



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO®

INSTITUTO TECNOLÓGICO DE CULIACÁN



SISTEMA DE EVALUACIÓN DE LA PERSONALIDAD Y DE LAS EMOCIONES EN EL PROCESO COGNITIVO

TESIS

PRESENTADA ANTE EL DEPARTAMENTO ACADÉMICO DE ESTUDIOS DE POSGRADO
DEL INSTITUTO TECNOLÓGICO DE CULIACÁN EN CUMPLIMIENTO PARCIAL DE LOS
REQUISITOS PARA OBTENER EL GRADO DE

MAESTRO EN CIENCIAS DE LA COMPUTACIÓN

POR:

VÍCTOR MANUEL BÁTIZ BELTRÁN
LICENCIADO EN INFORMÁTICA

DIRECTOR DE TESIS:
DR. RAMÓN ZATARAIN CABADA

CULIACÁN, SINALOA

Agosto 2021



"2021, Año de la Independencia"

Culiacán, Sin., 02 de Agosto del 2021

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
OFICIO: DEPI/257/08/2021

ASUNTO: **Autorización Impresión**

VÍCTOR MANUEL BÁTIZ BELTRÁN
ESTUDIANTE DE LA MAESTRÍA EN CIENCIAS DE LA COMPUTACIÓN
PRESENTE.

Por medio de la presente y en virtud de que ha completado los requisitos para el examen de grado de **Maestro en Ciencias de la Computación**, se concede autorización para la impresión de la tesis titulada: **"SISTEMA DE EVALUACIÓN DE LA PERSONALIDAD Y DE LAS EMOCIONES EN EL PROCESO COGNITIVO"** bajo la dirección del(a) **Dr. Ramón Zatarain Cabada**.

Sin otro particular reciba un cordial saludo.

ATENTAMENTE
Excelencia en Educación Tecnológica®

M.C. MARÍA ARACELY MARTÍNEZ AMAYA
JEFE(A) DE LA DIVISIÓN DE ESTUDIOS DE
POSGRADO E INVESTIGACIÓN

EDUCACIÓN **TECNOLÓGICO NACIONAL DE MÉXICO**
SECRETARÍA DE EDUCACIÓN PÚBLICA

INSTITUTO TECNOLÓGICO DE CULIACÁN

DEPARTAMENTO DE DIVISIÓN DE
ESTUDIOS DE POSGRADO E INVESTIGACIÓN

C.c.p. archivo

MAMA/lucy *



Juan de Dios Bádiz 310 Pte. Col. Guadalupe
C.P. 80050 Culiacán, Sinaloa
Tel. 667-713-3804

tecnm.mx | culiacan.tecnm.mx





**“SISTEMA DE EVALUACIÓN DE LA
PERSONALIDAD Y DE LAS EMOCIONES EN EL
PROCESO COGNITIVO”**

Tesis presentada por el(a):

C. VÍCTOR MANUEL BÁTIZ BELTRÁN

Aprobada en contenido y estilo por:

Dr. Ramón Zatarain Cabada
Director de Tesis

Dra. María Lucía Barrón Estrada
Secretario

Dr. Héctor Rodríguez Rangel
Vocal -1

M.C. Rosalío Zatarain Cabada
Vocal -2

M.C. María Aracely Martínez Amaya
Jefe(a) de la División de Estudios de
Posgrado e Investigación



Dedicatoria

Dedico esta tesis a mi esposa Alma Yolanda Díaz Valdez y a mi hija Alma Irán Bátiz Díaz por ser mi motivación principal para enfrentar nuevos retos y trabajar para conseguirlos. Gracias por su apoyo incondicional.

A mis padres Manuela Beltrán Valenzuela y Candelario Bátiz Valenzuela por darme la vida, educarme, alentarme y apoyarme siempre a perseguir mis sueños.

A mis hermanos Claudia, Alicia y José por estar siempre presentes en cada etapa de mi vida.

Víctor Manuel Bátiz Beltrán

Agradecimientos

Agradezco a CONACYT por proporcionarme apoyo económico para poder realizar mis estudios.

Al Tecnológico Nacional de México Campus Culiacán por permitirme estudiar un posgrado de calidad y proporcionarme las herramientas tecnológicas y el espacio físico para cursar las materias de la maestría y realizar mi trabajo de investigación.

A mi asesor de tesis Dr. Ramón Zatarain Cabada y la Dra. María Lucía Barrón Estrada por sus consejos, recomendaciones y aliento para llevar a buen término este trabajo de tesis. Así mismo, al resto de mis profesores de maestría Dr. Ricardo Quintero, Dr. Víctor González y Dr. Héctor Rodríguez quienes con sus enseñanzas me permitieron crecer como profesionista e investigador.

A la coordinadora de maestría MC Gloria E. Peralta Peñuñuri por su seguimiento puntual y apoyo con todo lo relacionado al proceso administrativo del posgrado y CONACYT.

A Lucy López por su apoyo con la gestión de requisitos y trámites administrativos durante los cuatro semestres de la maestría.

A mis compañeros de maestría Marcos Plata, Saúl Palazuelos, Óscar E. Sandoval, Manuel Medrano, Misael Burruel, Rafael Zavala, Rafael Imperial, Daniel Leyva y Eduardo Huerta con los que compartí dos años de esfuerzo y dedicación y de los que aprendí muchísimo.

A mi compañero de investigación MC Héctor M. Cárdenas López por su apoyo y guía en la realización de mi tesis.

A MC Aldo Uriarte y MC Brandon Cárdenas por su apoyo en el equipo de investigadores a cargo del Dr. Ramón Zatarain. Un gusto compartir y discutir ideas con ellos.

Agradezco de igual forma al INAOE y al Dr. Hugo Jair Escalante Balderas por la oportunidad de realizar mi estancia en modalidad virtual y por su apoyo para poder orientar de mejor forma mi trabajo de investigación.

Declaración de autenticidad

Por la presente declaro que, salvo cuando se haga referencia específica al trabajo de otras personas, el contenido de esta tesis es original y no se ha presentado total o parcialmente para su consideración para cualquier otro título o grado en esta institución o cualquier otra Universidad. Esta tesis es resultado de mi propio trabajo y no incluye nada que sea resultado de algún trabajo realizado en colaboración, salvo que se indique específicamente en el texto.

Víctor Manuel Bátiz Beltrán

Culiacán, Sinaloa, México, 2021

Resumen

En el ámbito del reconocimiento automático de la personalidad aparente, se han realizado diversos estudios que alcanzan diferentes niveles de certeza con base en conjuntos de datos de video y voz previamente etiquetados. Por otra parte, existen pruebas estandarizadas de personalidad que permiten con base en un modelo de factores de la personalidad determinar el nivel de desarrollo de cada factor en una persona. Sin embargo, no existe una plataforma que permita al investigador recolectar nuevos conjuntos de datos de video (incluyendo voz) y así mismo, permita aplicar una prueba de personalidad estandarizada, y almacenar dicha información para posteriormente evaluar la certeza de los reconocedores automáticos aplicados a los conjuntos de datos recolectados.

El presente trabajo describe el desarrollo de una plataforma de recolección de datos (PersonApp) con el objetivo de realizar análisis de la efectividad de reconocedores automáticos de personalidad aparente con respecto a los resultados de una prueba estandarizada de personalidad del mismo participante y de esta forma, contar con elementos que permitan la mejora de los modelos evaluados. Así mismo, se presentan los resultados de la evaluación de un modelo de reconocimiento automático de personalidad aparente, con la finalidad de poner a prueba la plataforma.

Con respecto a la prueba estandarizada, la plataforma recolectó resultados de 32 participantes distintos. Para cada uno de ellos se obtuvieron los valores correspondientes a cada uno de los rasgos de personalidad. Dentro de la muestra analizada se observó que los rasgos de amabilidad y apertura obtuvieron el valor promedio más alto. Por otra parte, neuroticismo fue el rasgo con el valor promedio más bajo. Se realizó un experimento en donde se le solicitó a los participantes grabar un video (incluyendo audio) con una duración de 1 minuto. Se obtuvieron 84 videos correspondientes a 20 participantes. Dichos videos fueron utilizados para poner a prueba un reconocedor automático de personalidad aparente basado en una red neuronal convolucional. Los resultados obtenidos confirmaron la existencia de una brecha importante entre los valores predichos por el reconocedor evaluado al compararse con los valores de la prueba estandarizada.

Palabras clave

Aprendizaje máquina

Aprendizaje profundo

Computación afectiva

Dataset

Emociones

Emociones centradas en el aprendizaje

Modelo de los cinco factores

Modelo de los cinco grandes rasgos

Personalidad

Personalidad aparente

Personalidad real

Plataforma web

Pruebas estandarizadas de personalidad

Reconocimiento automático de personalidad

Índice general

1.	Introducción.....	1
1.1.	Descripción del Problema	1
1.2.	Objetivos	2
1.2.1.	Objetivo General	2
1.2.2.	Objetivos Específicos.....	2
1.3.	Hipótesis.....	3
1.4.	Justificación	3
1.5.	Estructura de la tesis.....	4
2.	Marco teórico.....	5
2.1.	Evaluación de la personalidad	5
2.1.1.	Teorías de la personalidad.....	5
2.1.2.	Modelo de los cinco grandes o <i>Big-Five</i> de la personalidad	6
2.1.3.	Pruebas del IPIP	6
2.1.4.	Reconocimiento automático de personalidad	6
2.2.	Computación afectiva y emociones.....	7
2.2.1.	Teoría de las emociones	7
2.2.2.	Clasificación de las emociones.....	9
2.2.3.	Emociones centradas en el aprendizaje.....	9
2.2.4.	Reconocimiento automático de emociones	10
2.3.	Aprendizaje máquina.....	11
2.3.1.	Aprendizaje máquina tradicional	12
2.3.1.1.	Algoritmos de aprendizaje no supervisado	13
2.3.1.2.	Algoritmos de aprendizaje supervisado	13
2.3.1.3.	Algoritmos de aprendizaje reforzado	14
2.3.2.	Aprendizaje profundo.....	14
2.3.3.	Medidas de rendimiento para problemas de regresión.....	17
3.	Estado del arte	19
3.1.	Reconocimiento de personalidad real (con base en pruebas estandarizadas)	19
3.2.	Reconocimiento de personalidad aparente	20
3.3.	Pruebas estandarizadas de personalidad en línea	24
3.4.	Conjuntos de datos disponibles para el reconocimiento de personalidad aparente..	25
4.	Plataforma para la recolección de datos de personalidad.	27

4.1.	PersonApp: plataforma para la recolección de datos	27
4.2.	Análisis de requisitos	28
4.2.1.	Requisitos funcionales	28
4.2.2.	Requisitos de calidad	28
4.2.3.	Restricciones	29
4.2.4.	Actores	29
4.2.5.	Casos de uso	30
4.3.	Diagrama de contexto	32
4.4.	Arquetipos	33
4.5.	Modelo arquitectónico	34
4.5.1.	Componentes	34
4.5.2.	Vistas de la arquitectura	35
4.5.2.1.	Vista lógica	36
4.5.2.2.	Vista de desarrollo	37
4.5.2.3.	Vista de despliegue	38
4.6.	Implementación	39
4.6.1.	Lenguajes y herramientas de desarrollo	40
4.6.1.1.	React	40
4.6.1.2.	JavaScript	40
4.6.1.3.	HTML	40
4.6.1.4.	CSS	40
4.6.1.5.	Visual Studio Code	40
4.6.2.	Representación y almacenamiento de datos	40
4.6.2.1.	JSON	40
4.6.2.2.	Firebase	41
4.7.	Interfaz gráfica de la plataforma	41
4.8.	Módulo manejador de reconocedores	46
4.9.	Reconocedor evaluado	47
5.	Pruebas, Experimentos y Resultados	51
5.1.	Prueba estandarizada de personalidad	51
5.2.	Evaluación inicial de la plataforma	52
5.3.	Experimento	53
5.4.	Resultados	54
5.4.1.	Resultados de las pruebas del IPIP	54
5.4.2.	Resultados del reconocedor automático evaluado	58

6. Conclusiones y trabajo futuro	62
6.1. Conclusiones del proyecto	62
6.2. Aportaciones y limitaciones	63
6.3. Trabajo futuro	63
Bibliografía	65
Anexos	70
A. Ítems de la prueba IPIP-50	70

Índice de figuras

Figura 2-1. La relación entre inteligencia artificial, aprendizaje máquina y aprendizaje profundo..	12
Figura 2-2. Arquitectura general de alto nivel de una CNN (Patterson & Gibson, 2017)	16
Figura 4-1. Diagrama de casos de uso.....	31
Figura 4-2. Diagrama de contexto de la plataforma PersonApp.	33
Figura 4-3. Diagrama de arquetipos y sus relaciones.....	34
Figura 4-4. Vista lógica de la plataforma.	36
Figura 4-5. Interfaces provistas y requeridas de los componentes de PersonApp.	37
Figura 4-6. Vista de desarrollo de la plataforma.	38
Figura 4-7. Vista de despliegue de la plataforma.	39
Figura 4-8. Interfaces para creación de cuenta e inicio de sesión.	41
Figura 4-9. Ventana de bienvenida.	42
Figura 4-10. Parte superior de la prueba estandarizada.....	43
Figura 4-11. Parte inferior de la prueba estandarizada.....	43
Figura 4-12. Ventana de bienvenida a la grabación de videos.	44
Figura 4-13. Grabación de video para experimento 1-1.....	45
Figura 4-14. Ventana para envío de comentarios y sugerencias.	46
Figura 4-15. Diagrama de operación del manejador de reconocedores.	47
Figura 4-16. Proceso de etiquetado del rostro.	48
Figura 4-17. Topología de red neuronal convolucional discreta.	49
Figura 5-1. Ejemplo de presentación de los ítems del IPIP utilizados.	52
Figura 5-2. Histograma del atributo de Apertura.	55
Figura 5-3. Histograma del atributo de Responsabilidad.	56
Figura 5-4. Histograma del atributo de Extroversión.....	56
Figura 5-5. Histograma del atributo de Amabilidad.....	57
Figura 5-6. Histograma del atributo de Neuroticismo.....	57
Figura 5-7. Histograma de errores absolutos del atributo de Apertura.	59
Figura 5-8. Histograma de errores absolutos del atributo de Responsabilidad.	59
Figura 5-9. Histograma de errores absolutos del atributo de Extroversión.	60
Figura 5-10. Histograma de errores absolutos del atributo de Amabilidad.....	60
Figura 5-11. Histograma de errores absolutos del atributo de Neuroticismo.....	61

Índice de tablas

Tabla 2-1. Taxonomía de las emociones en los estudiantes (Pekrun, 2008).....	10
Tabla 3-1. Trabajos relacionados al reconocimiento automático de personalidad aparente.	23
Tabla 3-2. Comparativa de algunas pruebas de personalidad en línea.....	25
Tabla 3-3. Comparativa de algunos datasets utilizados en reconocimiento de personalidad (Junior et al., 2019).....	26
Tabla 4-1. Requisitos funcionales.	28
Tabla 4-2. Requisitos de calidad.	29
Tabla 4-3. Actores del sistema.	30
Tabla 4-4. Casos de uso.....	30
Tabla 4-5. Descripción de los casos de uso.....	32
Tabla 4-6. Arquetipos de la plataforma PersonApp.....	33
Tabla 4-7. Instrucciones para la grabación de videos.	45
Tabla 4-8. Comparativa entre la técnica utilizada y otros enfoques del estado del arte.....	50
Tabla 5-1. Combinación de ítems positivos y negativos para la elaboración de la prueba estandarizada.	51
Tabla 5-2. Comentarios de usuarios.....	53
Tabla 5-3. Estadística descriptiva de las pruebas del IPIP.	54
Tabla 5-4. Error absoluto medio de cada atributo.	58

Capítulo 1

1. Introducción

En los ambientes de aprendizaje es importante considerar tanto los aspectos cognitivos del estudiante como los aspectos afectivos. Para ello el reconocimiento multimodal admite diversas fuentes de información y ofrece una mejor alternativa para el reconocimiento de emociones (Zatarain Cabada et al., 2019).

En la detección de emociones orientadas al aprendizaje se ha demostrado, en estudios previos, que es posible utilizar técnicas de fusión temprana para el reconocimiento multimodal de emociones (Cárdenas López, 2019).

Estudios recientes demuestran que los avances en visión computacional y el reconocimiento de patrones basado en técnicas de aprendizaje profundo (DL por sus siglas en inglés) han contribuido al establecimiento de modelos de redes neuronales convolucionales (CNN por sus siglas en inglés) que pueden reconocer con éxito señales humanas no verbales y determinar los atributos de sus rasgos de personalidad (Suen et al., 2019).

Este trabajo de investigación tiene como objetivo el diseño y desarrollo de una plataforma para la recolección de datos de video (incluyendo voz) y de pruebas estandarizadas de personalidad real con el fin de evaluar la eficacia de reconocedores automáticos de personalidad aparente.

1.1. Descripción del Problema

En la actualidad, los procesos de enseñanza a través de sistemas digitales raramente consideran los aspectos afectivos de la persona. Es importante que los sistemas tutores inteligentes, puedan detectar la personalidad y las emociones de los estudiantes para adaptarse a las necesidades afectivas del usuario; tratando de enfocar de forma óptima el proceso de enseñanza, con el objetivo de lograr el mayor impacto posible en el individuo durante su proceso cognitivo. Para llevar a cabo la detección de personalidad de forma práctica y rápida, es necesario contar con un reconocedor automático de personalidad

aparente. El principal problema para la construcción de modelos automáticos de reconocimiento de personalidad aparente, es la falta de una plataforma que permita, por una parte, contar con la posibilidad de evaluar la personalidad de un individuo a través de una prueba estandarizada de personalidad real y por otra parte, poder recolectar información en video y audio de dicho individuo; con el fin de generar un conjunto de datos que pueda ser utilizado en el entrenamiento y mejora de modelos de reconocimiento automático de personalidad aparente.

1.2. Objetivos

En este apartado se presentan los objetivos generales y los objetivos específicos definidos para el desarrollo de este trabajo de investigación.

1.2.1. Objetivo General

Esta propuesta tiene como objetivo principal diseñar y desarrollar una plataforma que permita evaluar la eficacia de reconocedores multimodales de personalidad aparente, utilizando grabaciones de video y voz de los individuos participantes en la investigación; contrastando los resultados de estos contra los valores obtenidos en una prueba estandarizada de personalidad real, buscando mejorar la precisión de los modelos evaluados.

1.2.2. Objetivos Específicos

Entre los objetivos específicos de esta investigación se encuentran los siguientes:

- Diseñar y desarrollar un ambiente multiplataforma para la aplicación de una prueba estandarizada de personalidad real.
- Implementar los componentes necesarios, dentro de la plataforma, para grabar y almacenar videos de personas para la realización de experimentos.
- Diseñar y construir una estructura de bases de datos para almacenar información sobre los usuarios, así como los resultados obtenidos en los diversos exámenes de personalidad presentados y las grabaciones de video.
- Evaluar la efectividad de los reconocedores automáticos de personalidad aparente al comparar sus predicciones contra los valores obtenidos por una prueba estandarizada de personalidad real.

1.3. Hipótesis

En este apartado se plantean las hipótesis establecidas para este trabajo de investigación; donde H0 hace referencia a la hipótesis nula, mientras que H1 y H2 hacen referencia a las hipótesis alternativas.

- H0.** La precisión de modelos de reconocimiento automático de personalidad aparente basados en técnicas de fusión temprana, y entrenados con base en un conjunto de videos de una base de datos de referencia, se mantendrá al aplicarse en una nueva base de datos de videos.
- H1.** Los resultados de la detección automática de personalidad aparente usando modelos basados en técnicas de fusión temprana, y entrenados con base a un conjunto de videos de una base de datos de referencia, difieren significativamente de los resultados reportados por una prueba estandarizada de personalidad.
- H2.** Un entorno de recolección de datos, referentes a pruebas estandarizadas de personalidad real y grabaciones de videos de los participantes, facilita el mejoramiento de los modelos de reconocimiento automático de personalidad aparente.

1.4. Justificación

El entrenamiento, validación y prueba de modelos de reconocimiento automático de personalidad aparente depende de tener disponible un conjunto de datos de grabaciones de videos de diversas personas, así como la información sobre características de personalidad real con base en una prueba estandarizada correspondiente a los individuos que participaron en la grabación de los videos. Estos elementos serán generados en este trabajo de investigación. La detección automática de personalidad aparente será de gran utilidad para lograr una mejor detección de emociones y con ello, será posible adecuar los sistemas automatizados de enseñanza para que un usuario obtenga un mayor aprovechamiento y desempeño.

