Capítulo 4

Diseño de aplicación web y modelo emocional

Con el objetivo de desarrollar un sistema de recomendación de ropa que se adapte al estado emocional del usuario, este capítulo presenta la estructura conceptual del sistema, el flujo de funcionamiento de la aplicación, la lógica detrás del reconocimiento de emociones y la relación entre colores y emociones. Finalmente, se describe el procesamiento del dataset seleccionado para obtener las categorías principales de prendas utilizadas.

4.1. Modelo emocional y detección afectiva

El diseño emocional del sistema se fundamenta en el enfoque de emociones básicas propuesto por Paul Ekman [24], quien identificó un conjunto de emociones universales reconocibles mediante expresiones faciales: felicidad, tristeza, ira, miedo, sorpresa y disgusto. Estas emociones han sido validadas empíricamente a través de estudios interculturales, demostrando su relevancia para la interpretación automática de afecto en sistemas computacionales. A estas emociones se añade el estado neutral, que sirve como categoría de referencia base para distinguir la presencia o ausencia de una expresión emocional activa.

La elección del modelo de Ekman responde a su amplia adopción en el campo del reconocimiento facial de emociones y a su simplicidad conceptual, lo que permite una implementación más eficiente en aplicaciones en tiempo real. Además, estudios como el de Ko [25] han mostrado que los modelos de emociones básicas pueden integrarse exitosamente con técnicas de visión por computador y aprendizaje automático, lo que los hace ideales para aplicaciones como la presente.

En este sistema, la detección emocional del usuario se realiza mediante un componente de visión por computador. Al activarse la cámara del dispositivo y presionar el botón “Captar emoción”, el sistema toma una fotografía de la cara del usuario y la analiza en tiempo real. La red neuronal procesa esta imagen y la clasifica en una de las siguientes categorías emocionales: feliz, triste, molesto, sorprendido, miedoso, disgustado o neutral.

Este enfoque no solo permite una clasificación rápida y eficiente, sino que también garantiza una interacción no intrusiva, ya que no requiere que el usuario proporcione información emocional de manera manual. La emoción detectada se almacena junto con los demás datos del usuario en la base de datos del sistema, sirviendo como parámetro clave para personalizar las recomendaciones de prendas de vestir.

La justificación de este enfoque se alinea con el paradigma de la computación afectiva, tal como lo define Rosalind Picard en su obra seminal *Affective Computing* [1]. Picard argumenta que los sistemas computacionales pueden y deben responder al estado emocional de los usuarios para mejorar la calidad de la interacción. En este contexto, detectar y adaptar el contenido mostrado en función del estado emocional permite ofrecer recomendaciones más pertinentes, empáticas y alineadas con las necesidades psicológicas momentáneas del usuario, como el confort emocional o la elevación del ánimo.

4.2. Asociación entre emociones y colores

Además de captar la emoción a través de reconocimiento facial, el sistema solicita al usuario, en el formulario inicial, que seleccione un color que considere agradable o deseable en función de su estado emocional actual. Los colores disponibles en esta selección son: amarillo, rojo, azul, negro, morado, verde y blanco. Estos colores fueron elegidos no solo por su accesibilidad visual y popularidad, sino también por su relevancia psicológica documentada en estudios sobre percepción y emoción. Internamente, estos tonos pueden derivar en colores compuestos como naranja, café o rosado, permitiendo una paleta más rica y variada sin sobrecargar la interfaz de usuario.

La relación entre color y emoción ha sido ampliamente estudiada. Por ejemplo, Valdez y Mehrabian [26] demostraron que la percepción del color influye significativamente en la intensidad y valencia de las emociones. Colores cálidos como el rojo y el amarillo tienden a asociarse con estados de excitación, energía o felicidad, mientras que colores fríos como el azul y el negro suelen vincularse con tristeza, calma o incluso miedo. Asimismo, investigaciones como las de Kaya y Epps [27] encontraron asociaciones consistentes entre colores específicos y emociones en contextos culturales diversos, lo que valida su inclusión como un canal adicional de entrada emocional.

Esta estrategia responde a un principio clave del diseño centrado en el usuario, permitir que el sistema no solo infiera, sino también escuche y recoja intenciones explícitas del individuo. De esta manera, se equilibra el análisis automático (visión por computador) con una entrada subjetiva y voluntaria (selección cromática), lo cual aumenta la precisión en la estimación del estado emocional real y mejora la aceptación del sistema por parte del usuario.

A continuación, se presenta una tabla que resume las asociaciones entre colores y emociones que han sido integradas en el sistema como referencia para la personalización de las recomendaciones:





Emoción	Colores Asociados					Sensación Percibida
Feliz					-	Vitalidad, alegría, ligereza
Triste						Calma, introspección, melancolía
Molesto				-	-	Tensión, intensidad emocional
Sorprendido				-	-	Atención, energía repentina
Miedoso					-	Inseguridad, precaución, ansiedad
Disgustado					-	Rechazo, incomodidad
Neutral					-	Equilibrio, sobriedad, serenidad

Tabla 4.1: Asociaciones entre emociones, colores y sensaciones percibidas

La información recopilada a partir de esta selección cromática se almacena junto con la emoción detectada automáticamente, conformando el primer registro emocional compuesto del usuario. Esta entrada es utilizada como parte de la lógica de personalización del sistema de recomendación de prendas, permitiendo que las sugerencias visuales (por color y estilo) estén alineadas tanto con el estado emocional del usuario como con sus preferencias subjetivas. En conjunto, este mecanismo fomenta una experiencia más empática, coherente y personalizada, lo que fortalece el valor emocional del sistema.

4.3. Flujo de funcionamiento del sistema

El flujo de funcionamiento desde el acceso inicial del usuario hasta la generación de recomendaciones se resume en los siguientes pasos:

1. El usuario accede a la aplicación web desde el navegador.
2. Al iniciar sesión por primera vez, se despliega un formulario emocional que le permite activar la cámara.
3. El usuario presiona el botón “Captar emoción”, el sistema toma una imagen del rostro y clasifica la emoción automáticamente.
4. Luego, el usuario selecciona uno o varios colores con los que se siente identificado en ese momento.
5. Estos datos se almacenan en la base de datos como parte del perfil emocional inicial del usuario.
6. Con base en esta información, el sistema inicia la etapa de recomendaciones de prendas ajustadas emocionalmente.
7. El usuario puede aceptar prendas y estas guardarse en favoritos o rechazarlas.

El siguiente diagrama de flujo ilustra el proceso completo, incluyendo decisiones condicionales y acciones del usuario.




Figura 4.1: Diagrama de flujo de interacción con el sistema

4.4. Dataset de prendas y selección de categorías

El sistema de recomendación se apoya en una base de datos visual derivada del Fashion Product Images Dataset [28], que contiene más de 44,000 imágenes de alta calidad. Cada imagen está acompañada de metadatos relevantes como el tipo de prenda, color predominante, género objetivo (masculino/femenino/unisex), marca y otros atributos útiles para tareas de clasificación y recomendación de productos en contextos de comercio electrónico o moda asistida por inteligencia artificial.

Dado que el objetivo del sistema es ofrecer recomendaciones de prendas de forma intuitiva y emocionalmente significativa, fue necesario transformar el conjunto de datos original para adaptarlo a un contexto centrado en la experiencia del usuario. Esta transformación comenzó con la limpieza y normalización del archivo CSV original, eliminando entradas incompletas o redundantes, y asegurando la consistencia en los nombres de las categorías. Como resultado de este proceso de depuración, el dataset final quedó reducido a 16,460 registros, lo que permitió mantener solo los datos más relevantes y de calidad para el sistema de recomendación.

Posteriormente, se procedió a consolidar las múltiples etiquetas originales en un conjunto reducido y representativo de siete categorías generales: camiseta, camisa, top, pantalones, short, falda/vestido y abrigo. Este proceso implicó una revisión manual y automatizada de las etiquetas mediante scripts de mapeo que agruparon términos equivalentes o sinónimos. Por ejemplo, se unificaron las etiquetas “t-shirt”, “tee” y “crew neck” bajo la categoría “camiseta”, mientras que “jacket”, “blazer” y “coat” fueron reclasificados como “abrigo”.

Este proceso de agrupamiento y simplificación no solo redujo la complejidad del dataset, sino que también mejoró la usabilidad de la aplicación al permitir una interfaz clara y centrada en el usuario. En lugar de enfrentarse a decenas de categorías ambiguas, los usuarios pueden ahora navegar fácilmente por un conjunto acotado de opciones, facilitando la selección de prendas favoritas dentro de un marco emocional, y agilizando el entrenamiento del modelo de recomendación. Además, esta clasificación estructurada permitió generar filtros precisos y balanceados que aseguran una distribución equitativa entre las distintas clases al momento de entrenar y evaluar los modelos de predicción.

La adaptación del dataset a un número reducido de categorías también resultó en un aumento significativo de la eficiencia del sistema. Al tener menos categorías en las que clasificar las prendas, el modelo puede aprender patrones de manera más efectiva y, por lo tanto, ofrecer recomendaciones más precisas y alineadas con las preferencias del usuario. Este enfoque también permite la integración de tecnologías complementarias, como sistemas de recomendación basados en características extrínsecas de los productos, tales como atributos internos (por ejemplo, especificaciones técnicas, funciones o propiedades estructurales) y características visuales (como la similitud en los colores predominantes). La combinación de estos factores facilita una mayor eficiencia en la generación de recomendaciones precisas, al aprovechar la correlación entre los atributos categóricos y las propiedades visuales.

Además, al centralizarse en categorías más amplias y accesibles, el sistema no solo mejora la experiencia de usuario, sino que también ofrece un enfoque más inclusivo, permitiendo que usuarios con diversos gustos y necesidades encuentren opciones fácilmente dentro de un marco organizado y agradable.

4.5. Prototipo

Esta sección presenta el diseño visual de la aplicación web desarrollada como parte del sistema de recomendación de ropa basado en el bienestar emocional del usuario. El prototipo permite visualizar las distintas pantallas que componen la interfaz gráfica y cómo se espera que el usuario interactúe con ellas. A continuación, se detallan las herramientas utilizadas, el flujo de navegación y la descripción de cada pantalla diseñada.

4.5.1. Herramientas utilizadas para el diseño del prototipo

Para el desarrollo del prototipo de la aplicación se utilizó la herramienta Figma, una plataforma ampliamente usada para el diseño de interfaces gráficas debido a sus capacidades de colaboración en línea, componentes reutilizables, y facilidad para generar prototipos interactivos. Esta herramienta permitió representar de forma precisa cada una de las pantallas del sistema, respetando principios de diseño centrado en el usuario.

4.5.2. Flujo general de navegación

El flujo de navegación del prototipo fue estructurado para guiar al usuario desde el inicio de sesión hasta la interacción con las recomendaciones personalizadas. A continuación se describe el orden lógico de las pantallas y la función principal de cada una:


1. **Pantalla de inicio de sesión (Login):** acceso al sistema mediante autenticación.
2. **Pantalla de captura de emociones y selección de color emocional:** entrada inicial sobre el estado emocional del usuario y preferencia de color.
3. **Pantalla principal (selección de categoría):** el usuario elige el tipo de prenda que desea explorar.
4. **Pantalla de selección de género:** filtro adicional para recomendaciones personalizadas.
5. **Pantalla tipo Tinder (recomendaciones):** vista interactiva donde el usuario indica si le gusta o no una prenda.
6. **Pantalla final de cierre y feedback:** se agradece la participación y se ofrece un formulario de satisfacción.

4.5.3. Descripción de pantallas

A continuación, se presentan las principales pantallas diseñadas en el prototipo, incluyendo una breve descripción de su funcionalidad e interfaz. Las imágenes correspondientes a los wireframes se identifican como “Figura X”.

1. Pantalla de inicio de sesión (Login)

Esta pantalla permite al usuario autenticarse para acceder a la aplicación. Cuenta con campos para ingresar el correo electrónico y la contraseña, además de enlaces para registrarse o iniciar sesión mediante una cuenta de Google. El diseño está orientado hacia la simplicidad y la claridad visual, con un fondo neutro y botones destacados que facilitan la interacción.



The image shows a login screen prototype. It features a light purple background. In the center is a white rounded rectangle containing the login form. The form has the title "Iniciar Sesión" at the top. Below it are two input fields: "Correo" and "Contraseña". At the bottom of the form is a grey "Sign in" button. Below the button is a link that says "No tienes una cuenta? [Registrarse](#)".

Figura 4.2: Pantalla de inicio de sesión

2. Captura de emociones

Aquí el usuario debe registrar su estado emocional actual. Puede hacerlo mediante una fotografía (captura facial) o seleccionando su estado a través de un cuestionario emocional. Esta información será utilizada por el sistema para personalizar las recomendaciones.

Luego de registrar su emoción, el usuario selecciona un color que represente o complemente su estado de ánimo. Esta opción busca reforzar el vínculo entre emociones y preferencias visuales, sirviendo como un parámetro adicional para las sugerencias de prendas.