1.5. Estructura de la tesis

Esta tesis se conforma de una serie de capítulos que documentan el proceso de investigación y los resultados obtenidos, tal como se describe a continuación:

En el capítulo 2 se realiza un estudio del marco teórico donde se describe la base teórica de los temas que fundamentan esta investigación. Se abordan temas tales como la evaluación de la personalidad, la computación afectiva y el aprendizaje máquina.

El capítulo 3 presenta un análisis del estado del arte en materia de pruebas estandarizadas de personalidad real, reconocimiento automático de personalidad aparente, plataformas de aplicación de pruebas estandarizadas de personalidad y *datasets* disponibles para la generación de modelos de reconocimiento automático de la personalidad aparente.

En el capítulo 4 se aborda de manera extensa el diseño y desarrollo de PersonApp, la plataforma para la recolección de datos de pruebas estandarizadas de personalidad y de grabaciones de video de los individuos participantes en el experimento realizado en este trabajo de investigación. Se presenta el análisis de requisitos funcionales, el modelo arquitectónico utilizado, la implementación y la interfaz gráfica de la plataforma desarrollada.

El capítulo 5 describe las pruebas, experimento y resultados obtenidos al utilizar la plataforma PersonApp para recolectar información sobre la aplicación de la prueba estandarizada de personalidad del IPIP, la grabación de videos y la evaluación de un modelo de reconocimiento automático de la personalidad aparente.

El capítulo 6 describe las conclusiones del proyecto, las aportaciones, sus limitaciones y el trabajo futuro que se sugiere realizar como continuación de esta investigación.

Finalmente, se presentan las fuentes bibliográficas consultadas y los anexos de la tesis.

Capítulo 2

2. Marco teórico

En esta sección se presenta la fundamentación teórica del trabajo de investigación realizado para darle sustento teórico a este proyecto. Este capítulo comprende tres temas: evaluación de la personalidad, computación afectiva y aprendizaje máquina. Se hace un repaso de las investigaciones y conceptos relacionados con los temas mencionados, para servir de base teórica en el desarrollo de la investigación que se presenta en este documento de tesis.

2.1. Evaluación de la personalidad

En la actualidad, conocer los rasgos de personalidad es importante porque permite entender mejor a los individuos. Así mismo, identificar de manera rápida las características de personalidad tiene muchas aplicaciones prácticas, por ejemplo en el ámbito de estudio de esta investigación se considera que identificar la personalidad de un individuo permitiría adaptar de una mejor forma los procesos de enseñanza electrónica e incluso elegir a la persona adecuada para un puesto laboral dentro de una organización, buscando lograr el mayor impacto posible en el aprendizaje o desempeño del individuo en su proceso cognitivo o desarrollo profesional.

2.1.1. Teorías de la personalidad

Durante mucho tiempo, los psicólogos han estudiado la personalidad humana y a través de los años diversas teorías se han elaborado para explicarla, categorizarla y comprenderla. Yu et al. (2019) señalan que debido a la dificultad que implica inferir la personalidad real de un individuo, muchos investigadores han empezado a prestar atención a un problema menos complejo: el reconocimiento automático de personalidad aparente (AAPR por sus siglas en inglés: *Automatic Apparent Personality Recognition*), que consiste en la personalidad percibida por otras personas (primeras impresiones). Uno de los enfoques más utilizados en la actualidad para la descripción formal, tanto de la personalidad aparente como la real, es el modelo de los Cinco Grandes rasgos (*Big-Five traits*). Laverdière et al. (2020) señalan que su fortaleza recae en que de forma general se acepta que los rasgos de personalidad, aunque

se observen algunos cambios, se mantienen relativamente estables a lo largo de la vida de una persona.

2.1.2. Modelo de los cinco grandes o *Big-Five* de la personalidad

Babcock et al. (2020) establecen que el modelo de los cinco grandes o *Big-Five*, el cual en ocasiones es también llamado modelo de los cinco factores; es un modelo de rasgos de personalidad humana ampliamente aceptado. El modelo *Big-Five* incluye cinco dimensiones o factores utilizados por los psicólogos para describir y etiquetar características de personalidad.

Este modelo es usualmente representado por el acrónimo *OCEAN* donde cada letra se refiere a un término en inglés que representa cada uno de los cinco grandes rasgos de personalidad: Apertura a la experiencia (*Openness to Experience*), Responsabilidad (*Conscientiousness*), Sociabilidad o Extroversión (*Extraversion*), Amabilidad (*Agreeableness*) y Neuroticismo o Estabilidad Emocional (*Neuroticism*) (Junior et al., 2019).

Para el reconocimiento de personalidad real, las etiquetas usualmente se obtienen haciendo que el participante responda, en forma de autoanálisis, un cuestionario conocido como prueba estandarizada de personalidad. En dicho cuestionario, las personas califican su propio comportamiento utilizando una escala de Likert (Yu et al., 2019).

2.1.3. Pruebas del IPIP

Uno de los esfuerzos más relevantes en cuanto a la definición de los reactivos o preguntas (ítems, como se les conoce en el ámbito de la psicología) a utilizar para el modelo de los cinco grandes, es el realizado por el International Personality Item Pool (IPIP), el cual puede considerarse como un laboratorio científico para el desarrollo de medidas avanzadas de rasgos de personalidad y otras diferencias individuales que son del dominio público gracias a su sitio Web (IPIP, 2021). Dicho sitio mantiene un inventario de miles de ítems y cientos de escalas para la medición de los rasgos de personalidad y en general se basan en los estudios realizados por Goldberg (Goldberg, 1992; Goldberg, 1999; Goldberg et al., 2006).

2.1.4. Reconocimiento automático de personalidad

Yu et al. (2019) mencionan que es posible inferir los rasgos de personalidad con base en varios tipos de observaciones, tales como texto, audio, video o cualquier combinación de

estos (multimodal). Cada una de las variantes tiene sus propias aplicaciones dependiendo de la disponibilidad de observaciones en diferentes situaciones.

Los métodos convencionales de reconocimiento automático de personalidad aparente con base en audio suelen utilizar un grupo grande de características potencialmente prosódicas. Por ejemplo, coeficientes cepstrales en las Frecuencias de Mel, tono, energía, y sus derivadas temporales de primer y segundo orden (Yu et al., 2019).

En la modalidad de texto, Stillwell et al. (2017) mencionan que se ha logrado predecir perfiles de personalidad con base en la huella digital que los individuos dejan en redes sociales como sitios Web personales, blogs, mensajes de Twitter, perfiles de Facebook e imágenes de Instagram.

En la modalidad de video e imágenes, sin duda alguna, competencias como ChaLearn han permitido el surgimiento de diversos modelos que buscan predecir la personalidad aparente a partir de un conjunto de videos, de los cuales se pueden extraer imágenes y audio y se cuenta con etiquetas de los rasgos de personalidad. Dichas etiquetas fueron asignadas por trabajadores de Amazon Mechanical Turk (ChaLearn, 2021; Ponce-López et al., 2016).

2.2. Computación afectiva y emociones

En los últimos tiempos hay un creciente interés por lograr que las computadoras puedan interactuar de una forma más parecida a los seres humanos y esto ha abierto toda una línea de investigación dentro de las ciencias computacionales.

Picard (2000) establece el concepto de computación afectiva para explicar este creciente interés. La computación afectiva se entiende como la búsqueda de que las computadoras tengan la capacidad de reconocer, expresar y tener emociones como un ser humano.

2.2.1. Teoría de las emociones

Picard (2000) señala que los teóricos de las emociones no terminan de ponerse de acuerdo en una definición de emoción y hace mención que se han registrado y categorizado alrededor de cien definiciones del término emoción.

La Real Academia de la Lengua Española (RAE) define emoción como la “alteración del ánimo intensa y pasajera, agradable o penosa, que va acompañada de cierta conmoción somática” (RAE, 2021).

Merriam-Webster (2021) define emoción como “una reacción mental consciente (como ira o miedo) experimentada subjetivamente como un sentimiento fuerte generalmente dirigido hacia un objeto específico y típicamente acompañado de cambios fisiológicos y de comportamiento en el cuerpo”.

Por otra parte, la Asociación Americana de Psicología (American Psychological Association) presenta una definición más compleja del término emoción:

“patrón de reacción complejo, que involucra elementos experienciales, conductuales y fisiológicos, mediante el cual un individuo intenta lidiar con un asunto o evento personalmente significativo. La calidad específica de la emoción (por ejemplo: miedo o vergüenza) está determinada por el significado específico del evento. Por ejemplo, si la importancia implica una amenaza, es probable que se genere miedo; si el significado implica la desaprobación de otro, es probable que se genere vergüenza. La emoción generalmente involucra sentimientos, pero difiere de los sentimientos en tener un compromiso abierto o implícito con el mundo.” (APA, 2021).

Las diversas teorías de las emociones pueden examinarse ampliamente en términos de dos componentes:

- 1) Las emociones son cognitivas, enfatizando su componente mental.
- 2) Las emociones son físicas, enfatizando su componente corporal.

Las investigaciones sobre el componente cognitivo se enfocan en entender las situaciones que dan origen a las emociones. Picard (2000) menciona que históricamente el enfoque en los aspectos centrados en el cerebro de las emociones es atribuido a Walter Cannon, quien enfatiza que la emoción es experimentada centralmente en el cerebro y que su experiencia es posible sin sensaciones provenientes del cuerpo (Cannon, 1927). La investigación del lado

del componente físico enfatiza la respuesta fisiológica que ocurre a la par de una emoción o inmediatamente después (Picard, 2000).

Picard et al. (2001) hacen el cuestionamiento sobre ¿qué tan bien debe una computadora reconocer los estados emocionales humanos para parecer inteligente? Es comprensible pensar que entender el componente cognitivo desde la perspectiva de una computadora, significaría lograr comprender los pensamientos más profundos de un ser humano. Esto es complejo, incluso para el mismo ser humano. Inclusive en algunas ocasiones las personas no logran reconocer sus propias emociones. Sin duda, algunos aspectos de los sentimientos internos permanecen privados, sobre todo si la persona desea que así sea. Los autores señalan que lo que un reconocedor externo tiene a su disposición, es lo que puede observar y razonar. Esto siempre estará acompañado de cierta incertidumbre. Aun así, las personas son capaces de reconocer las emociones lo suficientemente bien como para comunicar una retroalimentación útil. Por lo tanto, los autores concluyen que el objetivo es dotar a las computadoras de habilidades de reconocimiento similares a las que las personas tienen.

2.2.2. Clasificación de las emociones

Damasio (1994) establece que las emociones pueden dividirse en primarias y secundarias. Las emociones primarias corresponden a reacciones fisiológicas y de comportamiento automático ante la presencia de estímulos que el cerebro detecta de forma innata, sin que exista un aprendizaje previo, es decir, son disparadas ante la presencia de ciertos aspectos como el tamaño, el movimiento o sonido de un objeto. El autor considera que, si bien estas emociones son las primarias desde la perspectiva de desarrollo, no son las únicas y define otro grupo de emociones como secundarias. Las emociones secundarias, se forman en los individuos una vez que estos empiezan a experimentar sentimientos y a formar conexiones sistemáticas entre categorías de objetos y situaciones, por una parte, y por otro lado las emociones primarias (Restrepo, 2019).

2.2.3. Emociones centradas en el aprendizaje

Con base en la clasificación de las emociones presentada por Damasio (1994), se puede ubicar a las emociones centradas en el aprendizaje como emociones secundarias, ya que estas emociones se presentarán al momento que los estudiantes estén realizando diversas actividades de aprendizaje. Las emociones en el ámbito educativo implican darle un

significado a los eventos o sucesos que experimenta un educando, esto nos permite comprender y aceptar que la cognición y la emoción se afectan recíprocamente. Por ello, el educando debe ser visto como una mezcla de razón y emoción, ya que separar ambos componentes sería atentar contra el carácter humano de la persona (García Retana, 2012).

En cuanto a las categorías de emociones relacionadas con el aprendizaje y el logro que deberían considerarse, Pekrun (2008) señala que: 1) las emociones pueden ser ordenadas generalmente con base a su valor predominante, experimentado subjetivamente (positivo versus negativo); 2) las emociones se pueden clasificar como relacionadas a la tarea o a una naturaleza más social; 3) las emociones relacionadas con la tarea pueden diferir de acuerdo con la perspectiva de tiempo relacionada con la tarea y el resultado que implican, ya sean relacionadas con el proceso (durante la tarea), prospectivas (antes de la tarea, antes del resultado) o retrospectivas (después de la tarea, después del resultado). En la Tabla 2-1 se muestra la taxonomía de emociones en los estudiantes que propone el autor.

Tabla 2-1. Taxonomía de las emociones en los estudiantes (Pekrun, 2008).

	Positiva	Negativa
Relacionadas con la tarea		
<i>Relacionada con el proceso</i>	Disfrute	Aburrimiento
<i>Prospectiva</i>	Esperanza Alegría anticipatoria	Ansiedad Desesperanza (Resignación/Desesperación)
<i>Retrospectiva</i>	Alivio Alegría relacionada al resultado Orgullo	— Tristeza Decepción Vergüenza/Culpa
Social		
	Gratitud Empatía Admiración Simpatía/Amor	Enojo/Ira Celos/Envidia Desprecio Antipatía/Odio

2.2.4. Reconocimiento automático de emociones

El reconocimiento automático de emociones puede efectuarse a través de diversas modalidades y el término modalidad implica el tipo de expresión. La psicología de la percepción sugiere que el sistema cognitivo utiliza modalidades sensoriales y de signos para

transmitir algún significado. Las modalidades sensoriales pueden incluir cualquier forma de sentido visual, auditivo, táctil, entre otros. Una lista de tipos de signos incluiría por ejemplo la escritura. Tecnológicamente hablando la modalidad se refiere a cierto tipo de información y el formato de representación en el cual ésta es almacenada. Las modalidades utilizadas para el reconocimiento de emociones se pueden agrupar en tres categorías:

- Fisiológicas (expresiones faciales y gestos o movimientos corporales).
- Comportamiento (voz y texto).
- Imágenes de señales cerebrales.

En años recientes ha existido un creciente interés en el área de reconocimiento de emociones utilizando expresiones faciales. El reconocimiento de expresiones faciales tiene amplias aplicaciones en campos como el desarrollo de interfaces máquina amigables para el humano, estudios clínicos, tratamiento psicológico, video conferencia, entre otros (Abhang et al., 2016; Zatarain Cabada et al., 2020).

2.3. Aprendizaje máquina

Definir a la inteligencia artificial es un tema complejo, pero Ertel (2017) presenta una definición que explica de manera elegante lo que ha sido y es la inteligencia artificial, al citar la definición de Elaine Rich, la cual menciona que es el estudio de cómo lograr que las computadoras hagan cosas en las cuales, actualmente, las personas son mejores. En esta búsqueda y gracias a los avances tecnológicos, el aprendizaje máquina ha tenido un resurgimiento muy intenso en los últimos años. Lo anterior aunado al deseo de lograr que las computadoras pueden aprender sin ser programadas para realizar tareas específicas, ha generado una amplia gama de investigaciones relacionadas.

Swamynathan (2017) señala que el aprendizaje máquina es un subcampo de las ciencias computacionales que evolucionó del estudio del reconocimiento de patrones y la teoría del aprendizaje computacional en la inteligencia artificial. El mismo autor señala que en 1959, Arthur Samuel definió el aprendizaje máquina como un “campo de estudio que proporciona a las computadoras la habilidad de aprender sin ser explícitamente programadas”.

Otra definición que ofrece Swamynathan (2017) establece que el aprendizaje máquina implica el uso de métodos estadísticos para crear programas que mejoran su rendimiento con el tiempo o detectan patrones en cantidades masivas de datos que es poco probable que los humanos encuentren. En los últimos tiempos, se ha despertado un gran interés en una rama del aprendizaje máquina conocida como aprendizaje profundo. La Figura 2-1 muestra la relación entre la inteligencia artificial, el aprendizaje máquina y el aprendizaje profundo.

En general, el aprendizaje máquina involucra mecanismos adaptativos que permiten a las computadoras aprender de la experiencia, aprender con base en ejemplos y aprender por analogía. Las capacidades de aprendizaje pueden mejorar el desempeño de un sistema inteligente con el paso del tiempo (Negnevitsky, 2011).

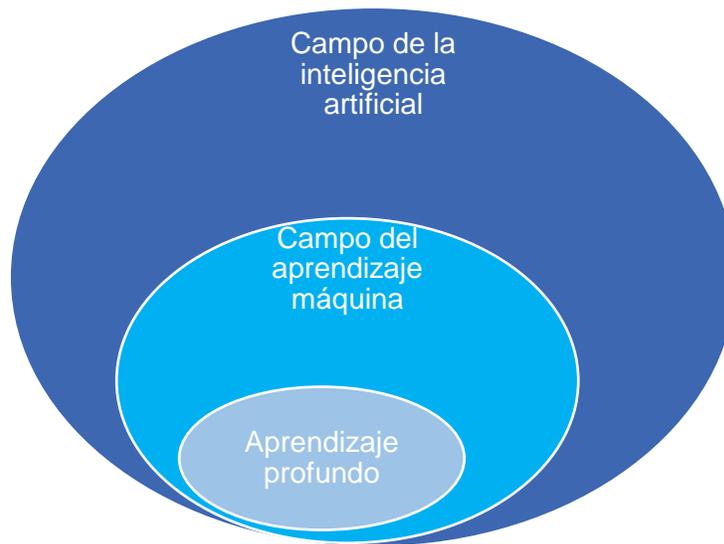


Figura 2-1. La relación entre inteligencia artificial, aprendizaje máquina y aprendizaje profundo.

2.3.1. Aprendizaje máquina tradicional

El aprendizaje máquina permite resolver tareas que se consideran complicadas para los programas tradicionales diseñados por el humano. Goodfellow et al. (2016) establecen que los algoritmos de aprendizaje máquina pueden ser categorizados en supervisados y no supervisados con base a la clase de experiencia que se les permite tener durante el proceso de aprendizaje.

En los últimos tiempos también se ha trabajado fuertemente en una tercera categoría: el aprendizaje reforzado (Aggarwal, 2018).

2.3.1.1. Algoritmos de aprendizaje no supervisado

Este tipo de algoritmos son entrenados con conjuntos de datos (*datasets*) que contienen muchas características, a partir de las cuales aprenden propiedades útiles de la estructura del *dataset*. El objetivo es lograr comprender el *dataset* e identificar patrones similares que puedan ser agrupados en clases o eventos específicos. A continuación, se describen algunos ejemplos de aprendizaje no supervisado:

- Agrupamiento (*clustering*). Supone que las clases no se conocen de antemano para un conjunto de datos determinado. El objetivo aquí es dividir el conjunto de datos de entrada en grupos lógicos de elementos relacionados. Algunos ejemplos son la agrupación de artículos de noticias similares o la agrupación de clientes similares en función de su perfil.
- Reducción de dimensión (*dimension reduction*). Aquí el objetivo es simplificar un gran *dataset* de entrada asignándolo a un espacio de menor dimensión. El enfoque es encontrar las variables clave que contienen un porcentaje significativo de información y solo usar éstas para el análisis (Swamynathan, 2017).

2.3.1.2. Algoritmos de aprendizaje supervisado

Son algoritmos entrenados con un *dataset* que contiene características, pero cada ejemplo se encuentra asociado a una etiqueta. El objetivo es aprender patrones en los datos y construir un conjunto general de reglas para relacionar la entrada a la clase o evento correspondiente. Existen dos tipos comunes de algoritmos de aprendizaje supervisado:

- Regresión. La salida para predecir es un valor numérico asociado al conjunto de datos de entrada. Por ejemplo, predecir la capacidad de pago de una persona con base en información de entrada como sueldo, edad, estado civil y número de hijos.
- Clasificación. Consiste en que el algoritmo sea capaz de aprender a relacionar los datos que recibe como entrada con una categoría o clase correspondiente. El número de clases pueden ser dos o más. Un ejemplo puede ser un algoritmo para clasificar un correo electrónico como correo basura o no (Goodfellow et al., 2016; Swamynathan, 2017).

2.3.1.3. Algoritmos de aprendizaje reforzado

Aggarwal (2018) señala que, en las formas generales de inteligencia artificial, la red neuronal debe aprender a tomar acciones en situaciones dinámicas y cambiantes. Los ejemplos incluyen robots de aprendizaje y automóviles autónomos. En estos casos, una suposición crítica es que el sistema de aprendizaje no tiene conocimiento de la secuencia apropiada de acciones por adelantado, y aprende a través del refuerzo basado en recompensas a medida que realiza varias acciones. Estos tipos de aprendizaje corresponden a secuencias dinámicas de acciones que son difíciles de modelar utilizando métodos tradicionales de aprendizaje automático. El supuesto clave aquí es que estos sistemas son demasiado complejos para modelarlos explícitamente, pero son lo suficientemente simples para evaluar, de modo que se puede asignar un valor de recompensa por cada acción del sistema de aprendizaje.

2.3.2. Aprendizaje profundo

Patterson & Gibson (2017) señalan que definir aprendizaje profundo ha sido un reto para muchos debido a su evolución en la década pasada. Una definición útil sería especificar que el aprendizaje profundo trata con una “red neuronal con más de dos capas”. El problema de esta definición es que hace que el aprendizaje profundo suene como si hubiera existido desde la década de 1980. La realidad es que las redes neuronales tenían que trascender arquitectónicamente de los estilos de red anteriores (junto con un incremento en la potencia de procesamiento) antes de mostrar los resultados espectaculares observados en años más recientes. A continuación, se presentan algunas de las facetas de esta evolución de las redes neuronales:

- Más neuronas que las redes previas.
- Formas más complejas de conectar capas y neuronas en las redes neuronales.
- Un incremento sustancial en el poder computacional disponible para entrenamiento.
- Extracción automática de características.

Patterson & Gibson (2017) señalan que es precisamente la extracción automática de características, la principal diferencia del aprendizaje profundo con respecto al aprendizaje máquina tradicional. De esta forma se elimina la necesidad de que una persona determine manualmente las características relevantes, ya que en el aprendizaje profundo la red neuronal

será capaz de decidir por sí misma que características del *dataset* se pueden utilizar como indicadores para etiquetar los datos de forma confiable.

Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN por sus siglas en inglés: *Convolutional Neural Networks*) tienen el objetivo de aprender características de orden superior utilizando convoluciones. Se consideran muy adecuadas para el reconocimiento de objetos con imágenes y consistentemente estos modelos se ubican entre los mejores en los concursos de clasificación de imágenes. Pueden identificar rostros, individuos, letreros de calles y muchos otros aspectos de los datos visuales. Las CNN se superponen con el análisis de texto a través del reconocimiento óptico de caracteres, pero también son útiles cuando se analizan palabras como unidades textuales discretas. También son buenas analizando el sonido (Patterson & Gibson, 2017).

Las CNN transforman los datos de entrada que reviven en la capa de entrada a través de todas las capas conectadas en un conjunto de puntuaciones de clase dadas por la capa de salida. Hay muchas variaciones de la arquitectura de CNN, pero todas ellas se basan en el patrón de capas, como se muestra en la Figura 2-2 donde se puede apreciar la arquitectura de alto nivel de una CNN (Patterson & Gibson, 2017).

La Figura 2-2 muestra tres grupos principales:

1. Capa de entrada (*Input layer*).
2. Capas de extracción de características (*Feature-extraction layers*).
3. Capas de clasificación (*Classification layers*).

La capa de entrada acepta entradas tridimensionales generalmente en la forma espacial del tamaño (ancho x alto) de la imagen y tiene una profundidad que representa los canales de color (generalmente tres para los canales de color RGB).

Las capas de extracción de características tienen generalmente un patrón repetitivo con la secuencia:

1. Capa convolucional (*Convolutional layer*), generalmente se suele indicar una capa adicional que representa a la función de activación. En las CNN es común utilizar ReLU (*Rectified Linear Unit*).
2. Capa de agrupamiento (*Pooling layer*).

Estas capas encuentran un número de características en las imágenes y progresivamente construyen características de orden superior. Esto se corresponde directamente con la fortaleza del aprendizaje profundo en el que las características se aprenden automáticamente en lugar del método de ingeniería manual del aprendizaje máquina tradicional.

Finalmente, están las capas de clasificación en las que existen una o más capas completamente conectadas para tomar las características de orden superior y producir probabilidades de clase o puntajes. Estas capas están completamente conectadas a todas las neuronas de la capa anterior, como su nombre lo indica. La salida de estas capas produce normalmente una salida bidimensional de las dimensiones $[\mathbf{b} \times \mathbf{N}]$, donde \mathbf{b} es el número de ejemplos en el mini-lote y \mathbf{N} es el número de clases que son de interés para puntuar.

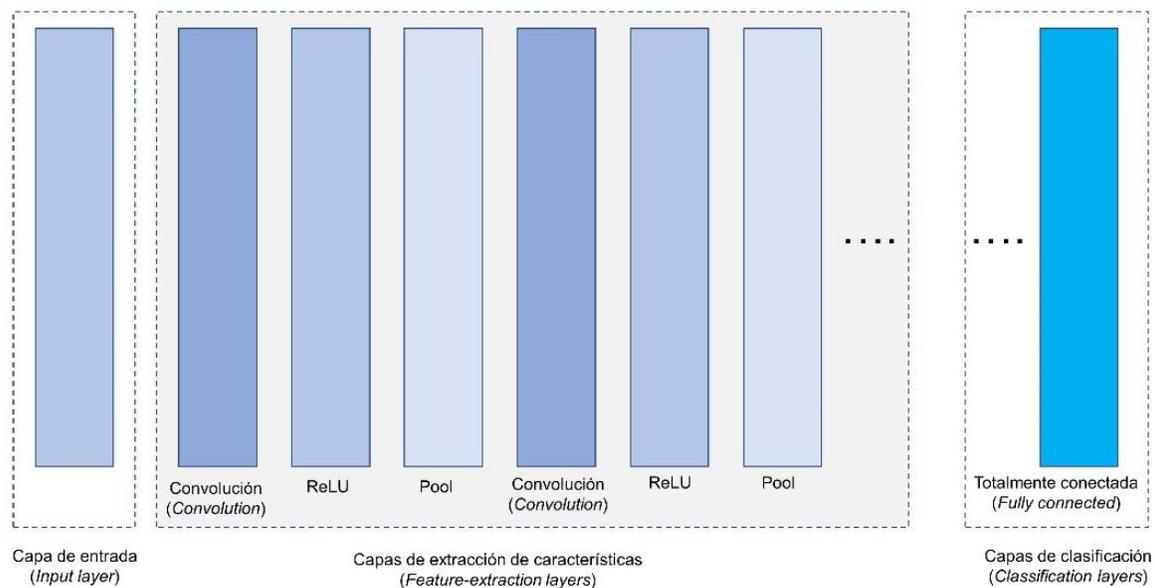


Figura 2-2. Arquitectura general de alto nivel de una CNN (Patterson & Gibson, 2017)

2.3.3. Medidas de rendimiento para problemas de regresión

La evaluación del rendimiento de un modelo automático de reconocimiento de personalidad aparente es uno de los objetivos de este trabajo de investigación. Por ello, es importante contar con mecanismos que permitan determinar de forma estadística, el desempeño logrado por el modelo evaluado al predecir valores de los rasgos de personalidad en videos de los participantes. El punto de comparación serán los valores reales de los rasgos de personalidad determinados por la prueba estandarizada del IPIP realizada por cada participante.

Géron (2019) define que una medida de rendimiento común en problemas de regresión es la Raíz del Error Cuadrático Medio (RMSE por sus siglas en inglés: *Root Mean Square Error*). Este indicador ofrece una idea de que tanto error comete típicamente el sistema en sus predicciones, dando un mayor peso a los errores más grandes. La fórmula para su cálculo se presenta en la Fórmula 2-1.

$$RMSE = \sqrt{\left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - x_i)^2} \quad (2-1)$$

Donde:

- n es el número de instancias a evaluar del conjunto de datos.
- y_i es la salida deseada o el valor real.
- x_i es el valor arrojado por la predicción del modelo.

Otra medida de rendimiento conocida es el Error Cuadrático Medio (MSE por sus siglas en inglés: *Mean Squared Error*). La fórmula utilizada para su cálculo se muestra en la Fórmula 2-2.

$$MSE = \left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - x_i)^2 \quad (2-2)$$

Como puede observarse, su cálculo es similar al del RMSE, eliminado la raíz cuadrada de la fórmula. Lo anterior provoca que ambas medidas compartan la característica de darle mucho peso a las diferencias grandes. Debido a esto, en muchos contextos es preferible usar una tercera medida de rendimiento conocida como Error Absoluto Medio (MAE por sus siglas en inglés: *Mean Absolute Error*). La fórmula para su cálculo se presenta en la Fórmula 2-3.

$$MAE = \left(\frac{1}{n}\right) \sum_{i=1}^n |y_i - x_i| \quad (2-3)$$

La principal ventaja de utilizar MAE es que es una puntuación lineal, por lo que todas las diferencias individuales se ponderan de la misma forma en el promedio.

Capítulo 3

3. Estado del arte

En esta sección se describen y analizan algunos trabajos de investigación relacionados con el área de pruebas estandarizadas y reconocimiento automático de la personalidad. Estos trabajos, aunque son esfuerzos separados, guardan similitud con elementos del presente trabajo de investigación y fueron considerados como base para el desarrollo e integración de este proyecto.

3.1. Reconocimiento de personalidad real (con base en pruebas estandarizadas)

Se ha demostrado que uno de los mejores enfoques para la detección de la personalidad es el modelo de los cinco grandes (*Big-Five*) o modelo de los cinco factores (FFM por sus siglas en inglés: *Five Factors Model*) de la personalidad. Como se mencionó previamente, Laverdière et al. (2020) hacen notar que su fortaleza recae en que de forma general se acepta que los rasgos de personalidad se mantienen estables a lo largo de la vida de una persona.

En los últimos años se han realizado múltiples trabajos de investigación que presentan adaptaciones a diversos idiomas de los ítems proporcionados por el IPIP, con la finalidad de evaluar su aplicabilidad en diversas culturas, encontrándose resultados positivos. Estos trabajos de investigación se describen a continuación. El estudio realizado por Gross y Cupani (2016) para la adaptación y contextualización de 100 ítems del IPIP en el medio argentino, obtuvo resultados satisfactorios en sus estudios de confiabilidad. La muestra analizada, seleccionó accidental o aleatoriamente a 910 argentinos entre los 15 y 80 años, de los cuales 543 fueron de sexo femenino y 367 de sexo masculino. El instrumento utilizado fue el cuestionario IPIP basado en los 100 ítems presentados por Goldberg (1999). En este cuestionario cada rasgo de personalidad se evalúa por 20 ítems redactados en forma de frases que describen comportamientos típicos de las personas. Los individuos participantes deben seleccionar la respuesta que mejor describa su comportamiento con una escala de Likert de cinco opciones. La traducción de los 100 ítems fue realizada por tres expertos de la lengua inglesa y posteriormente los autores del trabajo elaboraron una versión consensuada que fue

revisada con un grupo de estudiantes para establecer que ítems presentaban dificultades para su comprensión. En todos los casos, la presentación del cuestionario se realizó de manera grupal en salas preparadas para ello. En cuanto a los resultados, se concluyó que se puede considerar la aplicación del cuestionario como opción aceptable para medir en la población argentina los cinco grandes factores de la personalidad (Gross & Cupani, 2016).

Por otra parte, está la adaptación realizada por Laverdière et al. (2020) para la aplicación de una versión reducida del cuestionario IPIP en participantes de habla francesa. Dicha versión, llamada Mini-IPIP constaba de 20 ítems en total, en donde cada uno de los cinco rasgos de la personalidad del modelo *Big-Five* se evaluó con 4 ítems, obteniendo como resultado la confirmación de la pertinencia transcultural de los indicadores de personalidad del modelo de los cinco grandes en participantes con antecedentes idiomáticos y culturales diversos. En uno de los estudios realizados en la investigación, los participantes fueron estudiantes de psicología de una universidad francesa canadiense. Un total de 139 estudiantes de entre 19 y 59 años completaron la prueba Mini-IPIP. Para la adaptación se formó un comité de cuatro traductores bilingües. Se realizó la traducción al francés y de nuevo al inglés para comparar las versiones, no encontrándose diferencias significativas. Se obtuvieron dos conclusiones principales. Primero, los ítems adaptados resultaron similares en forma, significado y contenido a los ítems originales. Lo anterior muestra la pertinencia transcultural de los indicadores de los cinco grandes rasgos de personalidad en diferentes lenguajes o antecedentes culturales. Segundo, las propiedades sicométricas observadas en la versión adaptada fueron adecuadas y altamente similares a las de la versión original para las cinco dimensiones de la prueba Mini-IPIP.

3.2. Reconocimiento de personalidad aparente

En el ámbito del reconocimiento automático, en los últimos años se han propuesto diversos enfoques para el reconocimiento de la personalidad aparente. Algunos estudios han trabajado en el reconocimiento automático con base en información textual, como por ejemplo la información generada por los usuarios en redes sociales como Facebook, Twitter y Youtube (Farnadi et al., 2016). Entre los enfoques evaluados en el estudio mencionado, se encuentran

enfoques de regresión multivariada y enfoques univariados como árboles de decisión y máquinas de vectores de soporte (SVM por sus siglas en inglés: *Support Vector Machines*).

Pizzolli & Strapparava (2019) presentan un trabajo de investigación donde se busca predecir los rasgos de personalidad de los personajes de textos literarios. El modelo sugerido utiliza herramientas de procesamiento de lenguaje natural como NLTK y TextPro. Para el entrenamiento del modelo, se utilizó un *dataset* llamado *essays* que contiene aproximadamente 2400 textos de diferentes autores y cuenta con etiquetas relacionadas con los rasgos de personalidad del modelo *Big-Five*. En cuanto a los resultados, los autores señalan que obtuvieron un desempeño al nivel del estado del arte, pero también indican que para ciertos rasgos de personalidad obtuvieron valores muy similares entre los personajes literarios lo cual les parece extraño y lo atribuyen a las características y limitaciones del *dataset*.

Otros estudios han trabajado en el reconocimiento de la personalidad aparente con base en la voz de los participantes. Yu et al. (2019) realizaron un estudio en el que proponen un sistema basado en una red neuronal convolucional que evalúa una señal de voz, y regresa seis valores para los cinco rasgos de personalidad y una variable de entrevista (que indica si un candidato pudiera ser invitado a una entrevista de trabajo). La investigación señala que el modelo propuesto puede aprender a capturar los estilos de habla de un extremo a otro, y los resultados experimentales mostraron que la idea de la captura de estilos también funciona en el dominio del audio. Concluyen que la correlación entre las diferentes dimensiones de una señal de voz puede ayudar a inferir los rasgos de personalidad y la variable de la entrevista.

En su trabajo de investigación Ventura et al. (2017), presentan un modelo de reconocimiento de personalidad aparente basado en redes neuronales convolucionales utilizando imágenes extraídas de cortos de videos. Concluyen que la información facial juega un papel clave en la predicción de los rasgos de personalidad.

El-Batal & Darwish (2020) exploran en su artículo de investigación el reconocimiento automático de personalidad aparente, utilizando extracción de características faciales de fotografías de perfiles de usuarios de la red social Twitter (500 fotografías fueron analizadas). El estudio hace uso de la API Face++, la cual está basada en métodos de aprendizaje profundo

y permite extraer las emociones detectadas en el rostro, las cuales se utilizan para inferir los rasgos de personalidad.

En la investigación realizada por Butt et al. (2020), se presenta un estudio de los rasgos de personalidad usando señales fisiológicas generadas por los individuos durante la actividad de hablar en público. El estudio utiliza una fusión de señales fisiológicas como electroencefalografía (EEG), respuesta galvánica de la piel (GSR por sus siglas en inglés: *Galvanic Skin Response*) y fotopletismograma (PPG del inglés: *photoplethysmogram*). Las señales fueron capturadas mediante el uso de sensores portátiles utilizados por los individuos, mientras hablaban frente a una audiencia durante 5 minutos. El modelo hace la fusión de las características seleccionadas de cada tipo de señal evaluada y finalmente utiliza k vecinos más cercanos (k -NN por sus siglas en inglés: *k-Nearest Neighbors*) para la clasificación de los rasgos de personalidad. Los autores concluyen que las señales fisiológicas registradas por medio de sensores portátiles son útiles para el reconocimiento de los rasgos de personalidad.

Junior et al. (2019) ofrecen una revisión de diversos estudios sobre metodologías de tendencias recientes en el análisis de rasgos de personalidad aparente entre las que se encuentran modelos que utilizan diversas técnicas de regresión, redes neuronales convolucionales y LSTM (*Long Short-Term Memory*), así como técnicas de fusión temprana y tardía de señales visuales y de audio. Así mismo, se analizan trabajos que utilizan datos multimodales para la detección automática de personalidad aparente, usando además de señales audiovisuales contenido verbal obtenido de transcripciones manuales del audio en videos.

El renovado interés por el mundo de la inteligencia artificial y el aprendizaje automático, así como la existencia de competencias como las realizadas por *ChaLearn Looking at People* han ayudado al crecimiento de diversos modelos de redes neuronales para la detección de personalidad aparente con base en primeras impresiones. Los modelos utilizados por los participantes de la competencia incluyen el uso de las modalidades de audio y video. La mayoría de los equipos utilizó características espectrales para el audio; excepto un equipo que uso una red residual. Para la modalidad de video, el enfoque predominante fue el uso de redes neuronales convolucionales. Algunos participantes utilizaron fusión temprana, pero la

mayoría optó por fusión tardía de las modalidades, antes de alimentarlas a diferentes métodos de regresión (Ponce-López et al., 2016; Junior et al., 2019; ChaLearn, 2021).

En la Tabla 3-1 se presenta un resumen de los trabajos de investigación mencionados en este apartado.

Tabla 3-1. Trabajos relacionados al reconocimiento automático de personalidad aparente.

Autor(es)	Descripción	Modalidad					Técnica												
		Texto	Imágenes	Audio	Video	Señales fisiológicas	Regresión multivariada	SVM (Support Vector Machines)	árboles de decisión	Aprendizaje máquina supervisado	herramientas NLTK y TextPro	CNN	Aprendizaje profundo y API Face++	Fusión de señales fisiológicas (EEG, GSR y PPG)	k-NN	LSTM	Técnicas de regresión	ResNet	Técnicas de fusión temprana y tardía
Farnadi et al. (2016).	Revisión de diversos enfoques de reconocimiento automático de personalidad aparente con base a información textual generada por los usuarios en redes sociales como Facebook, Twitter y Youtube.	X					X	X	X										
Pizzolli & Strapparava (2019).	Reconocimiento automático de personalidad aparente de personajes en textos literarios.	X								X	X								
Yu et al. (2019).	Reconocimiento automático de personalidad aparente con base a señales de voz de los participantes.			X								X							
Ventura et al. (2017).	Reconocimiento automático de personalidad aparente utilizando expresiones faciales obtenidas de imágenes extraídas de videos de los participantes.				X							X							
El-Batal & Darwish (2020).	Reconocimiento automático de personalidad aparente por medio de la extracción de características faciales obtenidas de fotografías de perfiles de usuarios de Twitter.		X									X							
Butt et al. (2020).	Reconocimiento de los rasgos de personalidad a través de la fusión de diversas señales fisiológicas producidas por los individuos durante la actividad de hablar en público.					X							X	X					
Junior et al. (2019).	Revisión de diversas metodologías de tendencias en el análisis de los rasgos de personalidad.	X	X	X	X		X									X			X
Ponce-López et al. (2016), Junior et al. (2019) y ChaLearn (2021).	Análisis de los diversos modelos utilizados por los participantes del concurso ChaLearn enfocado al reconocimiento de rasgos de personalidad con base en primeras impresiones.			X	X							X			X	X	X	X	X

3.3. Pruebas estandarizadas de personalidad en línea

Existen diversos sitios en Internet que permiten realizar una prueba estandarizada de personalidad e incluso algunos ofrecen una interpretación de los resultados. A continuación, se presenta una descripción de algunos de estos sitios y la prueba estandarizada que implementan.

En 16Personalities (2021) se ofrece de forma gratuita una prueba de personalidad, la cual arroja una clasificación para el participante que lo ubica en uno de los 16 tipos de personalidad que la prueba determina. El cuestionario utiliza un modelo llamado NERIS que combina la teoría de rasgos y el indicador de tipos Myers-Briggs (Myers & Myers, 1995), generando entonces un modelo que trabaja con cinco escalas relacionadas con el modelo *Big-Five*. Al momento de elaboración de la presente investigación el sitio mencionaba que más de 426 millones de personas habían realizado la prueba, la cual está disponible en 37 idiomas.

En IPIP (2021) se puede acceder a una prueba de personalidad basada en IPIP-NEO, que originalmente contiene 300 ítems en su inventario para la prueba. Se hace mención que el tiempo promedio necesario para responder la prueba es de 30 a 40 minutos. La prueba arroja valores para los cinco dominios de modelo de cinco factores de la personalidad. Más de medio millón de personas han presentado la prueba desde que está disponible en Internet. En el mismo sitio se puede acceder a una versión reducida que hace uso de 120 ítems del inventario original. Esta prueba toma entre 10 y 20 minutos. Para validar su fiabilidad se utilizaron las respuestas de más de 20,000 personas. Se hace mención que la prueba original ofrece resultados más confiables, aunque la versión reducida cumple con los estándares profesionales de confiabilidad.