The screenshot shows a user interface for capturing emotions and selecting a color. At the top, there is a large gray rectangle with a black 'X' over it, indicating a camera view. Below this rectangle are two buttons: 'Activar Cámara' and 'Detectar Emoción'. The main heading is '¿Cómo te sientes hoy ?'. Underneath, there is a section titled 'Estado de ánimo' with a grid of checkboxes for 'Feliz', 'Molesto', 'Miedoso', 'Neutral', 'Triste', 'Sorprendido', and 'Disgustado'. The 'Feliz' checkbox is checked. Below this is a section titled 'Color que prefieres hoy' with a grid of checkboxes for 'Amarillo', 'Rojo', 'Negro', 'Verde', 'Blanco', 'Azul', and 'Morado'. The 'Amarillo' checkbox is checked. At the bottom center is a 'Continuar' button.

Figura 4.3: Pantalla de captura de emociones y selección de color emocional

3. Página principal – Selección de categoría de prenda

Esta pantalla funciona como menú principal. El usuario debe seleccionar el tipo de prenda que desea explorar. Solo se puede elegir una categoría por sesión: camiseta, camisa, top, pantalones, short, falda/vestido o abrigo. Se muestran iconos visuales e ilustraciones que facilitan la elección.



Figura 4.4: Pantalla de selección de categoría

4. Selección de género

En esta pantalla, el usuario puede indicar si desea ver prendas orientadas al género masculino o femenino. Esta selección permite afinar las recomendaciones, adaptándolas al contexto cultural y estético del usuario.



Figura 4.5: Pantalla de selección de género

5. Recomendaciones – Vista tipo Tinder

Esta es una de las pantallas centrales del sistema. Se presenta una prenda por vez en una tarjeta deslizante. El usuario puede indicar si le gusta (♥) o no le gusta (✕). Las tarjetas tienen animaciones suaves para mejorar la experiencia de usuario.




Figura 4.6: Pantalla de recomendaciones tipo Tinder

6. **Pantalla final y feedback** Al finalizar la sesión de recomendaciones, el usuario es redirigido a una pantalla de cierre que muestra una animación o GIF positivo. También se presenta un enlace a un formulario de satisfacción (Google Forms), y un botón para no volver a mostrar esta pantalla en futuras sesiones.



Figura 4.7: Pantalla final y feedback del usuario

4.5.4. Observaciones sobre el diseño del prototipo

El diseño del prototipo se basó en principios de diseño centrado en el usuario, enfocados en accesibilidad, facilidad de uso y adaptación emocional. Se tomaron en cuenta los siguientes aspectos:

- **Diseño emocional:** Las emociones del usuario se consideran desde el inicio, influyendo tanto en las recomendaciones como en la interfaz visual (por ejemplo, color y tono).
- **Interactividad amigable:** Se incorporaron elementos tipo Tinder para hacer la experiencia de selección más lúdica e intuitiva.
- **Accesibilidad:** Las decisiones gráficas buscan ser inclusivas, con textos legibles, iconografía clara, y compatibilidad móvil.
- **Cohesión visual:** Se usó una paleta de colores consistente y tipografías armónicas en todo el diseño.
- **Feedback constante:** El sistema muestra respuestas visuales inmediatas ante las acciones del usuario (por ejemplo, al dar like/dislike).

Estas decisiones buscan no solo crear una interfaz funcional, sino también transmitir una experiencia positiva y emocionalmente relevante para el usuario, en línea con los objetivos del sistema.

Capítulo 5

Implementación del sistema de recomendación y desarrollo del prototipo web

Este capítulo describe en detalle el proceso de desarrollo e implementación del prototipo web propuesto, cuyo objetivo es ofrecer recomendaciones personalizadas de ropa a partir del análisis del estado emocional del usuario. La solución integra múltiples tecnologías tanto en el frontend como en el backend, permitiendo la captura, procesamiento e interpretación de emociones mediante visión por computadora, y su posterior uso dentro de un sistema inteligente de toma de decisiones basado en aprendizaje por refuerzo.

En la primera sección se presenta la arquitectura del frontend, donde se implementa el reconocimiento facial en tiempo real utilizando modelos de aprendizaje profundo ejecutados en el navegador, así como la interfaz de usuario encargada de la interacción con el sistema. Posteriormente, se aborda el diseño y la implementación del backend, donde se procesan los datos recogidos y se ejecuta el modelo de recomendación emocional, desarrollado bajo un enfoque de aprendizaje contextual tipo Multi-Armed Bandit.

5.1. Implementación del Frontend

El frontend de la aplicación fue diseñado como una interfaz web responsiva e interactiva, desarrollada en React.js y configurado con Vite como herramienta de construcción para optimizar el rendimiento y la experiencia de desarrollo, que constituye el punto de contacto entre el usuario final y el sistema de recomendación de prendas basado en bienestar emocional. Este módulo se encarga de capturar datos emocionales y de preferencia visual del usuario, y de comunicarse directamente con el backend para generar recomendaciones personalizadas.

5.1.1. Contexto de ejecución del frontend

El desarrollo, pruebas e implementación del frontend se realizaron en una máquina local que cumple con los siguientes requisitos de hardware y software:

- Procesador: AMD Ryzen 5 3400G
- Memoria: 16 GB DDR4
- GPU: NVIDIA GeForce GTX 1660Ti

- Almacenamiento: SSD NVMe de 1 TB
- Sistema Operativo: Windows 11

5.1.2. Reconocimiento de emociones faciales en tiempo real

Uno de los elementos centrales de la lógica de recomendación es el reconocimiento automático de la emoción predominante del usuario a través de su rostro. Para ello, se implementó un sistema de visión por computadora basado en el navegador utilizando la biblioteca `face-api.js`, que permite el análisis de expresiones faciales en tiempo real sin necesidad de transmisión de imágenes al servidor ni procesamiento backend.

1. **Tecnología utilizada:** `face-api.js` es una biblioteca de JavaScript basada en TensorFlow.js que encapsula modelos de redes neuronales convolucionales previamente entrenados para la detección y análisis facial. Esta librería fue seleccionada por su eficiencia, compatibilidad con navegadores modernos, y por ser una solución que respeta la privacidad del usuario al ejecutar todos los procesos en el cliente.

Los principales modelos utilizados en esta implementación fueron:

- **TinyFaceDetector:** modelo liviano de detección de rostros que equilibra velocidad y precisión, ideal para ejecución en navegadores.
- **FaceExpressionNet:** red neuronal para clasificación de emociones faciales entre las siguientes clases: *happy*, *sad*, *angry*, *surprised*, *fearful*, *disgusted* y *neutral*.

2. **Flujo de trabajo:** El reconocimiento de emociones sigue el siguiente flujo lógico en el frontend:

- El usuario concede acceso a su cámara mediante permisos del navegador.
- Se inicia un intervalo periódico que captura fotogramas de la cámara cada cierto número de segundos (por ejemplo, cada 5 segundos).
- Se utiliza *TinyFaceDetector* para localizar el rostro dentro del fotograma capturado.
- Con el rostro localizado, se emplea *FaceExpressionNet* para calcular las probabilidades de cada emoción reconocida.
- Se selecciona como emoción dominante aquella con mayor probabilidad.
- Esta emoción se almacena temporalmente en el estado global del frontend, y también se envía a Firebase (Firestore) para su registro.
- Finalmente, la emoción detectada se convierte en uno de los parámetros clave de entrada para el sistema de recomendación tipo *multi-armed bandit* que opera desde el backend.




Figura 5.1: Flujo de captura y análisis de emociones con `face-api.js`

3. **Ventajas del enfoque utilizado:** Este enfoque en el navegador tiene múltiples beneficios:

- **Procesamiento local en el cliente:** no se transmiten imágenes a servidores externos, preservando la privacidad del usuario.
- **Experiencia en tiempo real:** el análisis facial se realiza con latencia mínima.
- **Alta compatibilidad:** funciona en cualquier dispositivo con un navegador moderno (computadoras, tablets, teléfonos móviles).
- **Fácil integración:** los resultados del análisis emocional se pueden conectar sincrónicamente con el resto de la lógica en React.

4. **Limitaciones técnicas observadas:** A pesar de su utilidad, se identificaron ciertas limitaciones:

- **Sensibilidad a condiciones lumínicas:** la precisión se ve afectada por sombras, poca luz o retroiluminación.
- **Limitación en dispositivos de baja gama:** puede ocasionar lentitud si el dispositivo tiene poca capacidad de procesamiento.
- **Ambigüedad entre emociones similares:** por ejemplo, las emociones *neutral* y *sad* presentan similitudes que pueden llevar a clasificaciones incorrectas.

5.1.3. Interfaz de usuario y flujo de interacción

La interfaz del sistema fue desarrollada con un enfoque centrado en el usuario, buscando proporcionar una experiencia clara, fluida y visualmente atractiva. Todo el flujo está diseñado para guiar progresivamente al usuario desde la selección inicial hasta la obtención de recomendaciones personalizadas, integrando reconocimiento emocional, decisiones interactivas y retroalimentación final.

1. Pantalla de inicio de sesión: autenticación de usuario

Antes de acceder al sistema, se presenta una pantalla de inicio de sesión que permite autenticar al usuario. Esta autenticación se realiza utilizando el sistema de autenticación de Firebase, que puede estar configurado para aceptar los métodos correo electrónico y contraseña y Google.

La interfaz de esta pantalla incluye campos básicos de entrada (correo y contraseña), un botón de ingresar, y enlaces para registrarse o ingresar con cuenta de Google.




Figura 5.2: Pantalla de inicio de sesión

2. Pantalla de captura de emociones y selección de color

A continuación, se presenta una pantalla clave para la personalización del sistema: el registro del estado emocional actual del usuario, mediante una captura facial usando la cámara del dispositivo, analizada en tiempo real por `face-api.js`.

Luego de registrar la emoción, el usuario debe seleccionar un color que represente o complemente su estado de ánimo actual. Esta información adicional sirve como parámetro visual que influye en la selección de prendas, reforzando la asociación entre emociones y preferencias estéticas.

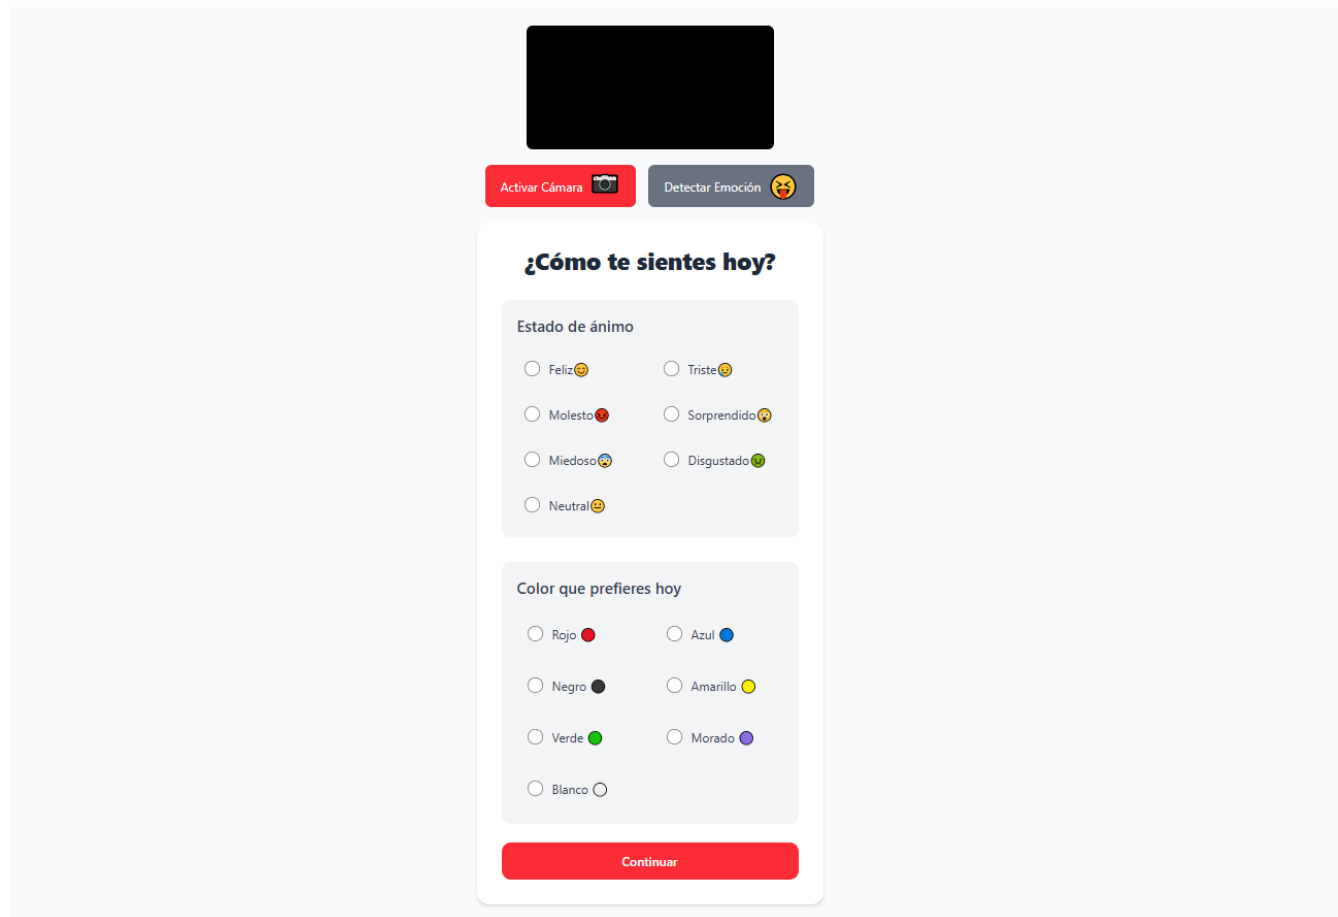
The image shows a mobile application interface for emotional capture and color selection. At the top, there is a black rectangular area representing the camera feed. Below it are two buttons: a red one labeled 'Activar Cámara' with a camera icon, and a grey one labeled 'Detectar Emoción' with a sad face emoji icon. The main content area is a white card with the title '¿Cómo te sientes hoy?'. It contains two sections: 'Estado de ánimo' with seven radio button options (Feliz, Triste, Molesto, Sorprendido, Miedoso, Disgustado, Neutral) each accompanied by an emoji, and 'Color que prefieres hoy' with eight radio button options (Rojo, Azul, Negro, Amarillo, Verde, Morado, Blanco) each accompanied by a colored circle. A red 'Continuar' button is at the bottom of the card.