En BigfiveTest (2021) se puede realizar una prueba de personalidad basada en IPIP-NEO 120, por lo que el participante debe responder 120 preguntas. Se estima que la duración de la prueba ronda los 10 minutos. Al momento de redactar el presente trabajo más de 700,000 personas habían realizado la prueba, la cual está disponible en 26 lenguajes diferentes. La prueba arroja resultados en los cinco factores reconocidos por el modelo de los cinco grandes o *Big-Five*. Esta plataforma ofrece incluso la posibilidad de descargar el código fuente de la aplicación para usarse de manera local y administrar pruebas de personalidad con base en los ítems del IPIP.

Finalmente, en Openpsychometrics (2021) se pueden encontrar múltiples pruebas de personalidad, pero la que el mismo sitio recomienda es la prueba llamada *Big Five Personality Test*, que se basa en los ítems del IPIP-50. La prueba toma entre 3 y 8 minutos para completarse. Esta prueba fue seleccionada para su implementación en el presente trabajo de investigación.

En la Tabla 3-2 se puede observar un resumen de las pruebas en línea mencionadas, así como la dirección de Internet en la cual se encuentran disponibles.

Tabla 3-2. Comparativa de algunas pruebas de personalidad en línea.

Nombre	Modelo usado	Idioma	Participantes	Sitio Web
16Personalities.	NERIS basado en MBTI y <i>Big-Five</i> .	Disponible en 37 idiomas.	> 426,000,000.	https://www.16personalities.com/
IPIP NEO 300.	IPIP-NEO 300 basado en NEO PI-R® (<i>Big-Five</i>).	Inglés.	> 500,000.	http://www.personal.psu.edu/~j5j/IPIP/ipipneo300.htm
IPIP NEO 120.	IPIP-NEO 120 basado en NEO PI-R® (<i>Big-Five</i>).	Inglés.	No se menciona el dato, pero se establece que las respuestas de más de 20,000 personas se utilizaron para validar la fiabilidad.	http://www.personal.psu.edu/~j5j/IPIP/ipipneo120.htm
BigfiveTest.	IPIP-NEO 120 basado en NEO PI-R® (<i>Big-Five</i>).	26 idiomas.	> 700,000.	https://bigfive-test.com/
Openpsychometrics.	IPIP-50.	Inglés.	Dato no disponible.	https://openpsychometrics.org/tests/IPIP-BFFM/

3.4. Conjuntos de datos disponibles para el reconocimiento de personalidad aparente

Junior et al. (2019) analizaron los diferentes conjuntos de datos que se encuentran disponibles y que han sido utilizados en diversos estudios para el desarrollo de modelos de reconocimiento automático de personalidad aparente. La mayoría de ellos cuentan con etiquetas relacionadas con los rasgos de personalidad del modelo *Big-Five* y en general

consisten de videos de diversa duración, tamaño y calidad. Algunas grabaciones fueron realizadas en ambientes controlados y otras en ambientes no controlados. El más extenso y quizás el más relevante de estos *datasets* es el que proporciona el concurso ChaLearn ya que cuenta con 10,000 cortos de videos con una duración aproximada de 15 segundos cada uno. Adicionalmente, cada video tiene asociada la información de los rasgos de personalidad aparente reportada por colaboradores de Amazon Mechanical Turk (ChaLearn, 2021). En la Tabla 3-3 se puede apreciar el concentrado de *datasets* descritos por Junior et al. (2019).

Tabla 3-3. Comparativa de algunos datasets utilizados en reconocimiento de personalidad (Junior et al., 2019).

Dataset	Descripción	Enfoque	Etiquetas
MHHRI, Multimodal (Celiktutan et al., 2017).	12 sesiones de interacción (~ 4 h) capturadas con cámaras egocéntricas, profundidad y biosensores, 18 participantes, ambiente controlado.	Personalidad e involucramiento durante interacciones humano-humano (HHI) e interacciones humano-computadora (HCI).	Evaluación de autoconocimiento / autoconocimiento Big-Five e involucramiento.
ChaLearn First Impression v2, Multimodal (Escalante et al., 2017).	Versión extendida de ChaLearn, con la inclusión de impresiones de contratación y transcripciones de audio.	Rasgo de personalidad aparente e impresiones de contratación.	Impresiones de Big-Five, variable de entrevista de trabajo y transcripciones.
ChaLearn First Impression, Audiovisual (Ponce-Lopez et al., 2016).	10K videos cortos: ~ 15 segundos cada uno, recopilados de 2762 usuarios de YouTube, 1280x720 de tamaño, RGB, 30 fps, entorno no controlado.	Análisis de rasgos de personalidad aparente (sin interacción: una sola persona hablando frente a una cámara).	Impresiones de Big-Five.
SEMAINE, Multimodal (McKeown et al., 2012).	959 conversaciones: ~ 5 minutos cada una, 150 participantes, 780x580 de tamaño, 49.979 fps, RGB y gris, vista frontal y de perfil, ambiente controlado.	Conversaciones cara a cara (interactivas) con agentes de escucha artificiales sensibles.	Metadatos, transcripciones, 5 dimensiones afectivas y 27 categorías asociadas.
Emergent LEADER (ELEA), Audiovisual (Sanchez-Cortes et al., 2012).	40 reuniones: ~ 15 minutos cada una, 27 con audio y video, compuestas por 3 o 4 miembros, 148 participantes; 6 cámaras estáticas (25 fps) y 2 portátiles (30 fps), entorno controlado.	Interacciones de grupos pequeños y liderazgo emergente (tarea de supervivencia invernal).	Metadatos, Big-Five (autoinforme) e impresiones sociales.
YouTube vlog, Audiovisual (Biel & Gatica-Perez, 2013; (Biel & Gatica-Perez, 2010).	442 vlogs: ~ 1 min cada uno, 1 video por participante, entorno no controlado.	Vlogs conversacionales y análisis de rasgos de personalidad aparente.	Metadatos e impresiones de Big-Five.

Capítulo 4

4. Plataforma para la recolección de datos de personalidad.

La recolección de datos presenta un fuerte reto ya que debemos establecer un medio para almacenar y consultar la información. En la actualidad, debido al avance de la tecnología, es posible desarrollar ambientes que hagan uso de Internet. Con ello, ha sido posible llegar a más personas, sin importar su ubicación ni el dispositivo que utilicen para conectarse a Internet. Por lo anterior, se optó por desarrollar una plataforma en la nube, que funcionara en cualquier dispositivo y que permitiera almacenar la información en un repositorio localizado en Internet para facilitar el estudio de los datos.

En este capítulo se describe como fue desarrollada la plataforma PersonApp producto de este trabajo de investigación.

4.1. PersonApp: plataforma para la recolección de datos

PersonApp surge con la intención de contar con una plataforma que permitiera cubrir dos aspectos necesarios para la evaluación de modelos de reconocimiento automático de personalidad aparente. Primero, el poder recolectar información de pruebas estandarizadas de personalidad real para tomar los resultados como el valor real de los factores de personalidad y con ello, poder verificar la exactitud de los valores generados por los reconocedores. Segundo, permitir la recolección de videos (incluido el audio) de los individuos participantes en los experimentos y utilizarlos como entrada para los reconocedores a evaluar.

Para el desarrollo de la aplicación, se utilizó una metodología iterativa e incremental, permitiendo de esta manera generar versiones evaluables de la plataforma, desde las primeras iteraciones y mejorarla de forma constante, con base en las recomendaciones sugeridas por los usuarios elegidos para la evaluación de la plataforma.

Esta metodología fue aplicable en el presente trabajo de investigación ya que se tenía una idea clara de lo que se deseaba diseñar, desarrollar e implementar (Jalote, 2008).

4.2. Análisis de requisitos

A continuación, se describe el análisis de requisitos funcionales y de calidad que fueron considerados para el desarrollo de la plataforma PersonApp.

4.2.1. Requisitos funcionales

La intención de los requisitos funcionales es la de proporcionar de forma clara, la lista de funciones que debe cumplir el producto software que se desea desarrollar. En la Tabla 4-1 se describen los requisitos funcionales establecidos para la plataforma PersonApp.

Tabla 4-1. Requisitos funcionales.

Requisito	Descripción
RF-01	El sistema deberá permitir el registro de los usuarios y su autenticación a través de un nombre de usuario (correo electrónico) y contraseña.
RF-02	El sistema deberá permitir a los usuarios presentar una prueba estandarizada de personalidad.
RF-03	El sistema deberá permitir a los usuarios la grabación de video en tres situaciones diversas como lo son: hablar de un tema libremente, imaginarse estar en una entrevista, y hablar hacia una audiencia de plataforma en línea como Facebook o Youtube.
RF-04	El sistema deberá permitir a los usuarios dar recomendaciones sobre la plataforma.
RF-05	El sistema deberá captar y almacenar la fecha de registro de los usuarios, presentación de la prueba estandarizada y grabación de videos.

4.2.2. Requisitos de calidad

Es un hecho que las características no funcionales de los sistemas de software, como lo son: usabilidad, rendimiento o desempeño y seguridad se han vuelto de suma importancia, sobre todo en la cuestión de protección de la información de los usuarios. En la Tabla 4-2 , se describen los requisitos de calidad contemplados para la plataforma PersonApp con base en el modelo SQuaRE (Oktaba, 2010).

Tabla 4-2. Requisitos de calidad.

Vista	Característica	Descripción del requisito
Calidad de uso	Satisfacción	La plataforma deberá ofrecer un flujo de operación agradable para el usuario.
	Usabilidad	El sistema debe mostrar las opciones en una interfaz estética y fácil de navegar.
El sistema debe ser amigable y fácil de usar.		
El sistema deberá explicar lo que el usuario debe hacer en todas sus interfaces de forma clara y sencilla.		
Calidad del producto	Seguridad	El sistema debe garantizar la privacidad de la información de los usuarios y debe apegarse a las reglas de confidencialidad del país.
		La información y los videos únicamente pueden publicarse bajo autorización de los usuarios.
		Todos los accesos al sistema deberán autenticarse.
Portabilidad		El usuario podrá acceder a la plataforma a través de un equipo de escritorio, portátil o dispositivo móvil.
		El sistema debe poder utilizarse en cualquier navegador Web.

4.2.3. Restricciones

Para el funcionamiento correcto de la plataforma y lograr así cumplir con los requisitos funcionales y de calidad, es necesario que el usuario cumpla los siguientes requerimientos.

- Se deberá contar con una conexión a Internet estable para poder acceder a la plataforma y realizar las actividades especificadas en la misma.
- El dispositivo utilizado para la conexión a la plataforma deberá contar con cámara y micrófono, ya sean estos integrados o externos.
- El usuario debe autorizar permisos para el uso de la cámara y el micrófono.

4.2.4. Actores

La Tabla 4-3 describe los actores del sistema determinados a partir del análisis de requisitos.

Tabla 4-3. Actores del sistema.

Actores	Descripción y objetivos
Participante	Es todo individuo que se registra en la plataforma con la finalidad de participar en la recolección de datos, mediante la resolución de una prueba estandarizada y la grabación de videos.
Investigador	Es la persona que se encarga de analizar los datos recolectados y generar los resultados de aplicar el reconocedor automático de la personalidad a los videos grabados por los participantes.
Servidor de Autenticación	Servidor que expone servicio para autenticar a los usuarios del sistema.
Sistema de reconocedores automáticos de personalidad	Servidor que expone los servicios de aplicación de los reconocedores a evaluar utilizando los videos recolectados y regresando al sistema los valores obtenidos para cada usuario, modelo y video.

4.2.5. Casos de uso

Con base en la lista de requisitos funcionales, se definieron los casos de uso. En la Tabla 4-4 se presenta un resumen de su descripción.

Tabla 4-4. Casos de uso.

Caso de uso	Nombre
CU-001	Registrar usuario en el sistema.
CU-002	Iniciar sesión en el sistema.
CU-003	Presentar prueba estandarizada.
CU-004	Grabar video.
CU-005	Registrar comentarios y sugerencias.
CU-006	Predecir factores de personalidad con reconocedor automático.
CU-007	Registrar actividad del sistema.

En la Figura 4-1, se ilustra el diagrama de casos de uso de los escenarios principales de la plataforma PersonApp.

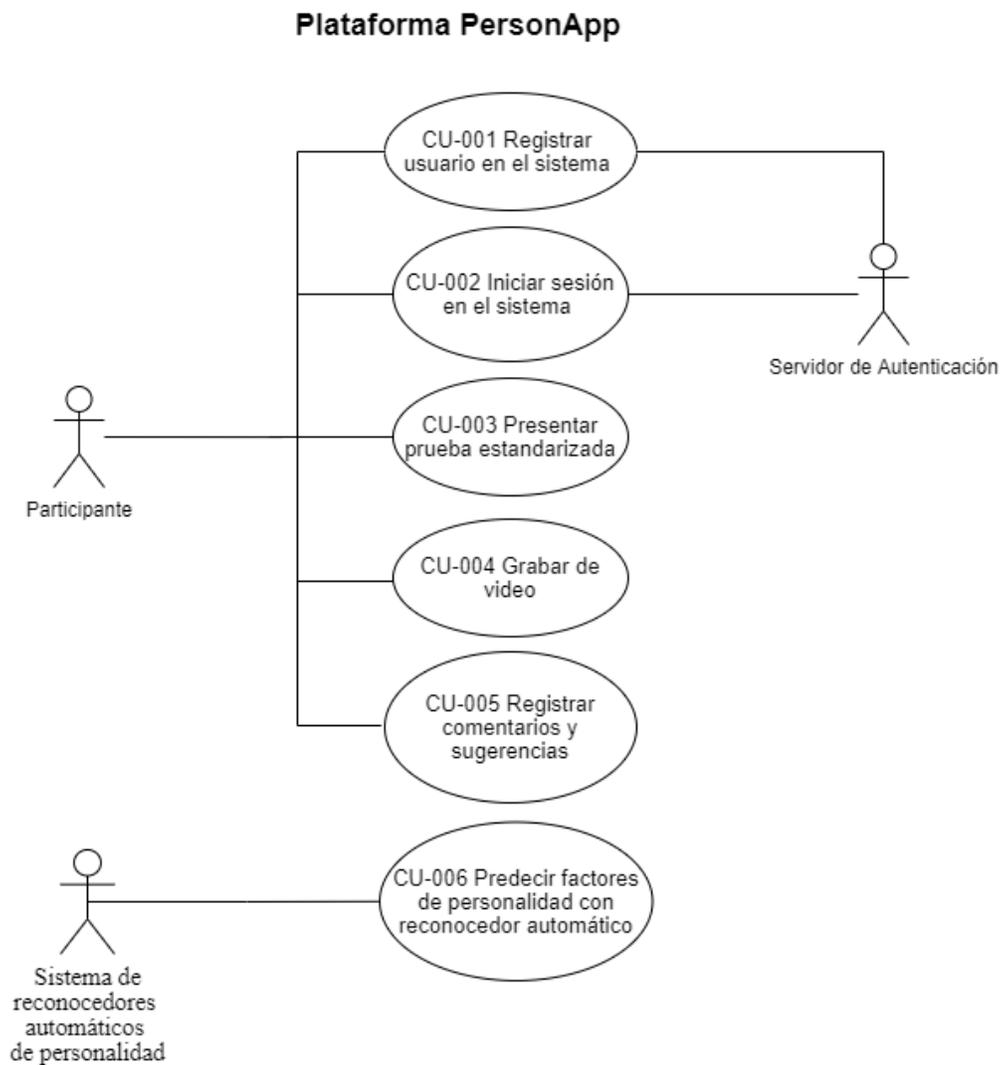


Figura 4-1. Diagrama de casos de uso.

Finalmente, en la Tabla 4-5 se muestra una descripción más detallada de cada caso de uso de la plataforma PersonApp.

Tabla 4-5. Descripción de los casos de uso.

Caso de uso	Nombre	Descripción
CU-001	Registrar usuario en el sistema.	Un participante puede registrarse en el sistema.
CU-002	Iniciar sesión en el sistema.	Un participante puede iniciar sesión en el sistema.
CU-003	Presentar prueba estandarizada.	Un participante ya autenticado en la aplicación puede presentar la prueba estandarizada.
CU-004	Grabación de video.	Un participante puede grabar un video de el mismo realizando alguna de las tres actividades solicitadas en el sistema.
CU-005	Registro de comentarios y sugerencias.	Un participante puede registrar sus comentarios y sugerencias sobre la plataforma con la finalidad de ofrecer retroalimentación para el mejoramiento de ésta.
CU-006	Predicción de factores de la personalidad por reconocedor automático.	El sistema de reconocedores automáticos de personalidad controlado por el investigador puede ejecutar el proceso de predicción de los factores de la personalidad por parte de los reconocedores automáticos, completando así el ciclo de generación de datos para el análisis de resultados.
CU-007	Registro de actividad del sistema.	El sistema registra los datos referentes a la fecha, hora y usuario en cada una de las actividades principales.

4.3. Diagrama de contexto

El diagrama de contexto, ver Figura 4-2, muestra la interacción de la plataforma PersonApp con los actores identificados, tanto usuarios como servidores y sistemas externos. En la parte superior del sistema se encuentran los usuarios; al centro, al mismo nivel del sistema se encuentran algunos servicios que no son estrictamente necesarios y en la parte inferior, están los servidores indispensables para la ejecución de todos los procesos de PersonApp.

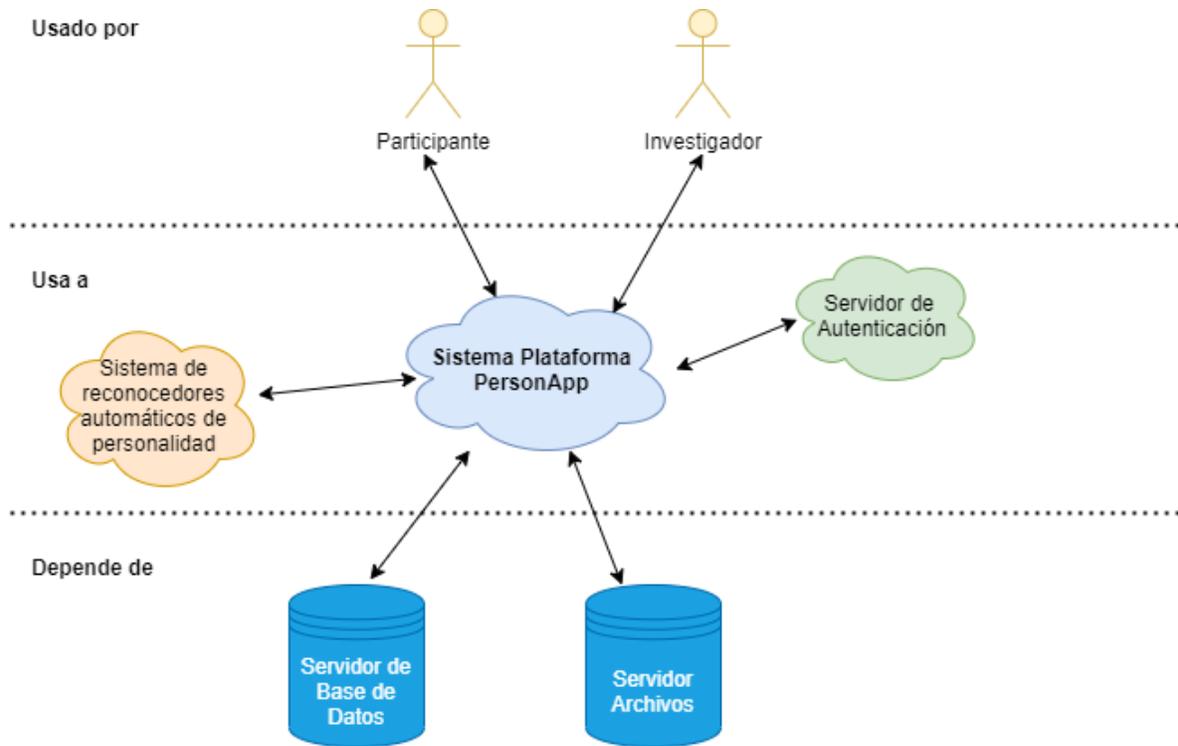


Figura 4-2. Diagrama de contexto de la plataforma PersonApp.

4.4. Arquetipos

Los arquetipos identificados para la plataforma PersonApp se listan y describen en la Tabla 4-6. Estos arquetipos están presentes en las diversas instancias de la plataforma desarrollada.

Tabla 4-6. Arquetipos de la plataforma PersonApp.

Arquetipo	Descripción
Prueba estandarizada	Representación de la prueba estandarizada.
Video	Representa la grabación de un video (incluido el audio) por parte del participante.
Investigador	Representación lógica en el sistema de la persona responsable de conducir los experimentos.
Participante	Representación lógica en el sistema del individuo que participa en los experimentos quien puede realizar la prueba estandarizada, grabar videos y enviar comentarios para mejora de la plataforma.
Comentario	Representación lógica de un comentario o sugerencia proporcionado por un participante.

En la Figura 4-3, se muestra la relación entre los arquetipos. Se indica que un participante presenta una prueba estandarizada, realiza grabación de videos y puede enviar comentarios de mejora. Así mismo, un investigador procesa los videos y pruebas estandarizadas y revisa los comentarios de mejora para determinar si son viables para implementación.

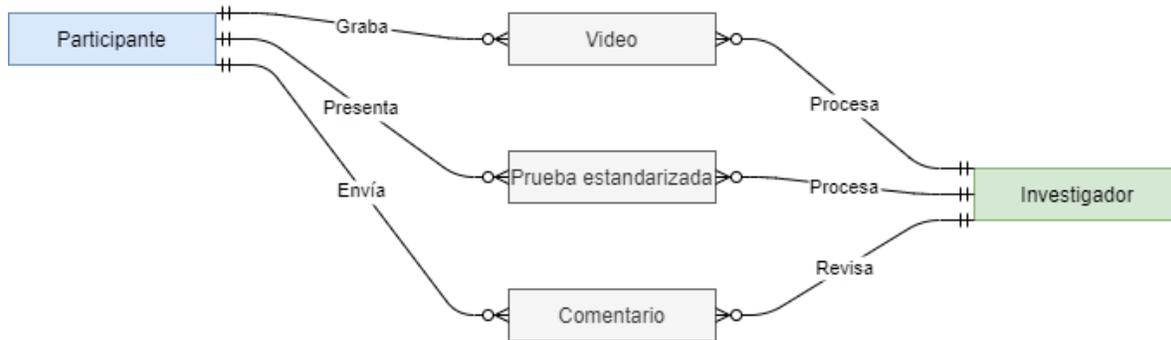


Figura 4-3. Diagrama de arquetipos y sus relaciones.

4.5. Modelo arquitectónico

Para el desarrollo de la plataforma PersonApp se optó por utilizar un modelo arquitectónico de capas sobre una arquitectura cliente/servidor. Se definen 3 capas: presentación, lógica de la aplicación y datos. Además, se requiere establecer conexión con los sistemas de reconocedores automáticos de personalidad y el servidor de autenticación.

4.5.1. Componentes

Los diversos componentes de la plataforma realizan tareas específicas para proporcionar en conjunto la funcionalidad del sistema PersonApp. Estos componentes se han definido con base en los requisitos funcionales, requisitos de calidad, arquetipos identificados, diagrama de contexto, conocimiento del dominio del problema y del dominio de la computación.

Se definen los siguientes componentes:

I. Capa de presentación

- a. Aplicación Web. Muestra al usuario la interfaz gráfica con las opciones para llevar a cabo las actividades del sistema. Se localiza del lado del cliente.

II. Capa de lógica de la aplicación

- a. Control de accesos. Este componente incluye la funcionalidad necesaria para que un usuario se registre o inicie sesión en caso de estar ya registrado. Esto nos permite asegurar la identidad única de cada usuario y ligar todas sus actividades a su cuenta.
- b. Prueba estandarizada. Componente encargado de presentar al usuario la prueba estandarizada de personalidad que debe contestar. Permite obtener los resultados para cada uno de los cinco factores de personalidad evaluados, así como el tiempo utilizado para responder la prueba.
- c. Video. Este componente proporciona la funcionalidad requerida para la grabación de videos por parte del participante.
- d. Comentario. Componente que proporciona la funcionalidad necesaria para que un participante pueda enviar sus comentarios de mejora.
- e. Manejador de reconocedores. Este componente proporciona toda la funcionalidad indispensable para procesar los videos de los participantes utilizando un reconocedor automático de personalidad específico y permitir guardar los resultados obtenidos en la base de datos, relacionando estos con el usuario correspondiente.

III. Capa de datos

- a. Base de datos. Componente que tiene la funcionalidad para almacenar información de los usuarios, los resultados de las pruebas estandarizadas, los comentarios de mejora y los resultados de las predicciones hechas por los reconocedores automáticos de personalidad evaluados.
- b. Almacenamiento de archivos. Componente encargado de almacenar los archivos de video incluyendo el audio de tal forma que estén relacionados al usuario correspondiente.

4.5.2. Vistas de la arquitectura

A continuación, se revisan las distintas vistas de la arquitectura del sistema.

4.5.2.1. Vista lógica

En la Figura 4-4 se ilustra la vista lógica de la plataforma PersonApp con base en el modelo arquitectónico de capas. Se puede apreciar que la arquitectura tiene una distribución en tres capas, las cuales se describen a continuación.

1. **Capa de presentación.** Su función es mostrar una interfaz gráfica al usuario a través de un navegador Web en un dispositivo de escritorio, portátil o móvil. Funciona del lado del cliente. Esta capa se comunica de manera bidireccional con la capa de lógica de la aplicación para llevar a cabo las actividades típicas del sistema.
2. **Capa lógica de la aplicación.** Esta capa se ejecuta del lado del servidor y se comunica con la capa de presentación y con la capa de datos. Contiene los algoritmos necesarios para proporcionar la funcionalidad ofrecida por el sistema.
3. **Capa de datos.** Capa que contiene los componentes de la base de datos y del almacenamiento de archivos. Es responsabilidad de esta capa mantener la integridad y seguridad de la información. Se comunica con la capa de lógica de la aplicación. Se encuentra del lado del servidor, pero separada de la capa de lógica de negocios.

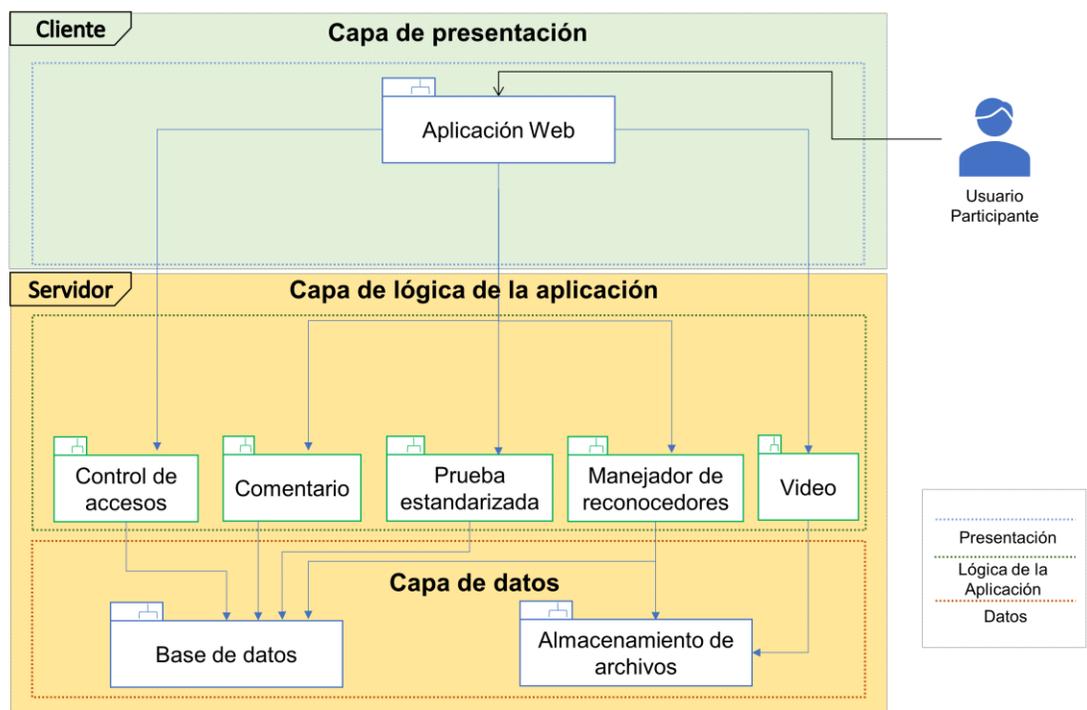


Figura 4-4. Vista lógica de la plataforma.

En la Figura 4-5 se presentan las interfaces provistas y requeridas por los componentes de la plataforma PersonApp.

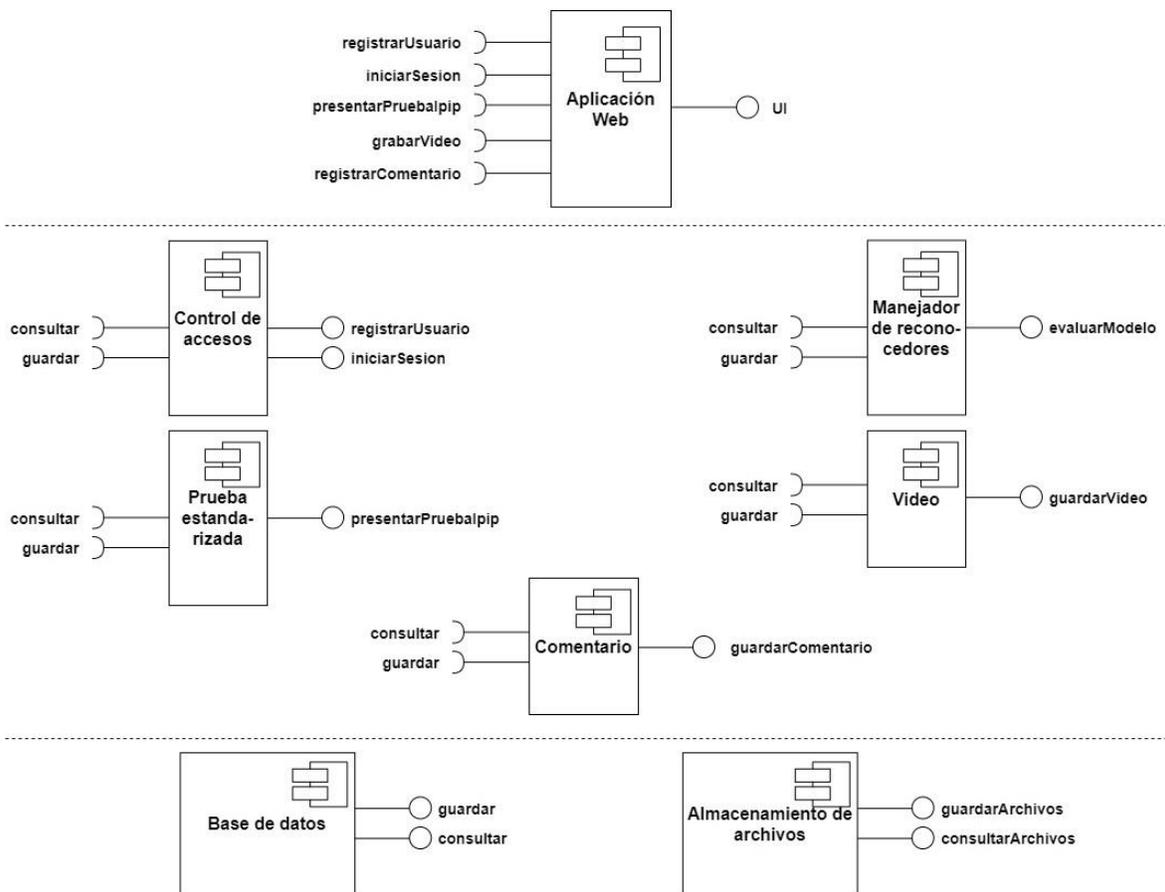


Figura 4-5. Interfaces provistas y requeridas de los componentes de PersonApp.

4.5.2.2. Vista de desarrollo

En esta vista se puede apreciar el ambiente de desarrollo utilizado para el sistema. Se seleccionaron los servicios en la nube de Google Firebase tanto para la fase de desarrollo como para la fase de despliegue, ya que proporciona servicios de autenticación, almacenamiento, base de datos y hospedaje de forma gratuita y cubriendo las necesidades de la investigación (Firebase, 2021). En la Figura 4-6 se muestra la vista de desarrollo. Los servicios que se utilizan son los siguientes:

Firestore Authentication. Permite controlar el acceso a la aplicación a través del uso de una cuenta de correo y una contraseña.

Firestore Cloud Storage. Permite el almacenamiento de los archivos de video de los participantes.

Firestore Firestore. Base de datos no relacional que almacena toda la información de usuarios, resultados de pruebas del IPIP, comentarios y de los reconocedores automáticos evaluados.

Firestore Hosting. Proporciona hospedaje y una dirección web para el acceso a la plataforma.

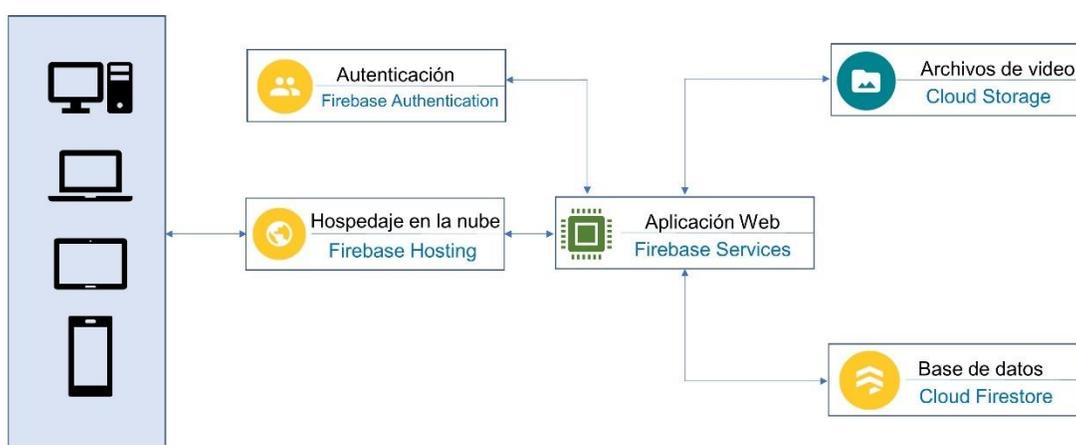


Figura 4-6. Vista de desarrollo de la plataforma.

4.5.2.3. Vista de despliegue

La vista de despliegue es muy similar a la vista de desarrollo. En la Figura 4-7 se puede apreciar la forma en que se encuentran distribuidos los componentes desde la perspectiva de la implementación.

Al estar desarrollada la plataforma como una aplicación Web, la interfaz gráfica se encuentra del lado del cliente y puede visualizarse en cualquier navegador Web, ya sea en un equipo de escritorio, portátil o móvil con conexión a Internet. La parte de lógica de la aplicación y almacenamiento de datos y archivos es atendida por los servicios y servidores que Google Firestore proporciona. Al estar hospedada la aplicación en la nube, permite su utilización en cualquier momento y en cualquier lugar, siempre que se tenga una conexión activa a Internet.

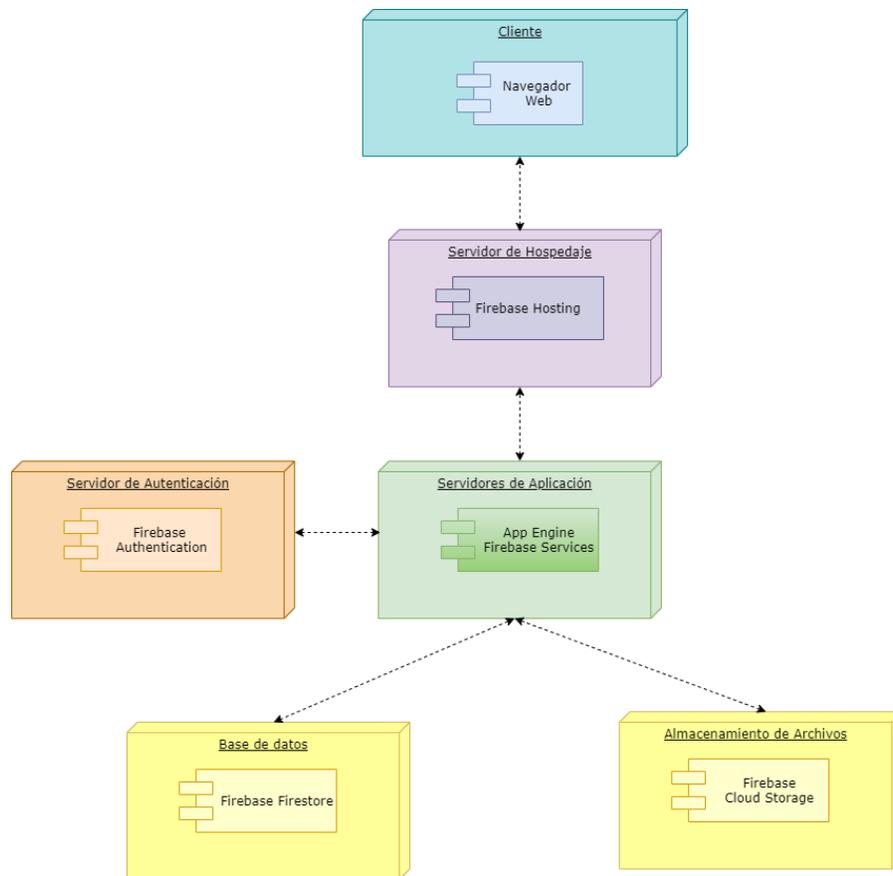


Figura 4-7. Vista de despliegue de la plataforma.

4.6. Implementación

La aplicación desarrollada para la recolección de datos, llamada PersonApp, es un sistema multiplataforma hospedado en la nube de Internet, utilizando el hospedaje gratuito que ofrece Google Firebase como parte de sus servicios. Para el desarrollo de la interfaz de usuario se decidió utilizar React (React, 2021) y para la parte de lógica de la aplicación y almacenamiento de información y de archivos, se optó por los servicios gratuitos de Google Firebase. Lo anterior, proporciona la flexibilidad de tener la información disponible desde cualquier ubicación que cuente con conexión a Internet. Otra ventaja de utilizar dichos servicios es el respaldo en privacidad y seguridad de los datos que ofrece Firebase, ya que está certificado en los principales estándares de seguridad y privacidad (Seguridad Firebase, 2021).

4.6.1. Lenguajes y herramientas de desarrollo

En esta sección se describen las herramientas de software utilizadas para el desarrollo de la plataforma.

4.6.1.1. React

Biblioteca de JavaScript para construir interfaces de usuario. React está basado en componentes. Permite el desarrollo de aplicaciones Web que se adaptan al dispositivo utilizado para la navegación (React, 2021).

4.6.1.2. JavaScript

Se define como un lenguaje de programación con soporte de múltiples paradigmas de programación, basado en prototipos, de un único hilo, dinámico y usualmente utilizado para el desarrollo de páginas Web (JavaScript, 2021).

4.6.1.3. HTML

Lenguaje de etiquetas de hipertexto (HTML por sus siglas en inglés: *HyperText Markup Language*). Se define como el componente básico de una página Web. Se utiliza para definir la estructura y significado del contenido de una página Web (HTML, 2021).

4.6.1.4. CSS

Hojas de Estilo en Cascada (del inglés *Cascading Style Sheets*) o CSS. Es un lenguaje de estilos que permite describir la presentación de documentos HTML. Describe como debe ser renderizado cada elemento (CSS, 2021).

4.6.1.5. Visual Studio Code

Herramienta de desarrollo de software libre enfocada a la edición de código. Se utilizó como el ambiente de desarrollo de la aplicación. Es multiplataforma y proporciona soporte para los lenguajes utilizados en el desarrollo de la plataforma PersonApp (Code, 2021).

4.6.2. Representación y almacenamiento de datos

En este apartado se describen las herramientas utilizadas en la plataforma para la representación de los datos y el almacenamiento de la información en la nube.

4.6.2.1. JSON

JSON (*JavaScript Object Notation* - Notación de Objetos de JavaScript). Es un formato de intercambio de datos muy ligero. Es utilizado en la plataforma para la creación de la prueba

estandarizada. Es un formato que puede ser leído y comprendido de manera simple por un humano. Muy fácil de procesar, interpretar y generar por un programa de computadora (JSON, 2021).

4.6.2.2. Firebase

Es auspiciado por Google y ofrece diversos servicios gratuitos y de paga que facilitan el desarrollo de aplicaciones. Entre los servicios que se están utilizando en la plataforma PersonApp se encuentran autenticación, hospedaje, base de datos no relacional Firestore y almacenamiento de archivos. Todos utilizados en su versión gratuita (Firebase, 2021).