Figura 5.3: Pantalla de captura emocional y selección de color

3. Pantalla de inicio: selección de categoría de prenda

Tras iniciar sesión exitosamente, se presenta una pantalla en la que el usuario puede elegir la categoría de prenda que desea explorar. Las opciones disponibles incluyen: camiseta, camisa, top, pantalones, short, falda/vestido y abrigo. Cada categoría está representada con una tarjeta ilustrada para facilitar la navegación visual. Esta elección inicial establece el enfoque del sistema de recomendación.




Figura 5.4: Pantalla de inicio: selección de categoría de prenda

4. Pantalla de selección de género: personalización por contexto estético

En esta etapa, el sistema solicita al usuario que indique su preferencia de visualización en cuanto al género de las prendas: *masculino* o *femenino*. Esta selección no implica una identificación de género del usuario, sino una afinación estética de las recomendaciones, permitiendo adaptar el contenido al contexto cultural, visual y funcional esperado por la persona usuaria.

La pantalla presenta dos opciones claramente diferenciadas, por dos botones. Esta decisión contribuye a filtrar el dataset de recomendaciones y a mejorar la percepción de relevancia en los resultados mostrados más adelante.




Figura 5.5: Pantalla de selección de género estético de las prendas

5. Pantalla de recomendaciones – Vista tipo Tinder

Esta es una de las pantallas centrales del sistema, diseñada para hacer el proceso de evaluación de prendas más dinámico, intuitivo y visualmente atractivo. En esta interfaz, las prendas se presentan de a una por vez mediante tarjetas de gran tamaño.

El usuario puede interactuar con cada tarjeta utilizando dos botones principales:

- **♥ Me gusta:** registra una preferencia positiva.
- **✗ No me gusta:** descarta la prenda.

Las tarjetas están diseñadas con animaciones suaves y transiciones visuales para hacer la experiencia más fluida y placentera. Este enfoque inspirado en la lógica de interacción de aplicaciones como Tinder permite captar rápidamente las preferencias del usuario de forma natural, sin necesidad de formularios extensos ni clics repetitivos.




Figura 5.6: Pantalla de recomendaciones con tarjetas interactivas tipo Tinder

6. Pantalla final y feedback: cierre de la experiencia de recomendación

Al finalizar la sesión de recomendaciones, el usuario es redirigido automáticamente a una pantalla de cierre que marca el final del flujo interactivo. Esta pantalla tiene un enfoque positivo y ligero, buscando reforzar una sensación de logro o satisfacción tras completar el proceso.

Visualmente, se presenta una animación o un GIF alegre (por ejemplo, relacionado con moda o emociones positivas), acompañado de un mensaje de agradecimiento por la participación. Esta elección busca generar un cierre emocionalmente grato y mantener una experiencia de usuario cohesiva de principio a fin.

Además, se incluye:

- Un enlace externo a un **formulario de satisfacción** (implementado con Google Forms), donde se recopila información cualitativa y cuantitativa sobre la experiencia: facilidad de uso, utilidad de las recomendaciones, diseño de la interfaz, entre otros aspectos.
- Un botón para que el usuario pueda indicar si ya completó el formulario y así omitir esta opción en futuras sesiones, mejorando así la personalización de su experiencia en el sistema.
- Un **botón adicional para enviar las prendas favoritas** al sistema de recomendación. Al presionar este botón, el conjunto de prendas marcadas como “Me gusta” durante la sesión se consolida y se envía de forma explícita al backend y se almacena en Firestore, permitiendo:
 - Registrar formalmente las elecciones del usuario.
 - Utilizar esa información como entrada directa para recomendaciones futuras.
 - Enriquecer el perfil del usuario dentro del sistema.




Figura 5.7: Pantalla final con animación positiva y formulario de retroalimentación

Toda la información que el usuario genera (incluyendo sus emociones, prendas seleccionadas, imágenes subidas y preferencia final) se almacena en Firebase Firestore, asociada al ID de usuario, lo que permite construir un perfil de preferencias detallado y permitiendo su posterior análisis o uso en ciclos de retroalimentación del sistema.

5.2. Conectividad y servicios en la nube con Firebase

Una parte fundamental del funcionamiento de la aplicación web desarrollada es su integración con servicios en la nube que permiten la autenticación, persistencia y consulta eficiente de datos, sin requerir la gestión manual de un servidor dedicado. Para ello, se utilizó Firebase, una plataforma de desarrollo

de aplicaciones en la nube proporcionada por Google, que ofrece una variedad de herramientas escalables que complementan y fortalecen tanto al frontend como al backend del sistema.

Firebase se encargó de facilitar la recolección y almacenamiento de datos clave provenientes del usuario, así como de proporcionar servicios críticos que habilitan el flujo de información hacia el sistema de recomendación basado en aprendizaje por refuerzo contextual. La elección de Firebase respondió a su fácil integración con tecnologías basadas en JavaScript, su escalabilidad inmediata y su infraestructura segura y altamente disponible.

5.2.1. Servicios utilizados

La implementación incluyó el uso de los siguientes servicios de Firebase:

- **Firebase Authentication:** Se utilizó para permitir el inicio de sesión y la autenticación segura de los usuarios. Este componente gestiona el acceso personalizado a cada sesión, garantizando que las emociones, selecciones y resultados se almacenen y consulten de forma individual.
- **Firebase Firestore:** Es la base de datos NoSQL en tiempo real utilizada para almacenar todos los datos relacionados con el usuario. Entre ellos se incluyen:
 - Emociones detectadas a través del análisis facial.
 - Selecciones de prendas hechas por el usuario.
 - Resultados del formulario de satisfacción.
 - Cualquier dato adicional sobre comportamiento o interacción con la interfaz.
- **Firebase Hosting (opcional):** Durante la fase de pruebas, la aplicación fue desplegada como una Progressive Web App (PWA) utilizando Firebase Hosting, lo cual permitió realizar validaciones funcionales desde cualquier navegador moderno, simulando condiciones reales de uso.

5.2.2. Ventajas de la integración con Firebase

La utilización de Firebase aportó múltiples ventajas para el desarrollo y despliegue del sistema:

- **Escalabilidad sin configuración de servidores:** El sistema puede atender a múltiples usuarios simultáneamente sin necesidad de infraestructura dedicada.
- **Sincronización en tiempo real:** Permite reflejar de inmediato los datos capturados desde el frontend al backend, habilitando respuestas personalizadas dinámicas.
- **Seguridad:** Los datos del usuario se mantienen bajo control de acceso mediante Firebase Authentication, protegiendo su privacidad.
- **Despliegue rápido:** El uso de Firebase Hosting facilitó la distribución del prototipo para pruebas remotas, con mínima configuración.

5.2.3. Relación con el sistema de recomendación

Los datos recopilados y gestionados por Firebase constituyen la entrada fundamental del sistema de recomendación. Las emociones detectadas, junto con las preferencias y elecciones del usuario, se consolidan como contexto que posteriormente se envía al backend para ser procesado por la red neuronal *multi-armed bandit*. Esta integración asegura que el sistema pueda aprender de cada sesión individual, personalizando y optimizando las recomendaciones en función del estado emocional del usuario.

5.3. Implementación del Backend y Entrenamiento del Modelo

El backend de la aplicación fue desarrollado utilizando FastAPI, un framework moderno y eficiente para la creación de APIs en Python, seleccionado por su alto rendimiento, tipado estático y facilidad de integración. Este módulo actúa como puente entre el frontend, la base de datos y el modelo de recomendación, permitiendo la gestión de usuarios, el almacenamiento de preferencias y la entrega dinámica de sugerencias de prendas.

Además, el backend incorpora un sistema inteligente de toma de decisiones basado en aprendizaje por refuerzo, específicamente mediante una red neuronal denominada BanditNet. Esta red implementa un algoritmo tipo Multi-Armed Bandit, que permite ajustar las recomendaciones en función del estado emocional del usuario y su historial de interacciones. Gracias a esta arquitectura, el sistema es capaz de aprender y adaptarse continuamente a las preferencias individuales, mejorando progresivamente la calidad de las recomendaciones.

5.3.1. Contexto de Ejecución

El sistema de recomendación inteligente fue desarrollado y ejecutado localmente para permitir un control total sobre el proceso de entrenamiento, pruebas y simulación del modelo de aprendizaje por refuerzo. Las características técnicas del entorno de desarrollo fueron las siguientes:

- **Procesador:** Intel Core i5 de 8.^a generación
- **Memoria RAM:** 16 GB DDR4
- **GPU:** Nvidia GeForce GTX 1050Ti
- **Almacenamiento:** SSD NVMe de 1 TB
- **Sistema Operativo:** Windows 10

Este entorno permitió realizar experimentos controlados con capacidad suficiente para entrenamiento ligero en tiempo real, así como la evaluación del modelo bajo distintas configuraciones.

5.3.2. Funcionamiento General del Backend

A continuación, se presenta en pseudocódigo una visión simplificada de los pasos clave que ejecuta el backend durante su inicialización. Esto incluye la configuración de la aplicación, la carga de archivos esenciales (como datos de productos y retroalimentación) y la preparación del algoritmo *Multi-Armed Bandit*, encargado de personalizar las recomendaciones según las preferencias del usuario.

Algorithm 1 Inicio del Sistema y Configuración

- 1: Inicializar la aplicación **FastAPI**
 - 2: Habilitar CORS para permitir peticiones desde cualquier origen
 - 3: Cargar archivo **recommendations.json**
 - 4: **if** el archivo no existe **then**
 - 5: Lanzar error
 - 6: **end if**
 - 7: Cargar (o crear) archivo **feedback.json**
 - 8: Cargar archivo **prendas.csv** con datos de prendas
 - 9: Inicializar algoritmo **Multi-Armed Bandit** para personalizar recomendaciones
-

5.3.3. Funcionamiento del sistema de recomendación emocional de prendas

Antes de aplicar el modelo Multi-Armed Bandit, el sistema realiza un preprocesamiento de los datos que considera tanto el contexto emocional del usuario como las preferencias de género y categoría. Este filtrado inicial es esencial para limitar el espacio de búsqueda a aquellas prendas que tienen una mayor probabilidad de ser relevantes.

El sistema utiliza un diccionario que asocia emociones con colores preferentes, lo cual permite adaptar visualmente las recomendaciones al estado de ánimo del usuario. En caso de que la emoción detectada sea “neutral”, se reemplaza por “happy” como estado base, siguiendo estudios previos que indican una mejor respuesta del usuario a recomendaciones positivas.

A continuación, se presenta el pseudocódigo que resume el proceso completo:

Algorithm 2 Sistema de recomendación emocional de prendas

```

1: Cargar diccionario de colores recomendados por emoción
2: Recibir datos del usuario: emoción, género, categoría
3: if emoción = "neutral" then
4:   emoción  $\leftarrow$  "happy"
5: end if
6: Buscar colores asociados a la emoción
7: Leer archivo recomendaciones.json
8: Leer archivo prendas.csv
9: Filtrar recomendaciones donde:

```

- emoción coincide con la del usuario
- género coincide con el del usuario
- categoría coincide
- color está en los recomendados

```

10: if númeroderesultados < 10 then
11:   Buscar más prendas en prendas.csv donde:

```

- color está en los recomendados
- categoría coincide
- género coincide o es *unisex*

```

12: end if
13: Mezclar todas las prendas filtradas
14: Aplicar algoritmo Multi-Armed Bandit:

```

- Asignar puntuación a cada prenda
- Seleccionar las mejores según la puntuación

```

15: Devolver 12 prendas ordenadas por puntuación

```

Este procedimiento garantiza que las prendas presentadas al usuario no solo estén contextualizadas emocionalmente, sino que también estén adaptadas a sus decisiones previas y preferencias visuales, mejorando la calidad de la recomendación.