4.7. Interfaz gráfica de la plataforma

La interfaz gráfica de PersonApp está realizada con base en los requisitos funcionales que se definieron para el desarrollo del sistema. En primera instancia se diseñaron y desarrollaron las interfaces de creación de cuenta e inicio de sesión. En la Figura 4-8 se muestra la presentación de ambas interfaces.

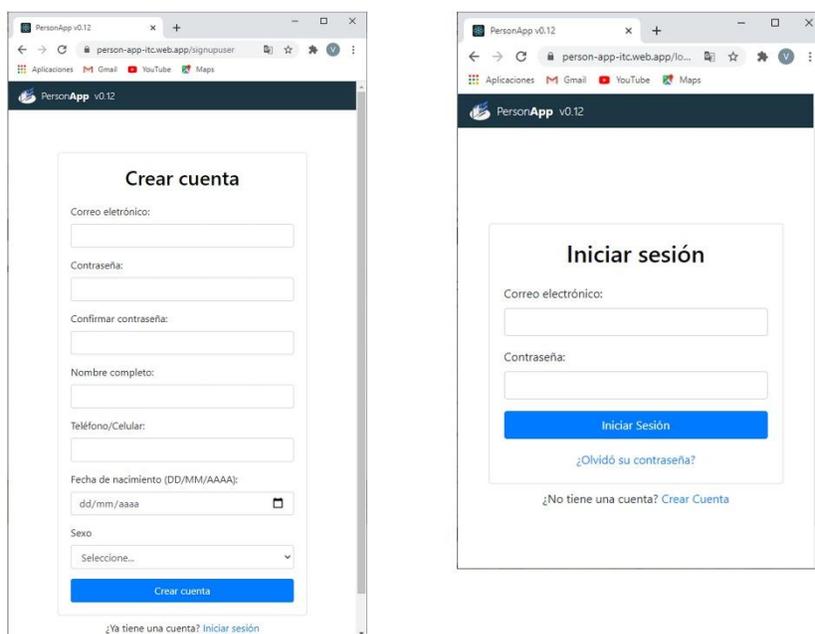


Figura 4-8. Interfaces para creación de cuenta e inicio de sesión.

Se ha implementado la autenticación por medio de correo electrónico y contraseña, utilizando como se ha mencionado previamente Firebase Authentication que ofrece los mecanismos de seguridad suficientes para garantizar un ingreso seguro y confiable a la plataforma.

Después de iniciar sesión, el usuario es redirigido a la interfaz de bienvenida. En la Figura 4-9 se puede apreciar el ejemplo de su interfaz visual inicial. En ella, se le da a conocer al usuario como está integrado el equipo de investigadores participantes en el proyecto, además de mostrar una breve descripción del objetivo del proyecto. También se presenta una breve descripción del procedimiento que deberá seguir cada participante del experimento.

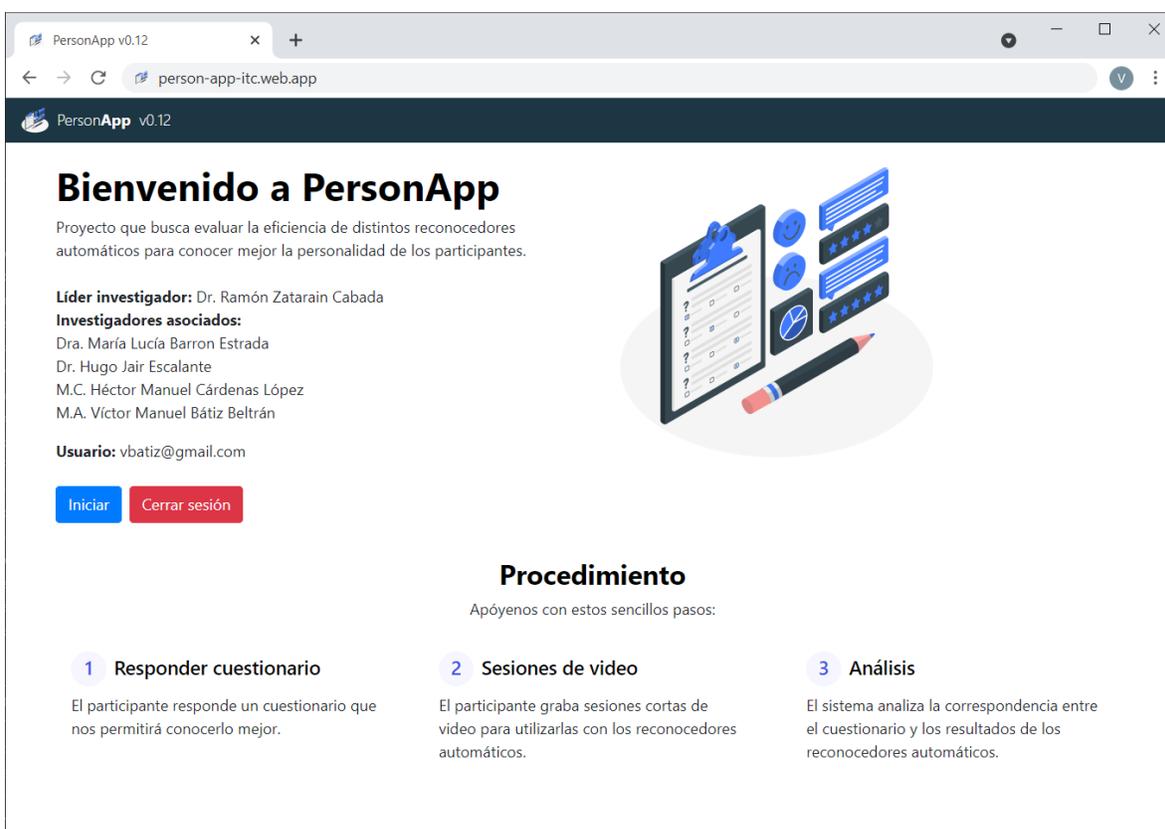


Figura 4-9. Ventana de bienvenida.

Una vez que el usuario presiona el botón iniciar, es redirigido a la interfaz de la prueba estandarizada. En dicha interfaz el participante deberá responder la prueba del IPIP. En la Figura 4-10 y la Figura 4-11 se muestran la parte superior de la prueba y la parte inferior respectivamente. Se puede apreciar que existe un contador de tiempo y un indicador del total de preguntas contestadas.

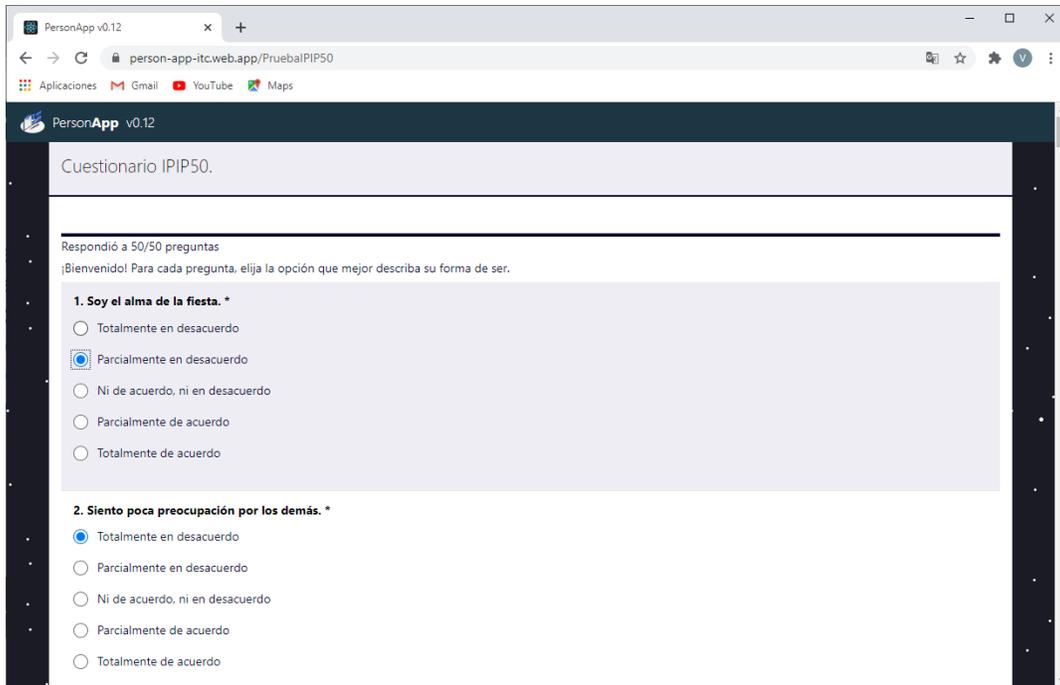


Figura 4-10. Parte superior de la prueba estandarizada.

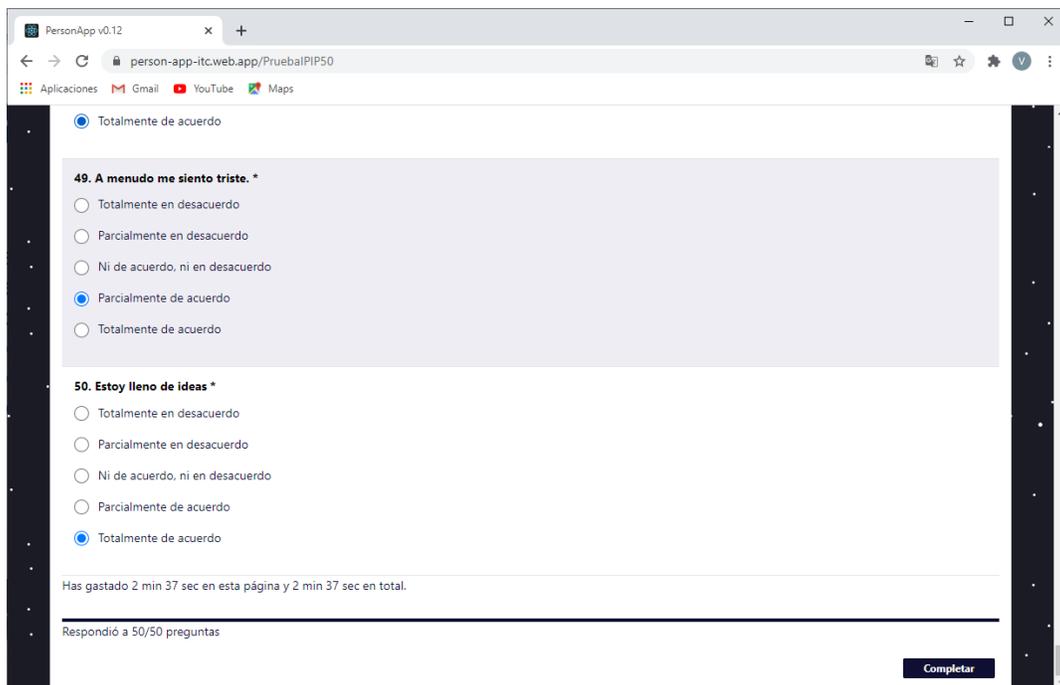


Figura 4-11. Parte inferior de la prueba estandarizada.

Una vez que el participante ha respondido las 50 preguntas que integran la prueba estandarizada debe dar clic al botón completar y de esta forma es redirigido a la interfaz de bienvenida de la grabación de videos.

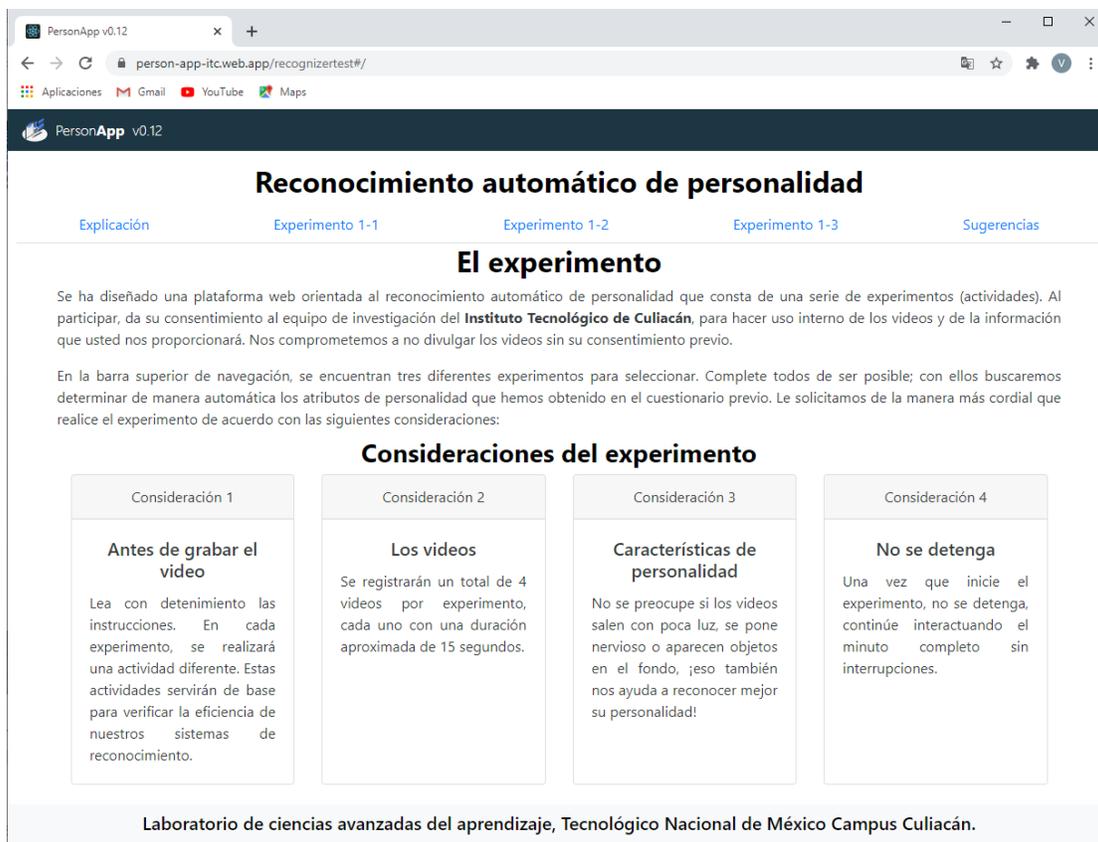


Figura 4-12. Ventana de bienvenida a la grabación de videos.

En la Figura 4-12 se puede apreciar esta interfaz donde se describen las características para la grabación de los videos que serán utilizados en los experimentos. Existen tres secciones de grabación de videos. El participante puede dar clic en el título correspondiente para realizar la grabación en el orden que desee, aunque se recomienda hacerlo en el orden numérico indicado. En la Tabla 4-7 se muestran las instrucciones para la grabación de los videos.

Tabla 4-7. Instrucciones para la grabación de videos.

Experimento	Instrucciones para el participante
Experimento 1-1	Una vez que presiones iniciar, habla sobre un tema que te guste. Puedes hablar sobre lo que sea. La recomendación es imaginar que se habla con amigos en una reunión de Zoom o Teams acerca del tema.
Experimento 1-2	En esta actividad pretenderás estar en una entrevista virtual en línea, trata de responder las siguientes preguntas ¿Cuáles son tus mayores fortalezas y debilidades?, ¿Por qué consideras que deberíamos contratarte?
Experimento 1-3	Por último, pretenderás ser una persona creando un video para exponer un tema en una plataforma en línea (Youtube, Facebook, Twitch, etc.), tú elijes el tema y la manera de presentarlo.

En la Figura 4-13 se ilustra la interfaz para la grabación del video correspondiente al Experimento 1-1.

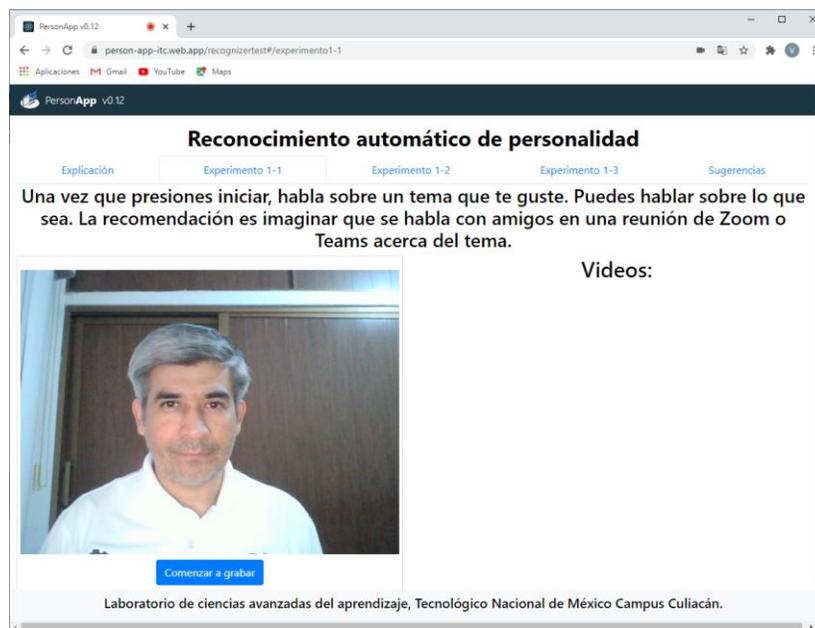


Figura 4-13. Grabación de video para experimento 1-1.

Una vez que el participante ha concluido la grabación de los videos, tiene la opción de enviar sus comentarios sobre el proceso y la aplicación. En la Figura 4-14 se muestra la interfaz para esta actividad.

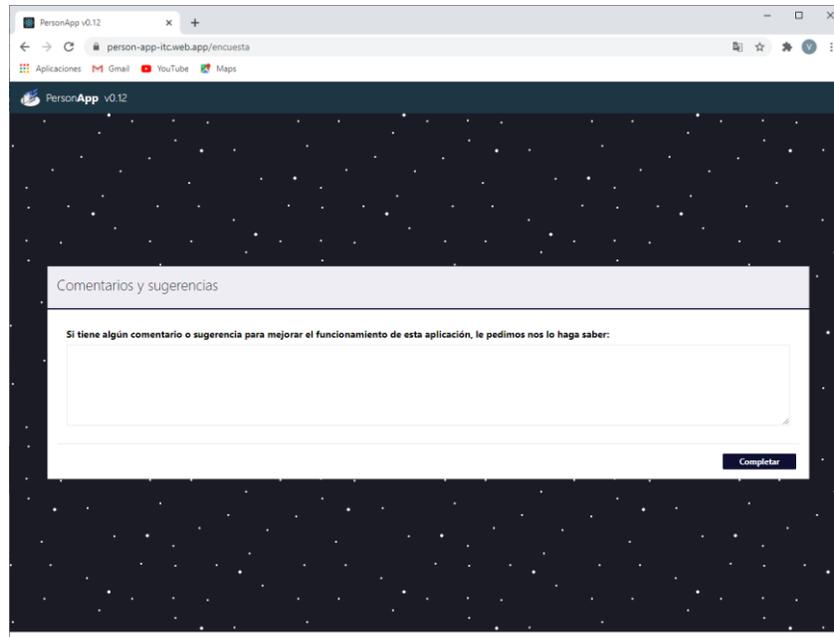


Figura 4-14. Ventana para envío de comentarios y sugerencias.

Con esto termina la participación del usuario en el proceso de recolección de datos. La información recolectada es procesada posteriormente por el servicio de reconocedores automáticos y la información resultante es adicionada a la base de datos para su análisis.

4.8. Módulo manejador de reconocedores

En la nube, los servicios ofrecen la posibilidad de usar observadores y ser observables. Se aprovechó esta tecnología y se construyó una tubería de procesamiento del lado del servidor. Este proceso opera de la siguiente forma. Cada vez que un participante graba un nuevo video, éste es descargado a un servidor local. Posteriormente, se preprocesa con el reconocedor automático de personalidad aparente seleccionado. Como siguiente paso, se procede a predecir los valores de los rasgos de personalidad. Finalmente, se almacenan en la base de datos de la plataforma PersonApp, ubicada en la nube, los datos de identificación del participante, el nombre del video, el escenario experimental y las diferentes etiquetas correspondientes a los cinco rasgos de personalidad del modelo *Big-Five*. En la Figura 4-15 se puede observar de manera gráfica el proceso que se ejecuta para la revisión de video y generación de los valores de predicción.