5.3.4. Red Neuronal Basada en Multi-Armed Bandit

El sistema de recomendación de prendas implementado en este proyecto se basa en un enfoque de aprendizaje por refuerzo, específicamente utilizando el algoritmo Multi-Armed Bandit (MAB). Este modelo es ideal para problemas en los que es necesario tomar decisiones dinámicas, equilibrando la exploración de nuevas opciones con la explotación de las preferencias ya conocidas. En este caso, el sistema tiene como objetivo predecir qué prendas serán de mayor interés para el usuario, mejorando así la experiencia de recomendación a través de la interacción continua y el aprendizaje en línea.

El algoritmo fue implementado utilizando Python y la librería PyTorch, lo que permitió construir una red neuronal que actúa como un estimador de recompensa. Esta red se entrena de manera online, es decir, cada vez que el usuario proporciona retroalimentación sobre una prenda sugerida (como un me gusta o no me gusta), el sistema ajusta su comportamiento y mejora sus recomendaciones.

El objetivo del sistema es aprender qué combinaciones de emoción y color tienden a generar mayor satisfacción en el usuario. Esta capacidad de adaptación constante es esencial para lograr un sistema de recomendación eficiente, que se ajuste a las preferencias cambiantes de los usuarios.

La red neuronal incorporada en el modelo juega un papel crucial en la predicción de la probabilidad de aceptación de una prenda. Esta probabilidad se calcula tomando en cuenta diversos factores, entre los cuales destacan:

- **Emoción del usuario:** El estado emocional del usuario en el momento de la recomendación influye directamente en sus decisiones de recomendación. El sistema utiliza esta variable para ajustar las recomendaciones, favoreciendo prendas que podrían coincidir con el estado anímico del individuo.
- **Color principal de la prenda:** La percepción del color también juega un papel importante en la atracción visual hacia un producto. El sistema incorpora esta variable para hacer predicciones más personalizadas, favoreciendo aquellos colores que podrían resonar con las preferencias o el estado de ánimo del usuario.

5.3.5. Funcionamiento del Algoritmo Multi-Armed Bandit

El modelo recibe como entrada una emoción (por ejemplo, *happy*) y un conjunto de opciones de prendas filtradas por género y categoría. Este enfoque permite que el sistema combine una emoción y color que tienen mayores probabilidades de generar una buena aceptación por parte del usuario. A diferencia de modelos estáticos, el Multi-Armed Bandit se adapta dinámicamente según la retroalimentación recibida, lo que resulta ideal para contextos donde las preferencias del usuario pueden ser variables o desconocidas al inicio.

El procedimiento seguido por el modelo consta de los siguientes pasos:

1. **Codificación de la Entrada:** La emoción del usuario y el color base de cada prenda son transformados en vectores one-hot. Esta codificación permite que estos atributos categóricos puedan ser procesados por la red neuronal como entradas numéricas. En total, el vector de entrada tiene una dimensión fija (7 emociones + 16 colores = 23 dimensiones).

2. **Evaluación de Prendas:** Cada una de las prendas disponibles en la sesión es evaluada por la red neuronal. El modelo predice un valor esperado de recompensa, que se interpreta como la probabilidad de que el usuario acepte esa prenda en función de su estado emocional actual y del color de la prenda.
3. **Selección de Prendas:** Se seleccionan las top-K prendas con las puntuaciones más altas según la red neuronal. Sin embargo, para permitir la exploración y evitar que el modelo se estanque en decisiones subóptimas, se aplica una estrategia *epsilon-greedy*. Esto significa que, con una probabilidad ε (epsilon), el sistema elige aleatoriamente entre todas las opciones disponibles, y con probabilidad $(1 - \varepsilon)$, selecciona entre las top-K. Este mecanismo garantiza un equilibrio entre seguir lo que ya se sabe que funciona y seguir aprendiendo de nuevas combinaciones.
4. **Presentación al Usuario:** Una de las prendas seleccionadas se muestra al usuario a través de la interfaz. El usuario puede responder indicando su preferencia (por ejemplo, me gusta o no me gusta). Esta interacción constituye una muestra de entrenamiento que puede usarse para actualizar el modelo.
5. **Entrenamiento en Línea del Modelo:** Si el usuario proporciona retroalimentación, la red neuronal se entrena nuevamente utilizando esta nueva muestra. Este proceso de aprendizaje en línea permite que el sistema ajuste sus pesos internos de forma continua, mejorando su capacidad predictiva para futuras recomendaciones. A lo largo del tiempo, esto ayuda a personalizar cada vez más las sugerencias, adaptándose a los gustos del usuario.

La red neuronal utilizada, **BanditNet**, tiene la siguiente arquitectura:

- **Una capa de entrada:** que codifica la emoción del usuario y el color base de la prenda. Vector de 23 dimensiones (7 emociones + 16 colores base).
- **Primera capa oculta:** 64 neuronas con activación ReLU, seguida de normalización **LayerNorm** y Dropout de 0.3.
- **Segunda capa oculta:** 32 neuronas con activación ReLU.
- **Capa de salida:** una única neurona con activación Sigmoid que predice la probabilidad de preferencia del usuario (recompensa esperada).

```
BanditNet(
    Linear(23 → 64),
    LayerNorm(64),
    ReLU(),
    Dropout(0.3),
    Linear(64 → 32),
    ReLU(),
    Linear(32 → 1),
    Sigmoid()
)
```

Configuraciones del modelo:

- **Función de pérdida:** MSELoss (Error cuadrático medio).
- **Optimizador:** Adam.

- **Tasa de aprendizaje (learning rate):** entre 0.005 y 0.02 según la configuración evaluada.
- **Exploración (epsilon ε):** valores entre 0.1 y 0.3, ajustados para balancear exploración y explotación.
- **Entrenamiento:** en línea (online learning), con actualización tras cada interacción del usuario.

Este enfoque de aprendizaje en línea y la retroalimentación constante por parte del usuario permiten que el modelo se adapte dinámicamente a sus preferencias y mejore la precisión de las recomendaciones con el tiempo.

Para mayor claridad del modelo de aprendizaje por refuerzo, este apartado resume en pseudocódigo el flujo de funcionamiento, desde la fase inicial de predicción hasta el proceso de actualización del modelo con base en la retroalimentación del usuario, sentando así las bases para una mejora progresiva en la calidad de las recomendaciones..

Algorithm 3 Algoritmo Multi-Armed Bandit con red neuronal

```

1: Inicializar red neuronal simple
2:   Entrada: emoción + color de la prenda
3:   Salida: puntuación (qué tanto gusta la prenda)

4: Recomendación de una prenda
5: if modo = explorar then
6:   Elegir prenda aleatoria
7: else if modo = explotar then
8:   for all prendas disponibles do
9:     Calcular puntuación usando la red neuronal
10:  end for
11:  Elegir prenda con mayor puntuación
12: end if

13: Recomendación de varias prendas
14: for all prendas disponibles do
15:   Calcular puntuación con la red neuronal
16: end for
17: Ordenar prendas por puntuación
18: Elegir las mejores (con algo de aleatoriedad)

19: Al recibir feedback del usuario
20: Recibir prenda evaluada y su valoración (me gusta / no me gusta)
21: Obtener datos de entrada de la prenda evaluada
22: Calcular error entre puntuación esperada y real
23: Ajustar pesos de la red neuronal para aprender

24: Repetir pasos para seguir mejorando las recomendaciones

```

5.3.6. Evaluación de Corridas del Modelo BanditNet

Se realizaron varias simulaciones para validar el modelo, variando parámetros como tasa de aprendizaje, número de épocas y nivel de exploración, con el objetivo de validar la estabilidad del modelo BanditNet bajo múltiples ejecuciones, se realizaron 10 corridas independientes variando únicamente la semilla aleatoria. En cada corrida, el modelo fue entrenado durante 5000 épocas con los siguientes parámetros fijos:

- **Learning rate:** 0.01
- **Epsilon (exploración):** 0.2
- **Feedback simulado:** 1000 muestras sintéticas generadas aleatoriamente

En la Tabla 5.1 se resumen los errores obtenidos al final de cada corrida y el promedio del error cuadrático medio (MSE) durante las últimas 100 épocas de entrenamiento.

Corrida	Error Final (MSE)	MSE promedio últimos 100
1	1.41×10^{-5}	1.74×10^{-4}
2	1.15×10^{-7}	3.10×10^{-4}
3	1.31×10^{-5}	9.49×10^{-3}
4	1.89×10^{-4}	1.10×10^{-2}
5	6.24×10^{-7}	2.00×10^{-2}
6	6.68×10^{-3}	5.91×10^{-2}
7	1.49×10^{-5}	3.36×10^{-2}
8	1.95×10^{-5}	2.09×10^{-2}
9	1.44×10^{-5}	1.04×10^{-2}
10	2.19×10^{-3}	6.13×10^{-3}

Tabla 5.1: Resumen de 10 corridas del modelo BanditNet.




Figura 5.8: Error final por corrida del modelo BanditNet




Figura 5.9: Promedio del MSE en las últimas 100 épocas

Los resultados muestran cierta variabilidad entre corridas, especialmente en las últimas épocas. Sin embargo, incluso en los peores casos (corrida 6), el error se mantiene dentro de rangos aceptables para un sistema de aprendizaje por refuerzo con retroalimentación simulada. En general, el modelo converge de forma eficiente en la mayoría de ejecuciones, confirmando su estabilidad.

Evaluación del comportamiento del error

De forma general, se ejecutaron múltiples iteraciones de entrenamiento (simulando sesiones de retroalimentación de usuarios). En la tabla 5.2 se presenta un resumen de algunas ejecuciones con distintas tasas de aprendizaje y epsilon.

Learning Rate	Epsilon	Error Final	Promedio Últimos 100	Semilla
0.005	0.1	$4.50e^{-7}$	$6.08e^{-7}$	42
0.005	0.2	$4.50e^{-7}$	$6.08e^{-7}$	42
0.005	0.3	$4.50e^{-7}$	$6.08e^{-7}$	42
0.010	0.1	$5.71e^{-8}$	$9.42e^{-8}$	42
0.010	0.2	$5.71e^{-8}$	$9.42e^{-8}$	42
0.010	0.3	$5.71e^{-8}$	$9.42e^{-8}$	42
0.020	0.1	$1.83e^{-9}$	$8.80e^{-7}$	42
0.020	0.2	$1.83e^{-9}$	$8.80e^{-7}$	42
0.020	0.3	$1.83e^{-9}$	$8.80e^{-7}$	42

Tabla 5.2: Evaluación de combinaciones de parámetros: learning rate y epsilon

En la figura 5.10 ilustra cómo el error de entrenamiento disminuye progresivamente durante las iteraciones iniciales del modelo. Este comportamiento sugiere que el modelo es capaz de ajustarse eficazmente con pocas muestras de retroalimentación.




Figura 5.10: Error total de la red neuronal Bandit - Ejecución inicial

Evaluación con datos ruidosos

El modelo fue evaluado bajo condiciones simuladas de ruido, introduciendo alteraciones aleatorias en las emociones y colores base. Esta prueba permite observar la robustez del sistema cuando se presentan datos no ideales o inconsistencias. A continuación se presentan los resultados obtenidos para distintos niveles de ruido:

Ruido (%)	Accuracy	Recall (Clase 1)	F1 Score	AUC
0	1.0000	1.0000	1.0000	1.0000
5	0.9933	1.0000	0.9091	0.9966
10	0.9833	1.0000	0.8148	0.9913
15	0.9933	0.7500	0.7500	0.8733
20	0.9833	0.6923	0.7826	0.8444
30	0.9667	0.2222	0.2857	0.6060

Tabla 5.3: Resultados con diferentes niveles de ruido en la entrada

Como se observa, el modelo mantiene un desempeño sobresaliente en niveles bajos de ruido (hasta un 10%), conservando altos valores de exactitud (accuracy), sensibilidad (recall) y capacidad de discriminación (AUC). A partir de un 15% de ruido, la capacidad para identificar correctamente la clase positiva comienza a deteriorarse gradualmente.




Figura 5.11: Comparativa del desempeño del modelo ante distintos niveles de ruido

Visualización del espacio de decisión

Con el objetivo de comprender cómo el modelo BanditNet valora las distintas combinaciones de emociones y colores de prendas, se realizó una visualización del espacio de decisión mediante un mapa de calor bidimensional.

Cada celda de la matriz representa el score de preferencia que el modelo predice para una combinación de emoción detectada y color de prenda. Estos valores corresponden a la salida de la red neuronal, tras aplicar una activación sigmoide, lo cual produce un número entre 0 y 1 que puede interpretarse como la probabilidad estimada de que esa prenda sea del agrado del usuario bajo dicha emoción.