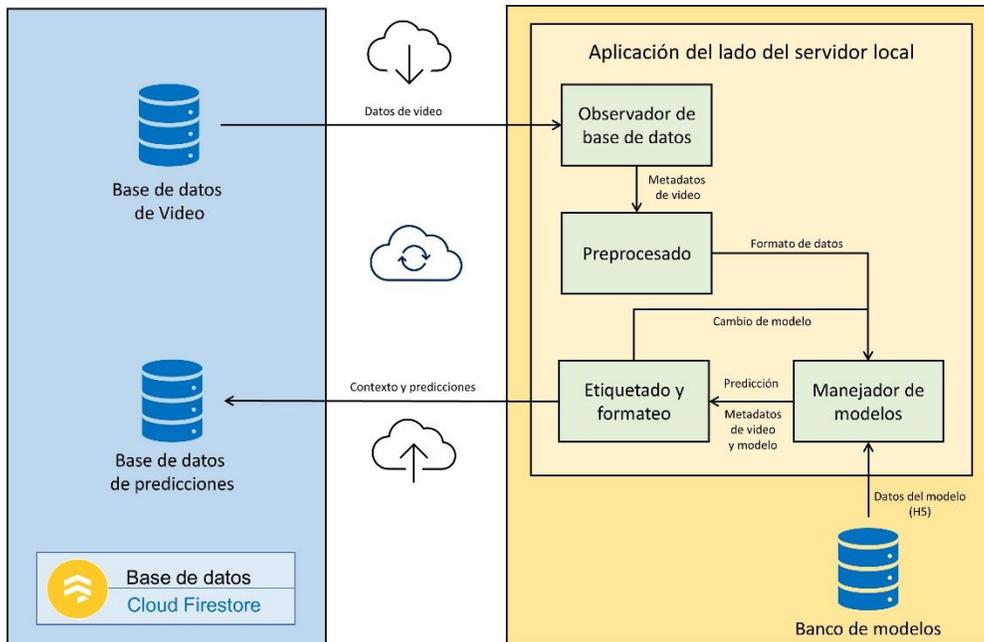


Figura 4-15. Diagrama de operación del manejador de reconocedores.

4.9. Reconocedor evaluado

En este proyecto se decidió evaluar inicialmente un modelo de reconocimiento automático basado en aprendizaje profundo, utilizando redes neuronales convolucionales (CNN, por sus siglas en inglés). Dicho reconocedor automático fue entrenado utilizando el conjunto de datos sobre personalidad de ChaLearn, el cual contiene 10,000 videos con una duración aproximada de 15 segundos cada uno. Estos videos fueron extraídos de más de 3,000 videos de alta definición de la plataforma Youtube (Escalante et al., 2018). El reconocedor utiliza imágenes extraídas de los videos.

Para extraer de manera efectiva las características de los datos de video y cumplir con los requisitos de CNN, es mejor muestrear los videos espacial y temporalmente. Primero, cada video se muestrea con 32 cuadros con ayuda de la biblioteca OpenCV (OpenCV, 2021) usando un tiempo de muestra de 2 segundos. Este número es uno de los más utilizados para equilibrar la extracción efectiva de características de las señales relevantes para el movimiento y los requisitos computacionales en este conjunto de datos de video. Luego se redimensionan a un tamaño de 500x500x3 y se utiliza la biblioteca dlib (King, 2009) para detectar rostros en cada cuadro. Una vez obtenidos los vectores representativos de los puntos

de referencia faciales, son utilizados para dibujar líneas para enfatizar los rasgos faciales en las imágenes. La Figura 4-16 describe el proceso anterior y se pueden apreciar los puntos de referencia faciales producto de este proceso.



Figura 4-16. Proceso de etiquetado del rostro.

La arquitectura utilizada por el reconocedor automático evaluado es una red neuronal residual convolucional discreta (ResNet). Se usaron imágenes de tamaño de 500x500x3 píxeles con sus correspondientes etiquetas de video para la entrada. Posteriormente se procede a usar 5 módulos de redes residuales convolucionales para procesar los datos de las imágenes y crear vectores de atributos. Finalmente, se utiliza una red neuronal artificial de 3 capas para la clasificación de características con una capa de salida de 6 neuronas para la regresión. La pérdida se midió utilizando el Error Absoluto Medio (MAE). La arquitectura completa, la cual se ilustra en la Figura 4-17, es la siguiente: primero está la capa de entrada de tamaño 500x500x3. Luego se crean 5 módulos ResNet, donde cada módulo ResNet contiene una capa convolucional bidimensional (Conv2D) de 16 filtros en 3 dimensiones, con activación de unidad lineal rectificadora (ReLU) conectada a otra capa Conv2D, con 16 filtros en 3 dimensiones con activación ReLU. Se usó una capa de concatenación para agregar las características de esta convolución con las características del último bloque de ResNet obtenido. Finalmente, esa capa se conectó a una capa de agrupación máxima bidimensional (Maxpool2D) con un paso (*stride*) de 3. Luego se usó una sola capa Conv2D con 16 filtros en 3 dimensiones y una agrupación promedio global. Se aplanó el vector de características y se procedió a unir 4 capas densamente conectadas, cada una con 512, 128, 64 y 6 neuronas respectivamente. Las primeras 3 utilizaron la activación de ReLU y la última capa usada para la regresión utilizó la activación sigmoidea.

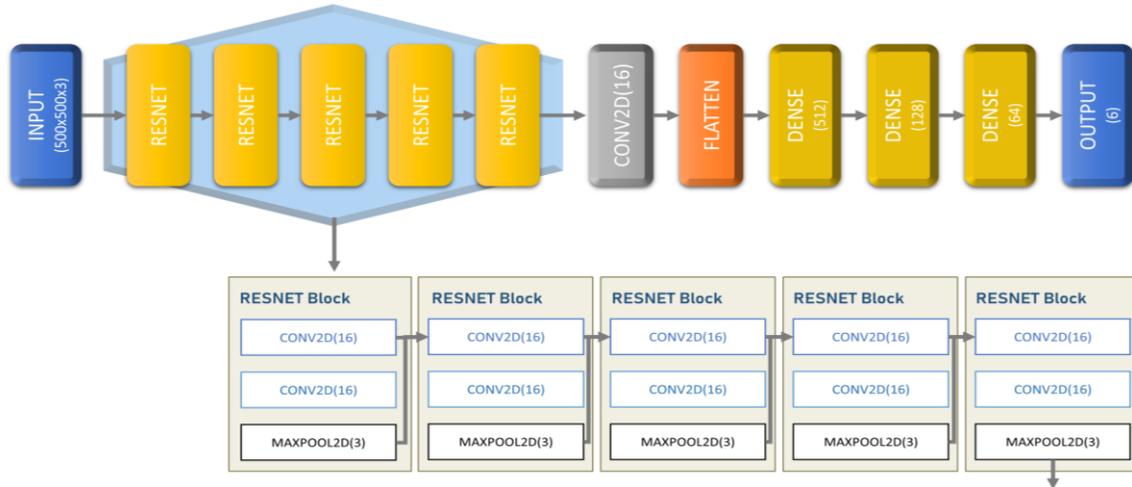


Figura 4-17. Topología de red neuronal convolucional discreta.

En la Tabla 4-8, se muestran los resultados de exactitud (*accuracy*) del modelo utilizado (denominado TNMCUL) y su comparativa contra enfoques del estado del arte, incluidos en las publicaciones de los mejores participantes en los concursos de reconocimiento de personalidad aparente con base en primeras impresiones de ChaLearn (Ponce-López et al., 2016; Subramaniam et al., 2016).

La exactitud de cada modelo se realizó con base a los parámetros establecidos por la competencia ChaLearn para mostrar la tabla de posiciones de los competidores. De esta forma, la evaluación consistió en calcular la exactitud (*accuracy*) media de todos los rasgos de personalidad y videos. La Fórmula 4-1 describe el cálculo de la exactitud (Ponce-López et al., 2016).

$$Acc = 1 - \frac{1}{N_t} \sum_{i=1}^{N_t} |t_i - p_i| \quad (4-1)$$

Donde:

- p_i es el valor predicho por el reconocedor automático evaluado.
- t_i es el valor base real.
- N_t es el total de videos evaluados.

Tabla 4-8. Comparativa entre la técnica utilizada y otros enfoques del estado del arte.

Nombre	Año	Técnica	Exactitud (Accuracy)
TNMCUL	2021	CNN Discreta	0.936158
NJU-LAMDA	2016	Deep Multi-Modal Regression	0.912968
evolgen	2016	Multi-modal LSTM Neural Network with Randomized Training	0.912063
DCC	2016	Multi-modal Deep ResNet 2D kernels	0.910933
Ucas	2016	AlexNET, VGG, ResNet con HOG3D, LBP-TOP	0.909824
BU-NKU	2016	Deep feature extraction with regularized regression and feature level fusion	0.909387
Pandora	2016	Multi-modal deep feature extraction single frame and late fusion	0.906275
Pilab	2016	Speech features 1000 forest random trees regression	0.893602
Kaizoku	2016	Multi-modal parallel CNN	0.882571

Capítulo 5

5. Pruebas, Experimentos y Resultados

En esta sección se presenta la información sobre la implementación de la prueba estandarizada de personalidad utilizada, los datos obtenidos de la evaluación inicial de la plataforma para recibir retroalimentación, la descripción del modelo evaluado y un análisis de los resultados obtenidos.

5.1. Prueba estandarizada de personalidad

En esta etapa del proyecto, en el apartado de prueba estandarizada de personalidad se implementó una representación IPIP de 50 ítems de los marcadores mencionados por Goldberg para la estructura factorial del modelo de los cinco grandes (Goldberg, 1992). En la Tabla 5-1 se muestra de forma resumida el número de ítems positivos y negativos que se recomiendan para evaluar cada factor de la personalidad (IPIP, 2021).

Tabla 5-1. Combinación de ítems positivos y negativos para la elaboración de la prueba estandarizada.

Factor de los Cinco Grandes (<i>Big-Five</i>)	Número de ítems positivos (+)	Número de ítems negativos (-)	Total de ítems
Extroversión	5	5	10
Amabilidad	6	4	10
Responsabilidad	6	4	10
Neuroticismo	2	8	10
Apertura	7	3	10

Cada uno de los cinco factores de la personalidad se evalúa por medio de 10 ítems, los cuales a su vez son calificados por el participante en una escala de Likert de 5 elementos (totalmente en desacuerdo; parcialmente en desacuerdo; ni de acuerdo, ni en desacuerdo; parcialmente de acuerdo y totalmente de acuerdo) con base en su nivel de acuerdo o desacuerdo con respecto a cada declaración mostrada. En la Figura 5-1 se muestra un ejemplo de la presentación de los ítems del IPIP utilizados. Cada opción tiene un valor de 1 a 5 puntos, cuando el ítem es positivo los puntajes se asignan desde 1 punto para totalmente en desacuerdo, hasta 5 puntos para totalmente de acuerdo. En el caso de que el ítem sea negativo se invierten los puntajes.

Por lo anterior, 50 es el máximo puntaje posible por factor. Finalmente, el puntaje de cada factor es dividido entre 50 para convertirlo en un valor entre 0 y 1. Esta información se almacena en el repositorio en la nube y se registra a que usuario pertenece. Dichos valores se utilizan para compararlos contra los resultados de los reconocedores automáticos de personalidad aparente. En el Anexo A, se pueden revisar los ítems utilizados para la prueba estandarizada (IPIP-50).

1. Soy el alma de la fiesta. *

- Totalmente en desacuerdo
- Parcialmente en desacuerdo
- Ni de acuerdo, ni en desacuerdo
- Parcialmente de acuerdo
- Totalmente de acuerdo

2. Siento poca preocupación por los demás. *

- Totalmente en desacuerdo
- Parcialmente en desacuerdo
- Ni de acuerdo, ni en desacuerdo
- Parcialmente de acuerdo
- Totalmente de acuerdo

Figura 5-1. Ejemplo de presentación de los ítems del IPIP utilizados.

5.2. Evaluación inicial de la plataforma

Respecto a la evaluación de la plataforma PersonApp se llevó a cabo una intervención inicial con estudiantes del Tecnológico Nacional de México en el Instituto Tecnológico de Culiacán. Gracias a su participación, se logró obtener una diversidad de comentarios, sugerencias y recomendaciones que fueron aplicadas en la optimización del funcionamiento de la plataforma. En la Tabla 5-2 se muestran los más relevantes.

Tabla 5-2. Comentarios de usuarios.

Participante	Comentario
Usuario 1	Todo funcionó excelente.
Usuario 2	Todo trabaja bien, ningún problema con la plataforma. Quizá un botón para regrabar los videos. una vez que entren los 4.
Usuario 3	Al realizar los videos no supe muy bien si realmente grabé algo, quise verlos y no pude. Creo que debe manejar alguna opción para ver el video y (si así lo deseas) volver a grabarlo.
Usuario 4	Quizá recomendar algunos temas dentro de la aplicación para que las personas puedan elegir.
Usuario 5	Me parece muy bien diseñada la aplicación, ¡felicidades!
Usuario 6	En general todo bien, me hubiera gustado un segundero para saber cuánto tiempo tenía o me quedaba disponible, pero todo funcionó correcto y estuvo bien explicado.
Usuario 7	Está un poquito confuso la forma de grabar, todo lo demás muy bien :)
Usuario 8	El diseño de la página me parece que está bien hecho, sin embargo, en la parte de los videos si se hizo un poco demasiado apresurado y divague mucho por el hecho de que no estoy acostumbrado a grabarme. En la parte de los 50 reactivos, se entiende en su mayoría lo que se pretende, sin embargo, puede que haya algunas cosas que pueden confundir la manera en la que se pregunta.
Usuario 9	Todo muy bien, quizás marcar que videos ya se hicieron y cuáles no, o al menos saber en cual estoy ubicado daría un poco de mejor usabilidad.
Usuario 10	Tuve problemas al crear mi cuenta, sería conveniente mejorar los mensajes de error para saber que está fallando.

Con base en las recomendaciones se realizaron los cambios pertinentes a la plataforma para mejorar la usabilidad y el despliegue de mensajes a los usuarios. Algunas recomendaciones se decidió ponerlas en espera. Sin embargo, están consideradas para abordarlas como un trabajo a futuro.

5.3. Experimento

En este apartado se describe el desarrollo de la intervención con el Experimento 1-1. En este experimento, a cada participante se le requirió que diera respuesta a la prueba IPIP. Una vez concluida la prueba IPIP, se le requería al usuario grabar en un lapso de un minuto, un video en donde se le pide hablar libremente sobre un tema cualquiera. Se le hace la recomendación al usuario de imaginarse que está en una plática con amigos a través de una plataforma de reunión virtual. Posteriormente, el video es procesado y segmentado en cuatro videos con

una duración de 15 segundos cada uno. Cada uno de los cuatro videos es utilizado por el módulo manejador de reconocedores, para extraer las imágenes que alimentan al reconocedor automático de personalidad aparente y los resultados son almacenados directamente en la base de datos en la nube.

5.4. Resultados

En este apartado se presentan y analizan los resultados obtenidos. Primero se analizan los datos obtenidos de las pruebas del IPIP y posteriormente los resultados comparativos entre las predicciones realizadas por el reconocedor automático de personalidad aparente y los valores de las pruebas del IPIP.

5.4.1. Resultados de las pruebas del IPIP

Participaron 32 individuos en la intervención con la prueba del IPIP, de los cuales, 15 son de sexo masculino y 17 de sexo femenino. Todos los participantes dentro de un rango de 23 a 44 años. En la Tabla 5-3 se puede apreciar la estadística descriptiva de los datos recolectados para cada uno de los atributos de personalidad.

Tabla 5-3. Estadística descriptiva de las pruebas del IPIP.

Atributo	Participantes	Media	Desv. Est.	Mínimo	Máximo
Apertura	32	0.7344	0.1450	0.30	1.00
Responsabilidad	32	0.6844	0.1568	0.40	0.90
Extroversión	32	0.5969	0.1750	0.20	0.90
Amabilidad	32	0.7906	0.1376	0.50	1.00
Neuroticismo	32	0.5656	0.2598	0.20	1.00

Como se explicó previamente al inicio del capítulo, en este trabajo de investigación la prueba del IPIP evalúa cada factor con un puntaje entre 0 y 1. Un valor cercano a 0 significa que el participante tiene un menor desarrollo en el factor evaluado y un valor cercano a 1 significa que el participante tiene muy desarrollado el factor en cuestión. Diversos estudios han confirmado que la autoevaluación que hace un individuo con respecto a sus rasgos de personalidad está altamente correlacionada con la opinión que otras personas tienen de él (Vinciarelli & Mohammadi, 2014).

De acuerdo con la Tabla 5-3 se puede observar que los atributos de personalidad con un valor promedio más alto fueron amabilidad con una media de 0.7906 y apertura con una media de 0.7344. Ambos rasgos presentaron también la menor variación con desviaciones estándar de 0.1376 y 0.1450 respectivamente. El factor con el menor valor medio resultó ser neuroticismo.

En la Figura 5-2 se muestra el histograma de los valores obtenidos por los participantes en el atributo de apertura.

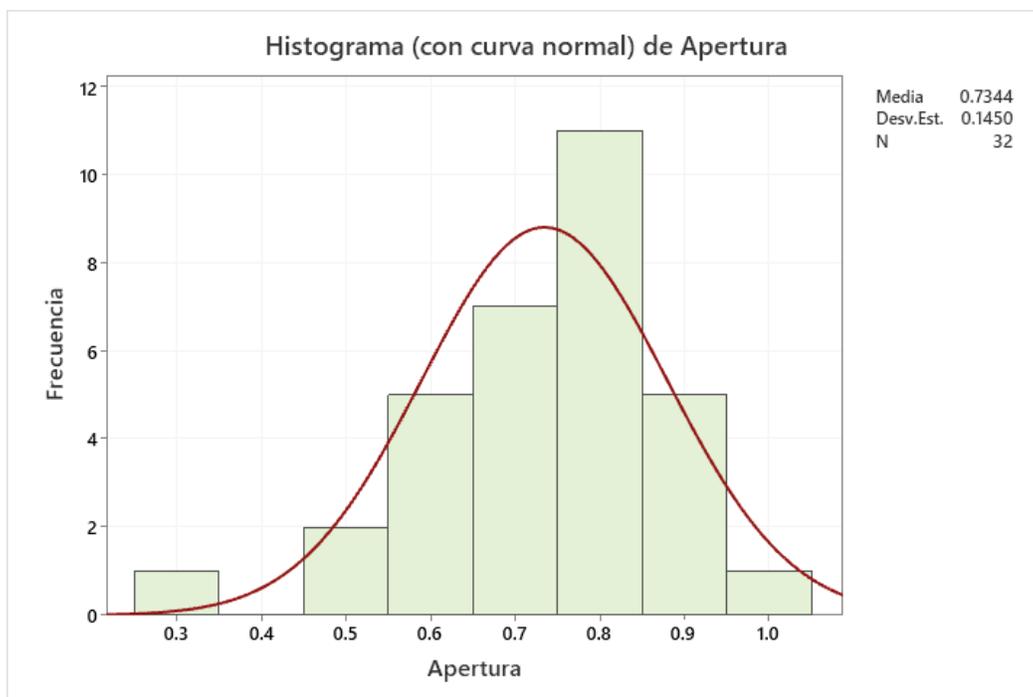


Figura 5-2. Histograma del atributo de Apertura.

En la Figura 5-3 se muestra el histograma de los valores obtenidos por los participantes en el atributo de responsabilidad.

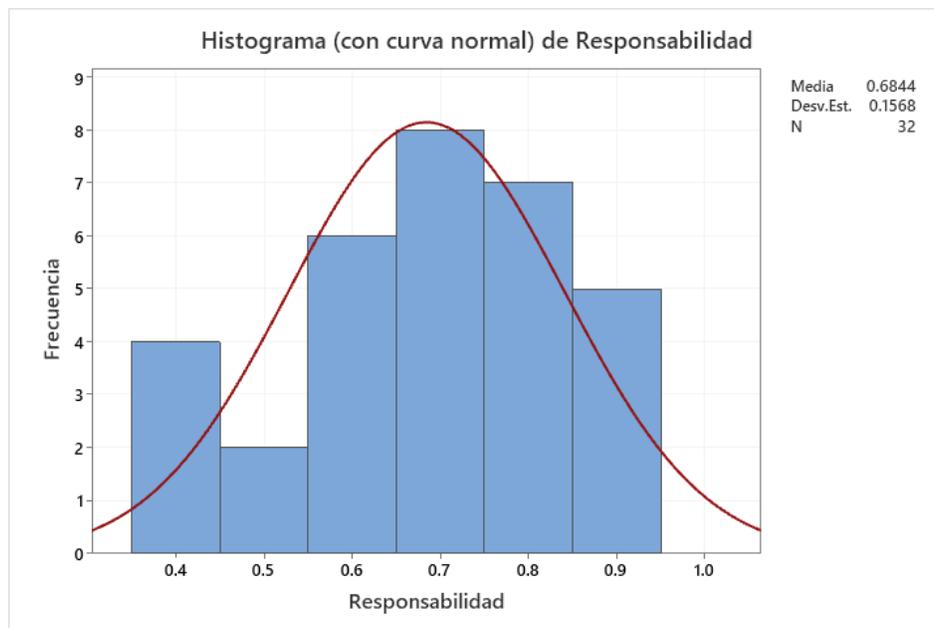


Figura 5-3. Histograma del atributo de Responsabilidad.