Figura 5.12: Mapa de calor del espacio de decisión del modelo (emociones vs colores)

Como se observa en la Figura 5.12, el modelo presenta ligeras variaciones en las puntuaciones asignadas. Aunque en esta versión se utilizó una red neuronal con pesos aleatorios simulando comportamiento entrenado, se pueden evidenciar algunas combinaciones favorecidas. Por ejemplo:

- En el caso de la emoción **angry**, los colores **red**, **blue** y **yellow** tienen puntuaciones más elevadas, lo que podría sugerir que el modelo aprendió a asociar tonos cálidos o intensos a emociones más fuertes.
- Para emociones como **neutral** o **happy**, las puntuaciones son más uniformes, aunque también se favorecen colores como **white**, **yellow** o **pink**.

Este tipo de visualización proporciona una herramienta útil para auditar el comportamiento del modelo, y puede ser clave en futuras extensiones orientadas a mejorar la explicabilidad del sistema de recomendación.

Discusión

Los resultados muestran que el modelo Bandit logra reducir progresivamente el error a medida que recibe retroalimentación, adaptándose a las preferencias del usuario sin necesidad de un conjunto de entrenamiento predefinido. Esta capacidad de aprendizaje en línea lo hace ideal para aplicaciones interactivas como la presente, donde los gustos cambian y la personalización es clave.

En la figura 5.13 se observa una ejecución que alcanzó un error inferior a 0.005 después de 4000 iteraciones, validando la efectividad del entrenamiento incremental.




Figura 5.13: Reducción progresiva del error durante entrenamiento Bandit

5.3.7. Integración con el Frontend: Sistema de Recomendación Interactiva

Para brindar una experiencia de usuario ágil y personalizada, se implementó en el frontend un modo interactivo de recomendación de prendas, inspirado en aplicaciones como Tinder. En este modo, el usuario puede expresar si una prenda le gusta o no le gusta mediante botones visuales: un ícono de corazón ♥ para aceptar y uno de ✕ para rechazar.

Este sistema se conecta directamente con el backend a través de dos endpoints principales de la API, los cuales permiten tanto obtener recomendaciones como retroalimentar al modelo:

GET /api/tinder-recommendation

- **Entrada:** emoción actual del usuario, género y categoría de prendas.
- **Salida:** una prenda sugerida por el modelo, seleccionada según la probabilidad de aceptación estimada.

Este endpoint se encarga de generar recomendaciones personalizadas en función del estado emocional del usuario y los filtros seleccionados.

POST /api/tinder-feedback-batch

- **Entrada:** lista de prendas con “like” agrupadas por emoción.
- **Acción:** actualiza el modelo de recomendación entrenándolo en tiempo real con los nuevos datos de retroalimentación.

Este flujo asegura que cada decisión del usuario contribuya directamente al aprendizaje del modelo, mediante un proceso de entrenamiento en línea que ajusta continuamente las recomendaciones según las preferencias observadas.

Este mecanismo se resume en el Diagrama de Flujo de Recomendación Interactiva en la Figura 5.14, el cual muestra cómo se articula la comunicación entre el usuario, el frontend y el backend:



Figura 5.14: Flujo de comunicación entre usuario, frontend y backend en el sistema de recomendación.

Capítulo 6

Pruebas

6.1. Diseño de la Evaluación

La fase de pruebas fue planteada como un componente fundamental para validar el funcionamiento del prototipo de sistema de recomendación de ropa basado en el bienestar emocional del usuario. Dado que el enfoque principal del sistema es ofrecer recomendaciones personalizadas en función del estado emocional detectado o declarado por el usuario, la evaluación debía contemplar tanto la eficacia técnica como la percepción subjetiva de quienes utilizaron la aplicación.

6.1.1. Objetivo de la evaluación

El propósito principal de las pruebas fue evaluar la experiencia del usuario al interactuar con la aplicación web desarrollada, que recomienda prendas de vestir basadas en el estado emocional del usuario. Los objetivos principales de esta fase fueron:

1. Evaluar la experiencia de uso general del sistema, incluyendo la facilidad de interacción, la comprensión del flujo de navegación y la intuitividad del mecanismo de selección de prendas.
2. Validar si las recomendaciones ofrecidas eran percibidas por los usuarios como adecuadas en relación con su estado emocional.
3. Recoger observaciones y sugerencias cualitativas que permitieran identificar oportunidades de mejora en futuras iteraciones del prototipo.

6.1.2. Instrumento de evaluación: Encuesta estructurada

Para la recolección de datos se utilizó una encuesta estructurada, aplicada de manera posterior al uso directo del sistema por parte de los usuarios. A diferencia de otros enfoques que usan videos o simulaciones, esta prueba se centró en la experiencia interactiva real, donde cada participante ingresó a la aplicación, respondió un cuestionario inicial de estado emocional, visualizó las prendas recomendadas, e interactuó con ellas mediante un sistema tipo “me gusta / no me gusta”.

La encuesta fue diseñada bajo principios de evaluación de la experiencia de usuario (UX), permitiendo analizar dimensiones clave como: claridad en el uso, adecuación de las recomendaciones, comprensión del sistema, y satisfacción general. Incluyó preguntas cerradas de selección múltiple, escalas de valoración y una pregunta abierta para capturar comentarios espontáneos.

6.1.3. Revisión y depuración del cuestionario

Durante esta etapa, se llevó a cabo un proceso de análisis y ajuste de la encuesta con el objetivo de garantizar la coherencia, claridad y relevancia de las preguntas formuladas. La revisión se enfocó en alinear las preguntas con los objetivos del estudio, asegurando que cada uno permitiera recopilar información significativa sobre los aspectos de usabilidad, perceptuales y emocionales asociados al sistema.

En su versión final, la encuesta constó de 12 preguntas, de las cuales 11 fueron cerradas (opciones de respuesta predeterminadas) y 1 fue abierta (comentario libre). Las preguntas se organizaron en tres bloques temáticos:

- **Datos sociodemográficos y de contexto de uso:** para comprender mejor el perfil del usuario y el entorno en el que usó la aplicación.
- **Percepción de la experiencia emocional y funcionalidad:** para evaluar la capacidad del sistema de interpretar emociones y generar recomendaciones acordes.
- **Evaluación de la usabilidad y experiencia general:** para valorar la facilidad de uso, comprensión de las funcionalidades y satisfacción subjetiva.

6.1.4. Contenido de la Encuesta

La siguiente tabla resume las preguntas utilizadas, su propósito principal y su agrupación temática:

N.º	Pregunta resumida	Categoría temática	Tipo
1	Género del usuario	Perfil demográfico	Cerrada
2	Rango de edad	Perfil demográfico	Cerrada
3	Tipo de dispositivo utilizado	Contexto de uso	Cerrada
4	Frecuencia de uso de apps de compras/recomendación	Contexto de uso	Cerrada
5	¿La app comprendió tu estado emocional?	Evaluación emocional	Cerrada
6	¿Las recomendaciones fueron adecuadas para tu estado de ánimo?	Evaluación emocional	Cerrada
7	¿Cantidad de prendas mostradas fue suficiente?	Evaluación funcional	Cerrada
8	¿Al menos una prenda fue llamativa?	Evaluación emocional	Cerrada
9	Claridad al empezar a usar la app	Usabilidad	Cerrada
10	¿La dinámica "me gusta/no me gusta" fue intuitiva?	Usabilidad	Cerrada
11	Calificación general de la experiencia (1 a 5)	Satisfacción	Escala
12	Comentarios y sugerencias	Opinión libre	Abierta

Tabla 6.1: Tabla de Preguntas y Categorías

Este diseño permitió obtener una visión integral del desempeño del sistema, considerando tanto las impresiones cuantificables como las reflexiones personales de los participantes. La estructura modular de la encuesta favoreció el análisis detallado de cada componente clave de la experiencia de usuario.

6.2. Ejecución y Resultados de las Pruebas

Se realizó una prueba cuantitativa y cualitativa de percepción y experiencia de usuario, después de utilizar la aplicación. Esta metodología se enmarca dentro de las pruebas de usabilidad y se enfoca en medir tanto variables objetivas (como claridad o frecuencia de uso) como subjetivas (como percepción emocional o gusto por las prendas).

Una vez finalizado el desarrollo del prototipo, se aplicó la encuesta diseñada a un grupo de 21 participantes, en su mayoría estudiantes y jóvenes adultos con conocimientos básicos de uso de tecnología y aplicaciones móviles o web.

6.2.1. Pregunta 1: ¿Cuál es tu género?

Esta primera pregunta permitió caracterizar el perfil demográfico básico de los participantes. La mayoría de las respuestas correspondieron al género masculino, representando el 76.2% del total, mientras que el género femenino representó el 23.8%.

1. ¿Cuál es tu género?

21 respuestas




Figura 6.1: Resultados de la pregunta 1 de la encuesta

Se observa una clara mayoría de usuarios de género masculino en la muestra. Esta distribución puede deberse a que el entorno de prueba estuvo más vinculado a una comunidad universitaria con predominancia masculina (por ejemplo, ingeniería de sistemas o carreras afines). Aunque no es necesariamente un sesgo negativo, sí es importante tenerlo en cuenta, ya que las preferencias visuales y emocionales pueden diferir entre géneros en el contexto de la moda.

Estudios como el de Joo [29] muestran que los modelos de recomendación basados en emociones pueden recibir diferentes niveles de aceptación según el género, siendo las mujeres generalmente más receptivas a la personalización emocional. Por lo tanto, sería recomendable en futuras iteraciones diversificar más la muestra para obtener una percepción más equilibrada en cuanto a género.

6.2.2. Pregunta 2: ¿Cuál es tu edad?

En cuanto a la edad, el 81 % de los participantes se ubicó en el rango de 18 a 24 años, mientras que el 19 % restante se distribuyó en el rango de 25 a 34 años. No se registraron respuestas de personas menores de 18 ni mayores de 35 años.

2. ¿Cuál es tu edad?

21 respuestas




Figura 6.2: Resultados de la pregunta 2 de la encuesta

La mayoría de los usuarios pertenece al rango de edad de 18 a 24 años, lo cual es coherente con el público objetivo inicial del sistema: jóvenes adultos acostumbrados al uso de tecnología, redes sociales y apps de personalización. Este grupo etario tiene una alta afinidad con sistemas de recomendación visuales e interfaces tipo swipe, como lo respaldan estudios como el de Chung [30], los jóvenes prefieren experiencias rápidas, visuales y emocionalmente relevantes.

Este rango también es clave para validar el atractivo de la app, ya que son usuarios más dispuestos a probar nuevas interfaces y dar retroalimentación crítica sobre su experiencia digital.

6.2.3. Pregunta 3: ¿Con qué dispositivo accediste a la app?

La tercera pregunta se enfocó en identificar los medios técnicos utilizados por los participantes. El 66.7 % de los usuarios accedió a la aplicación a través de un celular, mientras que el 33.3 % lo hizo desde una computadora.

3. ¿Con qué dispositivo accediste a la app?

21 respuestas




Figura 6.3: Resultados de la pregunta 3 de la encuesta

El uso mayoritario del celular como dispositivo de acceso demuestra la importancia de que la aplicación esté optimizada para entornos móviles. Esto concuerda con las tendencias actuales, según Statista [31], más del 60 % del tráfico web global proviene de dispositivos móviles. Además, para apps de recomendación de moda, el uso desde el celular facilita una experiencia más cercana al usuario, al permitir la toma de fotos, interacción táctil directa, y uso cotidiano.

Que un tercio haya accedido desde computadora también sugiere que la versión web no debe ser descuidada. Aun así, la ausencia de usuarios desde tablets indica que este no es un canal relevante para la muestra actual.

6.2.4. Pregunta 4: ¿Con qué frecuencia usas aplicaciones de recomendación o compras en línea?

Resultados:

- Todos los días: 4.8 %
- Varias veces por semana: 9.5 %
- Una vez por semana: 19 %
- Rara vez: 52.4 %
- Nunca: 14.3 %

4. ¿Con qué frecuencia usas aplicaciones de recomendación o compras en línea?

21 respuestas




Figura 6.4: Resultados de la pregunta 4 de la encuesta

La mayoría de los usuarios (66.7 %) indicó que usa raramente o nunca aplicaciones de recomendación o compras online. Este dato es clave, ya que revela que el público que evaluó la app no está familiarizado con este tipo de sistemas, lo cual plantea un mayor desafío de diseño y usabilidad.

Sin embargo, el hecho de que usuarios poco acostumbrados hayan logrado interactuar con la aplicación permite valorar positivamente su accesibilidad. Según Ricci [32], la facilidad de uso y la percepción de utilidad son factores determinantes para que los usuarios adopten sistemas de recomendación, especialmente si no tienen experiencia previa.

Además, estudios como el de Pu, Chen & Hu [33] muestran que la confianza y la personalización emocional incrementan la aceptación de estos sistemas, incluso entre usuarios novatos. Esto resalta la importancia de un diseño claro, atractivo y emocionalmente alineado con el usuario.

6.2.5. Pregunta 5: ¿Sentiste que la aplicación comprendió correctamente tu estado emocional?

Resultados:

- Sí: 90.5 %
- No: 9.5 %

5. ¿Sentiste que la aplicación comprendió correctamente tu estado emocional?

21 respuestas




Figura 6.5: Resultados de la pregunta 5 de la encuesta

Una gran mayoría de los participantes (más del 90 %) afirmó que la aplicación logró interpretar correctamente su estado emocional. Este resultado es altamente positivo y valida uno de los ejes centrales del sistema: su capacidad para vincular emociones con recomendaciones de vestimenta.

Esto sugiere que la combinación del formulario emocional inicial, junto con la lógica del recomendador, fue percibida como coherente por los usuarios. Según Martínez [34], la percepción de “empatía tecnológica” en sistemas personalizados es clave para mejorar la experiencia del usuario, ya que genera confianza y aumenta la disposición a seguir usando la herramienta.

Este resultado también indica que, aunque muchos usuarios no están familiarizados con este tipo de tecnología (como se vio en la pregunta 4), la aplicación logró transmitir efectividad emocional de forma intuitiva, lo que potencia su valor como sistema innovador.

6.2.6. Pregunta 6: ¿Las recomendaciones de ropa que viste te parecieron adecuadas para tu estado de ánimo?

Resultados:

- Muy adecuadas: 23.8 %
- Algo adecuadas: 61.9 %
- Poco adecuadas: 9.5 %
- Nada adecuadas: 4.8 %

6. ¿Las recomendaciones de ropa que viste te parecieron adecuadas para tu estado de ánimo?

21 respuestas




Figura 6.6: Resultados de la pregunta 6 de la encuesta

Cerca del 86 % de los usuarios consideraron que las recomendaciones fueron muy o algo adecuadas en relación con su estado emocional, lo cual es un indicador sólido de la eficacia perceptiva del motor de recomendación.

El grupo mayoritario (61.9 %) eligió la opción *algo adecuadas*, lo que sugiere que el sistema fue generalmente certero, pero todavía existe espacio para mejorar la precisión emocional de las sugerencias. Esto puede deberse a que los modelos emocionales aplicados aún no logran capturar por completo la subjetividad emocional de cada individuo o que la selección de prendas asociadas a ciertas emociones podría refinarse más.

Solo un 14.3 % expresó una percepción negativa (poco o nada adecuadas), lo que indica casos aislados donde el sistema no logró una alineación efectiva, posiblemente por diferencias individuales en la expresión o interpretación emocional.

Como destaca Picard [1], para que un sistema emocional sea realmente eficaz, no solo debe detectar emociones, sino también responder con estímulos que el usuario perciba como congruentes. Por lo tanto, estas observaciones pueden ser clave para futuras mejoras en la personalización de las sugerencias.

6.2.7. Pregunta 7: ¿Consideras que la cantidad de prendas mostradas fue suficiente para elegir?

Resultados:

- Sí: 57.1 %
- No: 42.9 %

7. ¿Consideras que la cantidad de prendas mostradas fue suficiente para elegir?

21 respuestas




Figura 6.7: Resultados de la pregunta 7 de la encuesta

La mayoría de los usuarios (57.1 %) consideró que la cantidad de prendas mostradas fue suficiente, aunque un porcentaje considerable (42.9 %) opinó lo contrario. Esta división sugiere que existe una percepción relativamente equilibrada respecto al volumen de opciones ofrecidas, lo cual es relevante en sistemas de recomendación.

En sistemas como este, la cantidad de elementos mostrados debe mantener un equilibrio entre variedad y saturación. Según Chen [35], un exceso de opciones puede generar fatiga decisional, mientras que una oferta limitada puede afectar la percepción de utilidad del sistema.

El hecho de que casi la mitad de los usuarios solicitara más opciones indica una oportunidad de mejora: implementar una funcionalidad que permita al usuario ver más recomendaciones si lo desea podría mejorar la experiencia, sin comprometer la simplicidad inicial de la app.

6.2.8. Pregunta 8: ¿Encontraste llamativa al menos una prenda recomendada durante el uso de la app?

Resultados:

- Sí: 90.5 %
- No: 9.5 %

8. ¿Encontraste llamativa al menos una prenda recomendada durante el uso de la app?

21 respuestas




Figura 6.8: Resultados de la pregunta 8 de la encuesta

Una gran mayoría de usuarios (90.5 %) respondió afirmativamente, indicando que al menos una prenda recomendada les resultó visualmente atractiva. Este resultado refuerza la eficacia visual del sistema y su capacidad de captar la atención del usuario, un aspecto fundamental en plataformas de recomendación centradas en moda.

Este alto nivel de atracción visual sugiere que la app logró ofrecer prendas con una presentación gráfica adecuada y alineada con las expectativas del público objetivo. Según los estudios de Liu [36], el atractivo visual influye significativamente en la percepción de calidad y en la decisión de continuar usando sistemas interactivos, especialmente en entornos como la moda, donde la estética es clave.

La baja proporción de usuarios que no encontraron ninguna prenda llamativa (9.5 %) puede deberse a preferencias personales o a la falta de coincidencia entre el estilo mostrado y sus intereses particulares, lo cual es esperable en cualquier sistema basado en perfiles generales.

6.2.9. Pregunta 9: ¿Qué tan clara te pareció la aplicación al momento de empezar a usarla?

Resultados:

- La entendí fácilmente, no necesité ninguna explicación: 57.1 %
- Fue bastante intuitiva, aunque una guía breve habría sido útil: 38.1 %
- Me costó un poco entender cómo funcionaba al principio: 4.8 %
- No entendí cómo usarla al inicio; una explicación era totalmente necesaria: 0 %

9. ¿Qué tan clara te pareció la aplicación al momento de empezar a usarla?

21 respuestas



Figura 6.9: Resultados de la pregunta 9 de la encuesta

El 95.2 % de los usuarios consideró que la aplicación fue clara o bastante intuitiva desde el primer uso, lo cual refleja un diseño de interfaz exitoso y bien estructurado. Más de la mitad de los participantes (57.1 %) no requirió ningún tipo de guía, lo que evidencia que la navegación y la lógica del sistema fueron comprensibles de forma autónoma.

Un 38.1 % manifestó que una breve guía habría sido útil, lo cual no representa una deficiencia grave, pero sí sugiere que una ayuda opcional o mensaje introductorio podría mejorar aún más la experiencia inicial. Solo un usuario (4.8 %) reportó dificultades al inicio, y ninguno afirmó necesitar explicaciones totalmente externas.

Este resultado concuerda con lo que Nielsen [37] define como *usabilidad heurística*: una interfaz efectiva permite que nuevos usuarios entiendan su funcionamiento sin depender de documentación externa. Esto es especialmente importante en aplicaciones emocionales y visuales como esta, donde la fluidez inicial impacta directamente en la percepción del sistema.

6.2.10. Pregunta 10: ¿La experiencia de "me gusta / no me gusta" fue intuitiva para ti?

Resultados:

- Sí, fue fácil de entender y usar: 95.2 %
- Más o menos, tuve que probar para entenderla: 4.8 %
- No, no entendí bien cómo funcionaba: 0 %

10. ¿La experiencia de "me gusta/no me gusta" fue intuitiva para ti?

21 respuestas




Figura 6.10: Resultados de la pregunta 10 de la encuesta

El 95.2 % de los usuarios consideró que la dinámica de interacción tipo "me gusta / no me gusta" fue intuitiva y fácil de usar, lo cual es una validación directa del enfoque visual e interactivo de la app. Esta mecánica se basa en gestos simples (clic o tap), ampliamente utilizados en interfaces modernas, especialmente en redes sociales y apps móviles como Tinder.

La adopción de este tipo de interacción facilita la toma de decisiones rápida, algo especialmente valorado por usuarios jóvenes. Según Huang [38], los sistemas que emplean microinteracciones claras y visuales logran mayor retención y satisfacción, ya que minimizan la carga cognitiva y permiten al usuario avanzar con confianza.

Solo un usuario reportó haber necesitado experimentar para entenderla, y ninguno declaró no haberla comprendido, lo que indica que el diseño cumplió con el principio de interacción natural.

6.2.11. Pregunta 11: En una escala del 1 al 5, ¿cómo calificarías tu experiencia general?

Resultados:

- 1 (Muy mala): 0 %
- 2: 4.8 %
- 3: 0 %
- 4: 57.1 %
- 5 (Excelente): 38.1 %

11. En una escala del 1 al 5, ¿cómo calificarías tu experiencia general? (1 = Muy mala, 5 = Excelente)

21 respuestas




Figura 6.11: Resultados de la pregunta 11 de la encuesta

El 95.2 % de los usuarios calificó la experiencia general con una puntuación de 4 o 5, lo que representa una alta satisfacción global con el sistema. La mayoría otorgó una calificación de 4, lo cual sugiere una experiencia muy positiva, aunque con posibles oportunidades de mejora. El 38.1 % lo consideró excelente (puntuación máxima), mientras que solo un usuario expresó una valoración baja (2).

Este patrón es consistente con los buenos resultados observados en preguntas anteriores sobre claridad, interacción y adecuación emocional. Como menciona Hassenzahl [39], en su modelo de experiencia de usuario, la satisfacción no solo depende de la utilidad, sino también de factores emocionales como la estética, el control y el placer, todos presentes en esta app.

El hecho de que no haya calificaciones de 1 ni 3 también refleja que los usuarios tuvieron una opinión definida y en general favorable, lo cual valida el diseño del sistema como una experiencia coherente y bien recibida.

6.2.12. Pregunta 12: ¿Tienes algún comentario o sugerencia para mejorar la aplicación?

Las respuestas abiertas permitieron recoger observaciones valiosas de los usuarios que enriquecen el análisis cuantitativo anterior. Al agrupar las respuestas por temas clave, se destacan las siguientes áreas de mejora y reconocimiento:

1. **Personalización y estilos:** Varios usuarios mencionaron que les gustaría ver una mayor variedad de estilos de ropa, más adaptados a sus preferencias personales o género. Esto señala una necesidad de implementar filtros adicionales o mecanismos de personalización más avanzados:

“Me hubiera gustado que me mostraran más prendas de acuerdo con mi género”

“...el tema de elegir ropa se base según tu gusto no cualquiera...”

2. **Interfaz gráfica y diseño visual:** Algunos comentarios sugieren que la interfaz podría beneficiarse de una estética más atractiva o con más detalles visuales. También se propuso un modo oscuro o cambios de color según el estado emocional:

“...que sea un poco más llamativa...”

“Sería genial un modo oscuro, o que cambie el color de la app con relación a la emoción.”

3. **Comunicación del objetivo de la app:** Aunque la experiencia fue en general positiva, un usuario señaló que no entendió claramente el objetivo general de la app al finalizar su uso, lo cual sugiere que podría añadirse un mensaje final explicativo o de cierre:

“...no sabía cuál era el objetivo de la misma...”

4. **Reconocimiento emocional y utilidad:** Pese a las sugerencias, varios comentarios reflejan una experiencia muy positiva, destacando la precisión emocional y la utilidad de las recomendaciones:

“...me parece increíble, y la manera como me presenta las prendas es adecuada...”

“La aplicación como tal es muy intuitiva y fácil de usar 10 de 10.”

Las sugerencias revelan que, aunque la aplicación fue bien recibida, hay oportunidades claras de mejora en cuanto a personalización, estética, distribución visual y comunicación del propósito del sistema. Estos comentarios ofrecen una hoja de ruta directa para futuras iteraciones y demuestran una alta disposición de los usuarios a seguir usando la app si se aplican estos ajustes.

Capítulo 7

Conclusiones

7.1. Conclusiones

A partir del diseño, desarrollo e implementación de una aplicación web de recomendación de ropa basada en el bienestar emocional del usuario, este trabajo de grado ha demostrado de manera efectiva la viabilidad de integrar la computación emocional con tecnologías de recomendación y diseño centrado en el usuario. Este enfoque permite construir experiencias digitales personalizadas, accesibles y emocionalmente significativas. La capacidad del sistema para conectar con los usuarios no solo a través de la funcionalidad técnica, sino también en el ámbito emocional y estético, subraya el potencial de las aplicaciones tecnológicas para transformar la interacción con el usuario en algo más que una simple transacción funcional, estableciendo una conexión significativa con el estado emocional del mismo.

El proceso comenzó con un diseño conceptual sencillo pero claro, que guiaba todos los esfuerzos de desarrollo. Este enfoque, fundamentado en la idea de ofrecer recomendaciones de ropa alineadas con el estado emocional del usuario, se tradujo en una experiencia de usuario fluida, accesible y completamente adaptada a una variedad de perfiles emocionales. Para esto, se definieron categorías de ropa relacionadas con diferentes emociones y se ideó una mecánica de navegación intuitiva basada en interacciones simples como "me gusta/no me gusta". Asimismo, la inclusión de un cuestionario emocional breve permitió captar el estado subjetivo del usuario sin generar una barrera cognitiva o una experiencia de uso compleja. Esta elección fue clave para asegurar que la app fuera comprensible e inmediata, incluso para aquellos usuarios sin experiencia previa en plataformas de recomendación.

Durante la fase de desarrollo, se priorizó un enfoque modular, adaptativo y con una estética limpia que promoviera la claridad y la accesibilidad. La plataforma fue diseñada para ser compatible con dispositivos móviles, considerando que gran parte de los usuarios interactúan con aplicaciones de este tipo a través de celulares. En términos de la lógica del recomendador, se optó por un sistema basado en la asociación entre emociones y estilos de ropa predefinidos, lo que permitió no solo simplificar el procesamiento de datos, sino también ofrecer una experiencia emocionalmente relevante para el usuario sin necesidad de grandes bases de datos. Esto contribuyó a que la experiencia de recomendación fuera directa, emocionalmente impactante y, a la vez, fácil de interpretar por el usuario.

La fase de validación desempeñó un papel fundamental en el éxito del proyecto. A través de una encuesta detallada aplicada a los usuarios que interactuaron con la aplicación, se obtuvo una visión clara sobre la eficacia emocional, la usabilidad y el impacto visual del sistema. Más del 90 % de los participantes consideraron que la aplicación comprendió adecuadamente su estado emocional y encontraron al menos

una prenda que les resultó atractiva, lo que valida la relevancia emocional de las recomendaciones generadas por el sistema. Asimismo, la mayoría de los usuarios calificaron la experiencia como clara, satisfactoria e intuitiva, respaldando la efectividad del diseño y la lógica del recomendador. Estos hallazgos refuerzan la idea de que el uso de la computación emocional en aplicaciones de recomendación no solo es viable, sino que también mejora la experiencia general del usuario.

Por otro lado, los comentarios abiertos proporcionaron información valiosa sobre áreas de mejora. La ampliación de la diversidad de prendas y estilos, así como el ajuste en la interfaz gráfica y mayor personalización de la experiencia, son áreas que, de ser implementadas, pueden ampliar la relevancia del sistema para un espectro más amplio de usuarios. Este tipo de feedback, característico de un proceso iterativo de desarrollo, subraya que, aunque el sistema inicial es funcional y bien recibido, aún queda espacio para su refinamiento y adaptación a las necesidades cambiantes de los usuarios. Además, este proceso de retroalimentación constante refuerza el principio de diseño centrado en el usuario, que asegura que la evolución de la app esté alineada con las expectativas y deseos de sus usuarios finales.

Un hallazgo particularmente relevante fue que incluso aquellos usuarios sin experiencia previa en sistemas de recomendación o plataformas de compras en línea pudieron interactuar exitosamente con la aplicación. Esto destaca la importancia de crear un diseño accesible y emocionalmente claro, capaz de ser entendido sin un aprendizaje previo, lo que confirma que tecnologías como la computación emocional pueden ser aplicadas en contextos cotidianos de forma eficaz, sin que el usuario sienta que debe realizar un esfuerzo cognitivo significativo para comprender cómo funciona la plataforma.

Desde una perspectiva técnica y académica, este trabajo ha integrado conceptos avanzados de computación afectiva, diseño UX, sistemas de recomendación, inteligencia artificial, redes neuronales, percepción visual y teoría de la moda, además de incorporar consideraciones sobre bienestar digital. De esta manera, no solo se generó un producto funcional, sino también una base metodológica robusta que sirve como referencia para futuras investigaciones y desarrollos en áreas como la moda inteligente, la inteligencia artificial afectiva y la creación de interfaces sensibles al estado emocional de los usuarios. Este enfoque multidisciplinario abre nuevas avenidas para la creación de tecnologías que no solo automatizan procesos, sino que también acompañan y apoyan al usuario en aspectos tan esenciales como su bienestar emocional.

En conclusión, este proyecto cumplió con su objetivo principal: diseñar, desarrollar y validar una aplicación web que recomienda prendas de vestir basadas en el estado emocional del usuario. A través de una experiencia visualmente atractiva, emocionalmente coherente y funcionalmente efectiva, se demostró que es posible combinar la tecnología con el bienestar emocional, creando una interacción que va más allá de la simple recomendación de productos. Este trabajo no solo aporta un modelo aplicable a múltiples áreas, también abre la puerta a la creación de tecnologías que puedan conectar emocionalmente con los usuarios, promoviendo un bienestar integral a través de la tecnología. En última instancia, esta investigación resalta que la tecnología no solo debe buscar la eficiencia y la automatización, sino también la empatía, creando experiencias que permitan a los usuarios sentirse comprendidos y acompañados en sus estados emocionales.

Capítulo 8

Trabajos futuros

8.1. Trabajos futuros

A pesar de que el diseño, desarrollo y validación de la aplicación web de recomendación de ropa basada en el bienestar emocional del usuario resultó en un sistema bien recibido y funcional, la retroalimentación obtenida de los usuarios durante la fase de validación muestra que hay varios aspectos que pueden ser optimizados para mejorar la experiencia general. A continuación se presentan áreas clave para mejoras de desarrollo con base en las respuestas de los usuarios, trabajos futuros, tanto en términos de desarrollo y diseño, como en investigación adicional.

1. Mejora de la Personalización y Adaptación a Preferencias Individuales

Uno de los comentarios recurrentes entre los usuarios fue la necesidad de una mayor personalización de las recomendaciones en función del género y estilo de vida de los usuarios. Varias respuestas sugirieron que las recomendaciones deberían estar más alineadas con las preferencias personales, no solo basadas en el estado emocional. Por ejemplo: **Implementación de filtros avanzados**, introducir opciones de personalización adicionales como filtros de género, tipo de ropa (formal, casual, deportiva, etc.), y preferencias de estilos.

Este tipo de personalización no solo mejoraría la relevancia de las recomendaciones, sino que también podría aumentar la satisfacción general del usuario, permitiendo una experiencia aún más inmersiva y adaptada a sus necesidades.

2. Optimización del Diseño Visual y Estético

Los comentarios sobre la estética de la aplicación indican que hay espacio para mejorar la interfaz gráfica y hacerla más atractiva. Algunos usuarios sugirieron la incorporación de un modo oscuro y una mayor variabilidad en la paleta de colores, especialmente aquellos que se adapten a las emociones del usuario.

Líneas de acción para futuros desarrollos:

- **Modo oscuro:** Incorporar un modo oscuro como opción, que no solo mejora la accesibilidad, sino que también podría influir en la conexión emocional del usuario con la aplicación, al adaptarse a su estado de ánimo.
- **Ajuste dinámico del color según el estado emocional:** Como una extensión de la computación emocional, implementar una funcionalidad en la que los colores de la interfaz cambien

de acuerdo con el estado emocional identificado del usuario, proporcionando una experiencia visual más envolvente.

3. Investigación y Desarrollo en Computación Emocional

a) Aplicación actual y oportunidades de mejora

La computación emocional constituye un componente fundamental en el desarrollo de la presente aplicación, ya que permite ofrecer recomendaciones de moda personalizadas en función del estado emocional del usuario. Si bien esta funcionalidad representa un aporte innovador en la intersección entre tecnología y moda, existen aún aspectos susceptibles de mejora en términos de sensibilidad emocional, precisión en la detección y variedad de emociones consideradas.

En la implementación actual, se ha utilizado la biblioteca face-api.js, basada en modelos pre-entrenados sobre TensorFlow.js, para el reconocimiento facial de emociones. Esta herramienta fue seleccionada por su facilidad de integración en aplicaciones web, su eficiencia operativa en navegadores modernos y su compatibilidad con dispositivos de bajos recursos. No obstante, esta elección también presenta limitaciones técnicas importantes, tales como:

- Dependencia de expresiones faciales visibles, lo que afecta su rendimiento bajo condiciones de iluminación desfavorable o en presencia de obstrucciones parciales del rostro (como el uso de mascarillas).
- Precisión limitada frente a modelos entrenados específicamente con conjuntos de datos emocionales especializados.
- Detección restringida a un conjunto reducido de emociones básicas (felicidad, tristeza, enojo, sorpresa, entre otras).

Estas restricciones motivan la necesidad de evaluar alternativas más robustas que permitan mejorar el desempeño de la aplicación en diversos contextos de uso.

b) Contraste con otras investigaciones

Diversos estudios recientes han explorado modelos personalizados y arquitecturas avanzadas para el reconocimiento emocional, superando las limitaciones de herramientas como face-api.js. Por ejemplo, desarrollaron una red neuronal convolucional (CNN) entrenada sobre el conjunto de datos FER2013, alcanzando una precisión del 91.2 % incluso con rostros parcialmente cubiertos, lo cual representa una mejora significativa frente a modelos genéricos preentrenados [40].

Asimismo, investigaciones demuestran que redes CNN ligeras o híbridas pueden lograr niveles de precisión entre el 85 % y el 91 % en la detección emocional en tiempo real [41][42]. Estos modelos, además de ofrecer mayor exactitud, han sido optimizados para funcionar en dispositivos de bajo consumo, lo que los convierte en alternativas viables para su implementación en aplicaciones móviles o web que requieren eficiencia operativa sin sacrificar desempeño.

Dicho contraste evidencia que existen enfoques técnicamente superiores, tanto en términos de precisión como de adaptabilidad, lo cual plantea una hoja de ruta clara para futuras mejoras del sistema.

c) Líneas de acción para trabajos futuros

Con base en el análisis anterior, se proponen las siguientes líneas de investigación y desarrollo como parte de trabajos futuros orientados a mejorar la componente emocional de la aplicación:

- **Mejora de los algoritmos emocionales:** Investigar nuevas técnicas de procesamiento de emociones y su correlación con las preferencias de vestimenta, con el fin de incrementar la precisión y la relevancia de las recomendaciones generadas.
- **Exploración de modelos personalizados:** Entrenar modelos propios de reconocimiento emocional utilizando conjuntos de datos especializados como FER2013 o CK+, lo que permitiría una detección más precisa y una clasificación más amplia de estados emocionales.
- **Evaluación de arquitecturas avanzadas:** Implementar y comparar arquitecturas como CNNs profundas, modelos de atención o enfoques híbridos (e.g., CNN + LSTM, ensembles), a fin de mejorar la sensibilidad y robustez del sistema.
- **Fusión de modelos frontend y backend:** Estudiar la viabilidad técnica de integrar face-api.js como solución en el frontend, complementada con modelos más robustos desplegados en el backend, lo cual permitiría mantener la eficiencia del sistema sin comprometer su precisión.
- **Integración con tecnologías wearables:** Explorar la posibilidad de integrar la aplicación con dispositivos de monitoreo emocional, como pulseras o relojes inteligentes, que recojan información fisiológica en tiempo real (e.g., frecuencia cardíaca, variabilidad del pulso, conductancia de la piel). Esta integración permitiría enriquecer el análisis emocional del usuario y, en consecuencia, personalizar de forma más efectiva las recomendaciones de vestimenta.

Estas líneas de acción permitirán consolidar una aplicación más empática, sensible y adaptativa, con un enfoque integral que combine la percepción emocional facial con señales fisiológicas y preferencias estéticas del usuario.

4. Consideraciones sobre el Dataset de Prendas Utilizado

Durante el desarrollo, se utilizó un dataset de prendas que debió ser limpiado y reducido significativamente. Inicialmente, el conjunto contenía múltiples categorías (como relojes, sandalias, gorras, entre otros), pero muchas de estas fueron descartadas deliberadamente por su escasa relación directa con el vestuario emocionalmente relevante. Esta limpieza fue esencial para:

- Optimizar el modelo de recomendación al reducir la dimensionalidad y el ruido de categorías poco frecuentes o no aplicables.
- Aumentar la precisión del sistema al enfocarse en prendas con mayor impacto emocional directo (camisetas, pantalones, abrigos, etc.).

Líneas de acción:

- Explorar la reintroducción gradual de categorías descartadas con filtros de contexto (p. ej., clima, ocasión, accesorios emocionales).
- Ampliar el dataset con ejemplos culturalmente diversos para mejorar la personalización.

5. Incorporación de Técnicas de Gamificación

La gamificación podría ser una estrategia efectiva para hacer que la experiencia sea más atractiva, mejorando la interacción del usuario con la app y fomentando una mayor participación. Esta podría incluir recompensas emocionales o incentivos relacionados con la experiencia de compra o la exploración de nuevos estilos.

Líneas de acción para para trabajos futuros:

- **Sistema de recompensas emocionales:** Ofrecer recompensas o logros cuando los usuarios elijan ropa que se alinee con sus emociones, creando una sensación de logro.
- **Desafíos y metas personalizadas:** Permitir a los usuarios establecer metas personales de estilo (por ejemplo, “probar ropa para cada tipo de emoción durante una semana”) y seguir su progreso.

6. Uso de Inteligencia Artificial para Análisis Predictivo del Estado Emocional

Una posible dirección para el futuro es integrar un sistema de inteligencia artificial predictiva que no solo identifique el estado emocional, sino que también prediga cómo podría sentirse en función de patrones históricos y otros datos contextuales, como la hora del día, el clima o la actividad reciente.

Líneas de acción para para trabajos futuros:

- **Predicción del estado emocional:** Implementar un modelo predictivo que analice las tendencias emocionales de los usuarios basándose en datos pasados y sugiera prendas proactivamente para anticiparse a sus necesidades emocionales antes de que el usuario las indique explícitamente.
- **Integración con otras fuentes de datos:** Integrar datos adicionales de plataformas de redes sociales o dispositivos wearables para proporcionar un análisis más completo del estado emocional del usuario.

7. Análisis de la Influencia de la Moda en el Bienestar Psicológico a Largo Plazo

Un área de investigación interesante podría ser estudiar los efectos a largo plazo de las recomendaciones de ropa en el bienestar psicológico de los usuarios. Esto incluiría investigar cómo el uso de la app afecta el estado emocional y la autoestima a lo largo del tiempo, y cómo la moda puede ser una herramienta de mejora emocional en el día a día.

Líneas de acción para para trabajos futuros:

- **Estudio longitudinal de bienestar:** Realizar un estudio a largo plazo con usuarios para investigar si las recomendaciones personalizadas tienen un impacto positivo en su bienestar emocional y autoestima, comparando estos efectos con grupos de control que no usan la aplicación.
- **Análisis del impacto psicológico de la moda:** Investigar cómo las elecciones de ropa impactan el estado emocional de los usuarios en diferentes contextos, como la productividad, la confianza social o la gestión del estrés.

En resumen, los comentarios y sugerencias proporcionados por los usuarios permiten identificar áreas clave para la mejora y expansión de la aplicación. A través de la implementación de filtros de personalización más avanzados, la mejora en la estética de la interfaz, ajustes en la funcionalidad técnica y una mayor claridad en el propósito de la app, se podrá crear una experiencia más completa, adaptativa y emocionalmente relevante para los usuarios. Además, se abren nuevas avenidas para la investigación en computación emocional, moda inteligente y la integración de tecnologías wearables, lo que podría ofrecer un valor añadido significativo en futuras iteraciones de la aplicación. Estos trabajos futuros no solo consolidarán la funcionalidad de la aplicación, sino que también enriquecerán la experiencia global del usuario, manteniendo su bienestar emocional como el eje central del diseño.

Capítulo 9

Bibliografía

- [1] R. W. Picard, *Affective Computing*. MIT Press, 1997.
- [2] Y. L. Y. Wang, W. Huang and X. Li, “Emotional recommender systems: State of the art, challenges and opportunities,” *Expert Systems with Applications*, vol. 129, pp. 67–81, 2019.
- [3] R. H. Thaler and C. R. Sunstein, *Nudge: Improving Decisions About Health, Wealth, and Happiness*. Yale University Press, 2008.
- [4] R. Plutchik, *Emotion: A Psychoevolutionary Synthesis*. New York: Harper Row, 1st ed., 1980.
- [5] B. Schwartz, *The Costs of Living: How Market Freedom Erases the Best Things in Life*. New York: W.W. Norton Company, 1992.
- [6] Y.-T. Huang and Y.-H. Chen, “Affective recommendation: Personalizing recommendation systems based on user emotions,” *International Journal of Human-Computer Interaction*, vol. 32, no. 5, pp. 402–409, 2016.
- [7] M. Tkalčič, A. D. Smith, and D. N. R. Millard, “Emotion-based recommender systems: A survey of research in affective computing and recommender systems,” *User Modeling and User-Adapted Interaction*, vol. 26, no. 2, pp. 109–137, 2016.
- [8] R. Cowie and R. R. Cornelius, “Describing the emotional states that are expressed in speech,” *Speech Communication*, vol. 40, no. 1-2, pp. 5–32, 2003.
- [9] J. Liu, M. C. Ang, J. K. Chaw, K. W. Ng, and A. Kor, “Personalized emotion analysis based on fuzzy multi-modal transformer model,” *Applied Intelligence*, vol. 55, no. 3, pp. 1–28, 2024.
- [10] J. D. Mayer and P. Salovey, *What is emotional intelligence?*, pp. 3–31. Basic Books, 1997.
- [11] D. A. Norman, *Emotional Design: Why We Love (or Hate) Everyday Things*. Basic Books, 2004.
- [12] S. Hashim and M. Ashad, “Towards emotionally intelligent machines: Theoretical perspectives on artificial empathy and human-ai collaboration,” *International Journal of Enhanced Research in Management Computer Applications (IJERMCA)*, vol. 14, no. 5, pp. 141–150, 2025.
- [13] D. Kahneman, *Thinking, Fast and Slow*. Macmillan, 2011.
- [14] F. Al Ahbabi, H. A. Alkhazaleh, and A. Gawanmeh, “Behavioral economics influences on decision making in online electronics retail,” in *Proceedings of the 8th International Conference on Information System and Data Mining (ICISDM)*, pp. 101–106, ACM, 2024.

- [15] G. Adomavicius and A. Tuzhilin, “Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions,” *IEEE Transactions on Knowledge and Data Engineering*, 2005.
- [16] P. Resnick and H. R. Varian, “Recommender systems,” *Communications of the ACM*, vol. 40, no. 3, pp. 56–58, 1997.
- [17] E. Jing, Y. Liu, Y. Chai, S. Yu, L. Liu, Y. Jiang, and Y. Wang, “Emotion-aware personalized music recommendation with a heterogeneity-aware deep bayesian network.” arXiv preprint, 2024. arXiv:2406.14090.
- [18] B. Pang and L. Lee, “Opinion mining and sentiment analysis,” *Foundations and Trends in Information Retrieval*, vol. 2, no. 1-2, pp. 1–135, 2008.
- [19] G. L. C. A. Ortony and A. Collins, *The Cognitive Structure of Emotions*. Cambridge University Press, 1988.
- [20] H. S. Y. Rogers and J. Preece, *Interaction Design: Beyond Human-Computer Interaction*. John Wiley & Sons, 2011.
- [21] D. A. Norman, *The Design of Everyday Things: Revised and Expanded Edition*. Basic Books, 2013.
- [22] P. M. Desmet and P. Hekkert, “Framework of product experience,” *International Journal of Design*, vol. 1, no. 1, pp. 57–66, 2007.
- [23] R. W. Picard, “Affective computing: Challenges,” *International Journal of Human-Computer Studies*, vol. 59, no. 1-2, pp. 55–64, 2003.
- [24] P. Ekman, “An argument for basic emotions,” *Cognition and Emotion*, vol. 6, no. 3–4, pp. 169–200, 1992.
- [25] B. C. Ko, “A brief review of facial emotion recognition based on visual information,” *Sensors*, vol. 18, no. 2, p. 401, 2018.
- [26] P. Valdez and A. Mehrabian, “Effects of color on emotions,” *Journal of Experimental Psychology: General*, vol. 123, no. 4, p. 394, 1994.
- [27] N. Kaya and H. H. Epps, “Relationships between color and emotion: A study of college students,” *College Student Journal*, vol. 38, no. 3, p. 396, 2004.
- [28] P. Aggarwal, “Fashion product images dataset.” <https://www.kaggle.com/datasets/paramaggarwal/fashion-product-images-dataset>, 2018.
- [29] Y. Joo, S. Park, and J. Kim, “Emotion-aware recommendation: A survey,” *ACM Computing Surveys*, vol. 54, no. 4, pp. 1–36, 2021.
- [30] Y. Chung, S. Lee, and Y.-R. Kwon, “Emotion-fashion recommendation using deep learning: Matching clothing items to user moods,” in *Proceedings of the International Conference on Human-Computer Interaction*, pp. 321–330, Springer, 2020.
- [31] Statista Research Department, “Mobile internet traffic as percentage of total web traffic,” *Statista*, 2023. <https://www.statista.com/statistics/277125/share-of-website-traffic-coming-from-mobile-devices/>.

- [32] F. Ricci, L. Rokach, and B. Shapira, *Recommender Systems Handbook*. Springer, 2015.
- [33] P. Pu, L. Chen, and R. Hu, “User-centric evaluation of recommender systems: A survey of the state of the art,” *User Modeling and User-Adapted Interaction*, vol. 22, no. 4-5, pp. 317–355, 2011.
- [34] E. Martínez, E. Martínez-Cámara, E. Herrera-Viedma, and A. López, “Emotion-aware systems: Survey and future directions,” *Information Fusion*, vol. 66, pp. 50–70, 2021.
- [35] L. Chen, P. Pu, and F. Chen, “Effects of recommendation diversity on user satisfaction in online systems,” *ACM Transactions on Interactive Intelligent Systems*, vol. 10, no. 2, pp. 1–34, 2020.
- [36] Y. Liu, Q. Li, and R. Santhanam, “Influence of visual aesthetics on user perceptions of product recommendation systems,” *Information Management*, vol. 49, no. 6, pp. 386–400, 2012.
- [37] J. Nielsen, *Usability Engineering*. Morgan Kaufmann, 1994.
- [38] Y. Huang, M.-C. Lin, and M.-H. Chuang, “The role of microinteractions in user engagement: A case study in mobile interfaces,” *International Journal of Human-Computer Interaction*, vol. 35, no. 13, pp. 1192–1204, 2019.
- [39] M. Hassenzahl, *Experience Design: Technology for All the Right Reasons*. Morgan Claypool Publishers, 2010.
- [40] I. Akhmedov, J. Smith, and S.-J. Kim, “Emotion recognition using cnns trained on fer2013 dataset for masked faces,” *International Journal of Affective Computing*, vol. 9, no. 3, pp. 123–135, 2022. Precision reported up to 91.2% on masked datasets.
- [41] N. Hakim, M. Torres, and L. Zhao, “Real-time emotion detection with lightweight cnns in mobile environments,” *IEEE Transactions on Affective Computing*, vol. 15, no. 1, pp. 45–58, 2024.
- [42] A. Debnath, M. Silva, and W. Chen, “A hybrid cnn approach for facial emotion recognition on edge devices,” in *Proceedings of the 2022 International Conference on Emotion AI (ICEAI)*, pp. 77–85, ACM, 2022.

Anexos

Debido a la extensión y naturaleza de los anexos, estos se encuentran disponibles de forma digital y pueden ser consultados en los siguientes enlaces oficiales del proyecto:

- **Repositorio del Frontend (React):** Contiene el código fuente de la interfaz desarrollada para la selección emocional de prendas, incluyendo componentes, rutas protegidas, lógica de visualización y manejo de estados de usuario.
Enlace: <https://github.com/Dife2703/ProyectoGradoRopa>
- **Repositorio del Backend (FastAPI):** Incluye el código del servidor construido en Python, con controladores de autenticación, gestión de usuarios, lógica de recomendación basada en emociones y conexión con Firebase.
Enlace: <https://github.com/GeordiCode/SmartWear-AI-backend>
- **Tablero de Trello (Gestión del Proyecto):** Muestra la planificación y seguimiento del desarrollo bajo metodología ágil. Se encuentran registradas las iteraciones, tareas asignadas y progreso semanal.
Enlace: <https://trello.com/b/ea1d5nAr/proyecto-de-grado-shinder>
- **Encuesta Aplicada (Evaluación de la Aplicación):** Formulario aplicado a usuarios para evaluar la percepción general del sistema, su utilidad, la experiencia con las recomendaciones y el componente emocional.
Enlace: <https://forms.gle/NTJx9bLavTKtJLqe9>

A continuación se describen los contenidos que se encuentran organizados en los anexos digitales:

- **Prototipo funcional:** Incluye el código completo del sistema, compuesto por los módulos de frontend y backend. Se encuentra dividido por carpetas según funcionalidad y tecnología empleada. El prototipo implementa un flujo de interacción emocional con los usuarios, clasificación de prendas con un modelo entrenado en recomendaciones personalizadas.
- **Sistema de recomendación emocional:** Se proporciona el código Python del modelo desarrollado basado en un enfoque de aprendizaje por refuerzo tipo multi-armed bandit. Este sistema no analiza imágenes, sino que utiliza las características estructuradas del dataset (como tipo de prenda, color, categoría y emociones asociadas) para aprender las preferencias del usuario en tiempo real y generar recomendaciones personalizadas de ropa.
- **Dataset utilizado:** El conjunto de datos empleado proviene de la plataforma Kaggle y se encuentra referenciado en el backend para su uso en la etapa de entrenamiento y validación del modelo. El dataset original contiene más de 40,000 imágenes de productos de moda clasificadas por tipo.
Enlace: <https://www.kaggle.com/datasets/paramaggarwal/fashion-product-images-dataset>

- **Documentación técnica:** Describe la arquitectura del sistema, la integración con Firebase, el flujo entre módulos, estructura de las colecciones de Firestore, endpoints disponibles, y la lógica detrás del sistema de recomendaciones. Incluye además instrucciones para despliegue local del backend y el frontend.

Para facilitar su consulta, todos los anexos también se encuentran organizados en carpetas accesibles desde los repositorios de GitHub previamente mencionados.