En la Figura 5-4 se muestra el histograma de los valores obtenidos por los participantes en el atributo de extroversión.

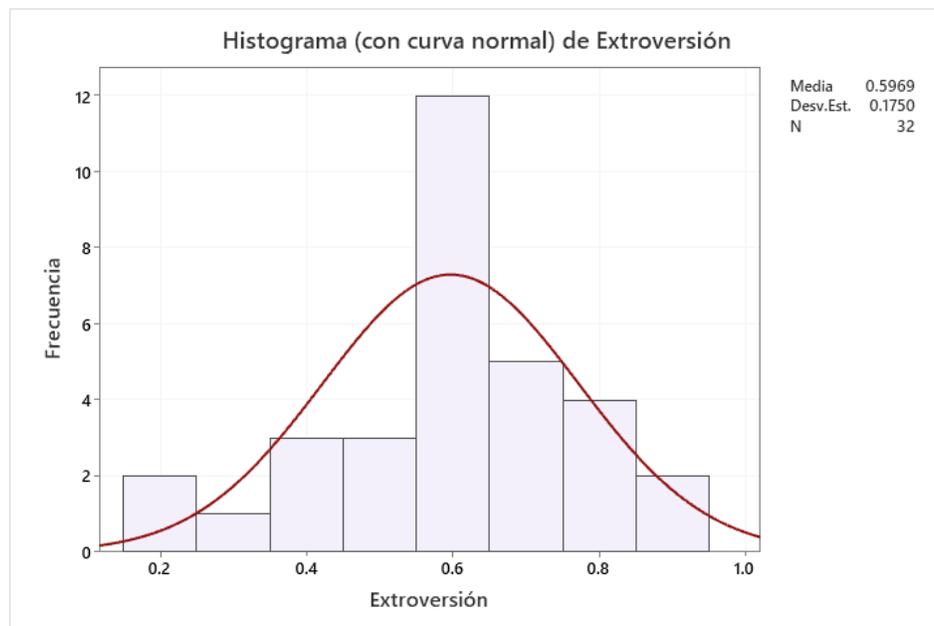


Figura 5-4. Histograma del atributo de Extroversión.

En la Figura 5-5 se muestra el histograma de los valores obtenidos por los participantes en el atributo de amabilidad.

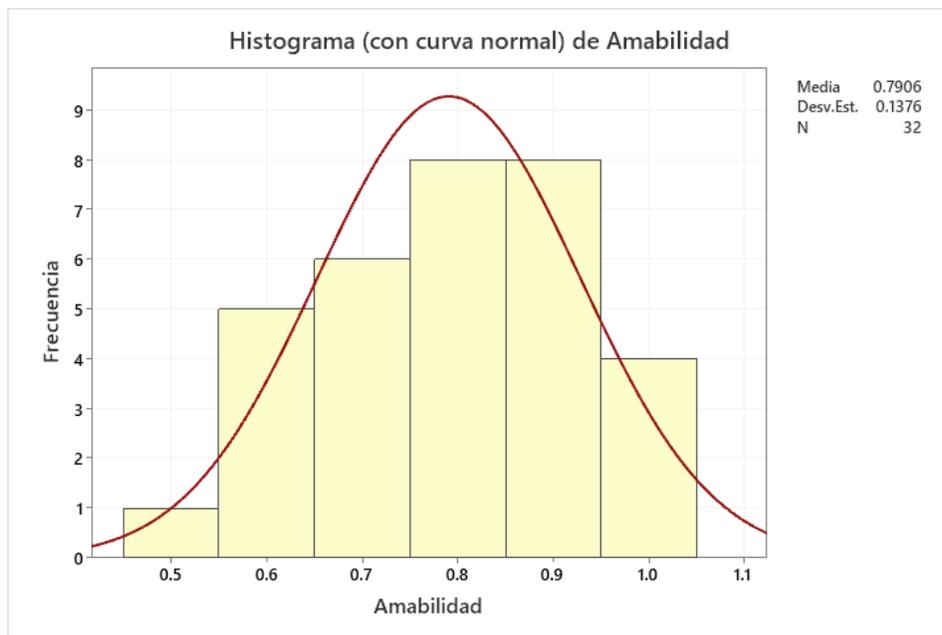


Figura 5-5. Histograma del atributo de Amabilidad.

En la Figura 5-6 se muestra el histograma de los valores obtenidos por los participantes en el atributo de neuroticismo.

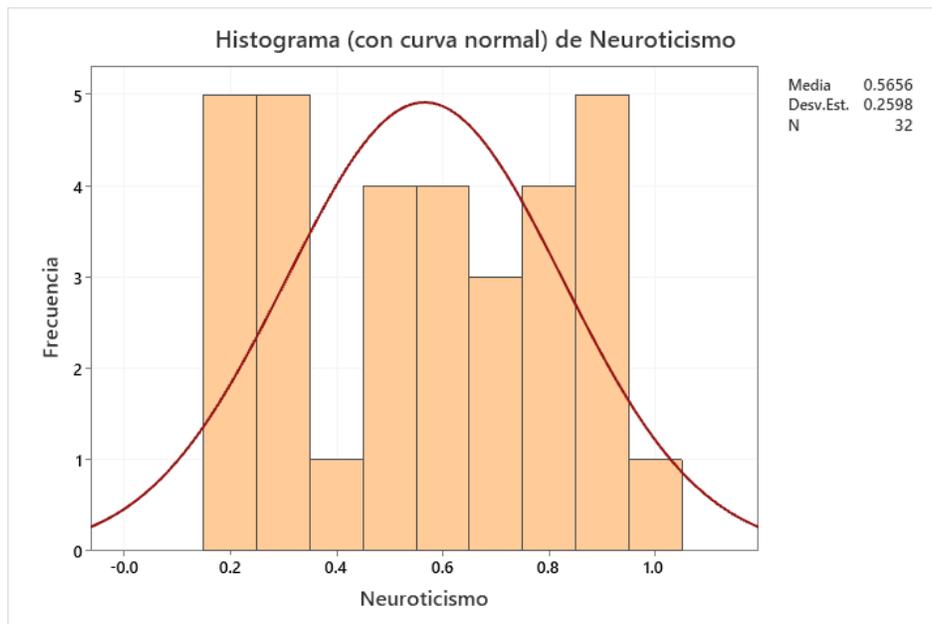


Figura 5-6. Histograma del atributo de Neuroticismo.

Al realizar el análisis de los histogramas de frecuencia de los cinco atributos de personalidad, es interesante observar la distribución de los datos y se puede resaltar que, exceptuando al atributo de neuroticismo, el resto de los atributos tiene una tendencia hacia una distribución normal.

5.4.2. Resultados del reconocedor automático evaluado

Para la evaluación del reconocedor automático de personalidad aparente seleccionado, se recolectaron 84 videos. Los videos fueron producto de la intervención de 21 participantes, de los cuales, 13 son de sexo masculino y 8 de sexo femenino. El rango de edades de los participantes está entre 23 y 40 años. En la Tabla 5-4 se muestran los valores de error absoluto medio (MAE) obtenidos al comparar cada valor de los atributos de personalidad predichos por el reconocedor automático de personalidad aparente contra el valor correspondiente para el participante con base a la prueba del IPIP.

Tabla 5-4. Error absoluto medio de cada atributo.

Atributo	Videos	MAE
Apertura	84	0.2683
Responsabilidad	84	0.2684
Extroversión	84	0.1941
Amabilidad	84	0.3698
Neuroticismo	84	0.2806

Con base en los datos obtenidos se pudo detectar que el error absoluto medio (MAE) fue menor en el factor de extroversión y mayor en amabilidad. Sin embargo, en todos los atributos de personalidad el valor es demasiado alto por lo que no es posible considerar que el modelo de reconocimiento automático evaluado haya realizado una predicción adecuada.

En la Figura 5-7 se muestra el histograma de los errores absolutos correspondientes al atributo de apertura.

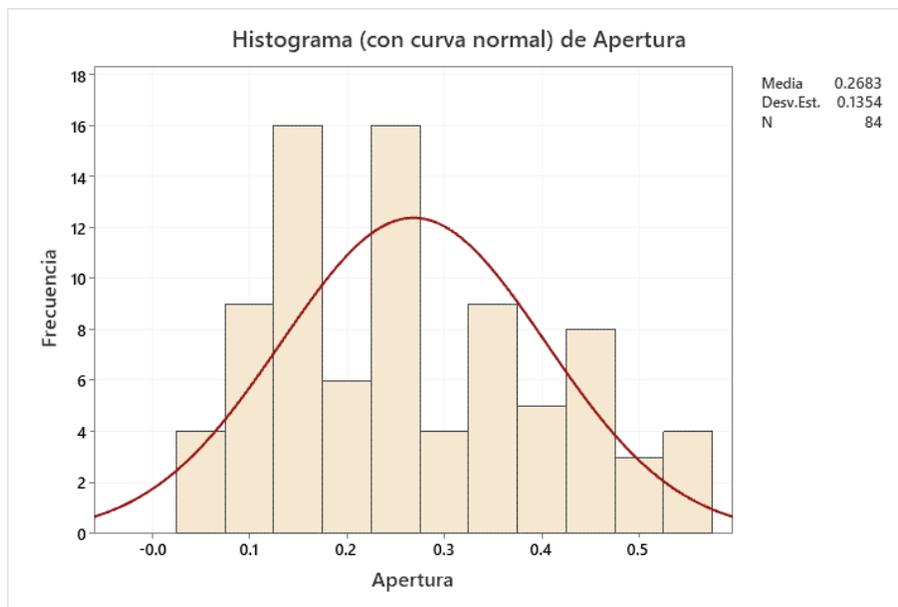


Figura 5-7. Histograma de errores absolutos del atributo de Apertura.

En la Figura 5-8 se muestra el histograma de los errores absolutos correspondientes al atributo de responsabilidad.

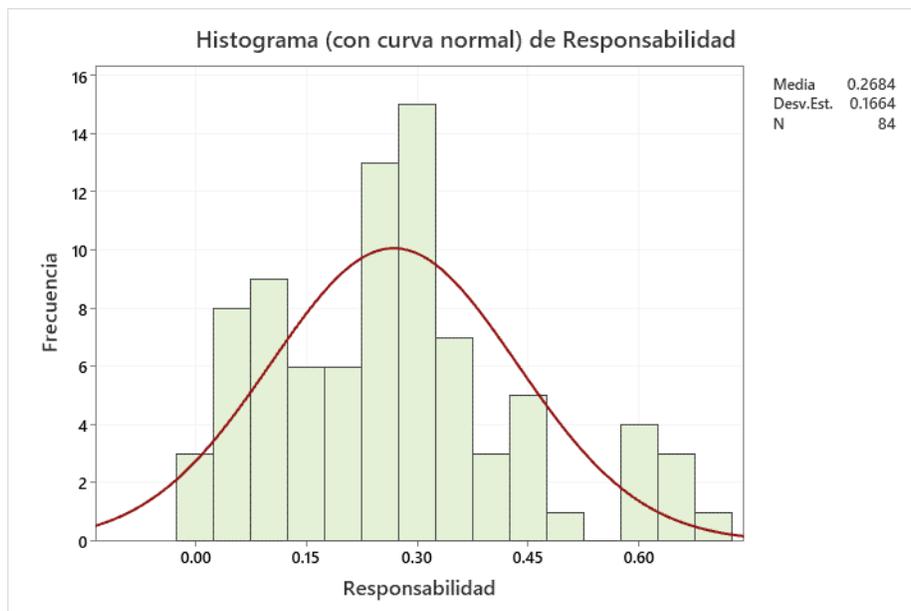


Figura 5-8. Histograma de errores absolutos del atributo de Responsabilidad.

En la Figura 5-9 se muestra el histograma de los errores absolutos correspondientes al atributo de extroversión.

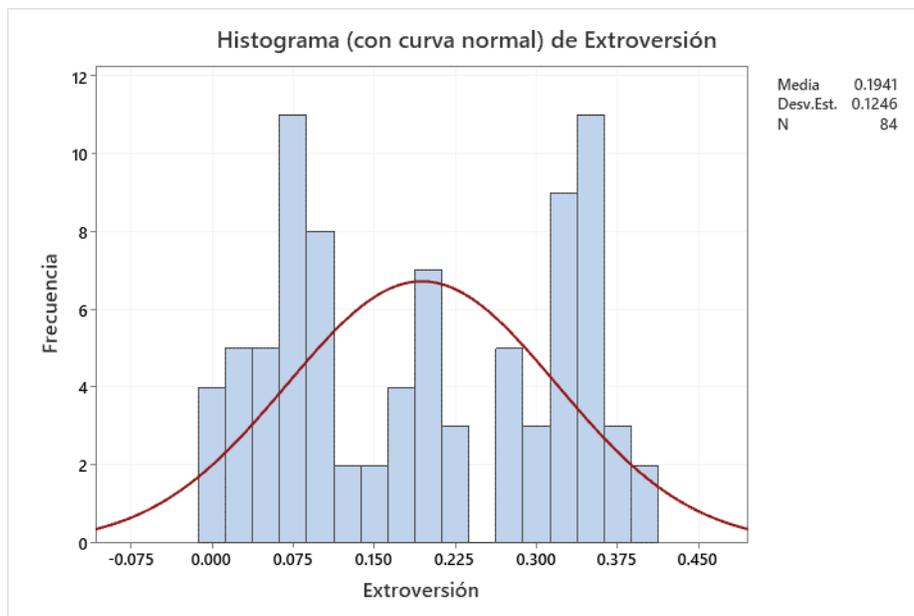


Figura 5-9. Histograma de errores absolutos del atributo de Extroversión.

En la Figura 5-10 se muestra el histograma de los errores absolutos correspondientes al atributo de amabilidad.

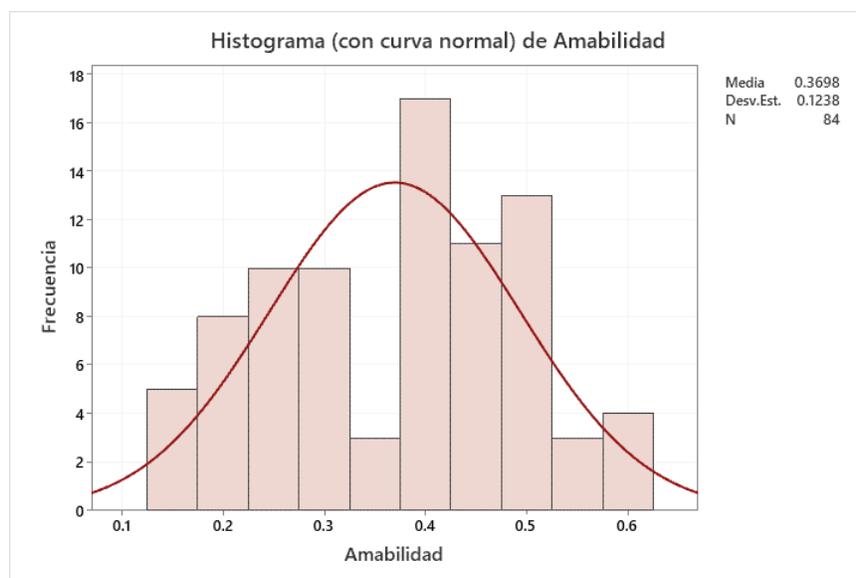


Figura 5-10. Histograma de errores absolutos del atributo de Amabilidad.

En la Figura 5-11 se muestra el histograma de los errores absolutos correspondientes al atributo de neuroticismo.

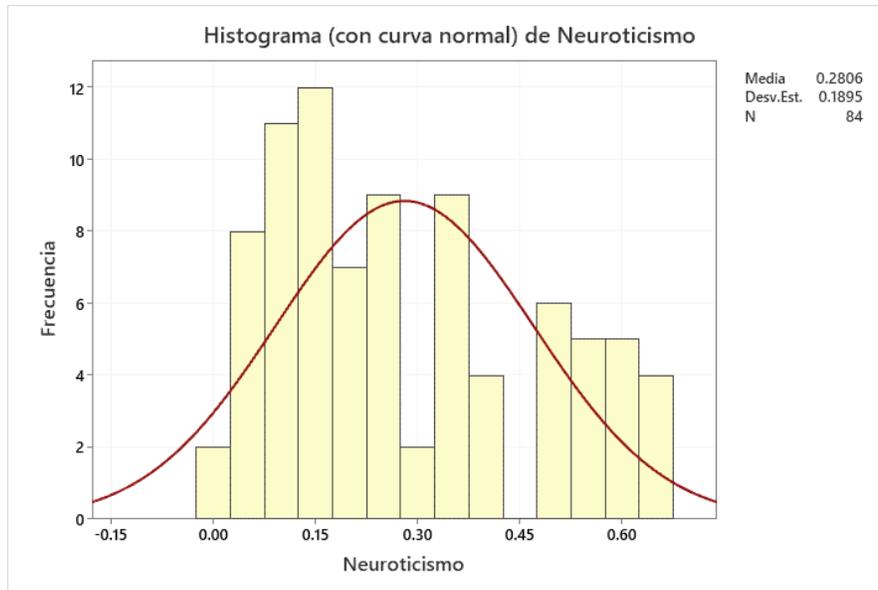


Figura 5-11. Histograma de errores absolutos del atributo de Neuroticismo.

Una característica que surge al realizar el análisis gráfico de los errores absolutos de cada atributo de personalidad es que se puede apreciar la alta dispersión de los datos, situación que confirma la existencia de una brecha importante entre el valor predicho y el valor real.

Capítulo 6

6. Conclusiones y trabajo futuro

En este capítulo se describen las conclusiones de este trabajo de investigación. Se mencionan las aportaciones y limitaciones de la investigación. Así mismo, se define el trabajo futuro que se pretende realizar para fortalecer este proyecto.

6.1. Conclusiones del proyecto

Los resultados obtenidos permiten afirmar, por una parte, que en acuerdo con la hipótesis H2 (un entorno de recolección de datos, referentes a pruebas estandarizadas de personalidad real y grabaciones de videos de los participantes, facilita el mejoramiento de los modelos de reconocimiento automático de personalidad aparente), se pudo corroborar que el contar con una plataforma como la desarrollada, permite una recolección de datos muy sencilla y aplicable a través de cualquier dispositivo para navegar en Internet y, por ende, facilita su análisis y generación de información valiosa para la evaluación de modelos de reconocimiento automático de personalidad aparente.

Los resultados obtenidos con respecto al modelo de reconocimiento automático de personalidad aparente evaluado conducen a rechazar la hipótesis nula H_0 (la precisión de modelos de reconocimiento automático de personalidad aparente basados en técnicas de fusión temprana, y entrenados con base a un conjunto de videos de una base de datos de referencia, se mantendrá al aplicarse en una nueva base de datos de videos obtenidos) y aceptar la hipótesis alternativa H_1 (los resultados de la detección automática de personalidad aparente usando modelos basados en técnicas de fusión temprana, y entrenados con base a un conjunto de videos de una base de datos de referencia, difieren significativamente de los resultados reportados por una prueba estandarizada de personalidad). Lo anterior, al concluir que el modelo entrenado con un conjunto de datos de videos en idioma inglés y etiquetados con base a la apreciación de un tercero, no obtuvo resultados positivos, al aplicarse en videos de personas de habla hispana y usando como etiqueta los resultados de una prueba de personalidad estandarizada realizada por cada individuo participante. En este primer

ejercicio, se encontró que el reconocedor evaluado presenta una brecha importante en los resultados con respecto a la prueba IPIP.

La decisión de optar por un almacenamiento en la nube permite la posibilidad de recolectar información desde cualquier ubicación y apoya la disponibilidad inmediata de los datos recolectados para su análisis. Los servicios de almacenamiento seleccionados permiten garantizar la seguridad de los datos, detalle muy relevante puesto se está trabajando con información y videos de personas.

6.2. Aportaciones y limitaciones

La principal aportación de este trabajo de investigación es el diseño, desarrollo e implementación de una plataforma cuya finalidad es la recolección de datos de pruebas estandarizadas de personalidad y de videos, para manejar información centralizada y disponible, de una manera sencilla, para evaluar distintos reconocedores automáticos de personalidad aparente. Se considera este punto como valioso, ya que la plataforma permite adaptarse a distintos dispositivos y proporciona los niveles de seguridad necesarios para el correcto tratamiento de datos personales.

La construcción de un conjunto de datos de videos y resultados de la prueba de personalidad es también una aportación importante que puede servir como punto de partida para diversos estudios en el futuro.

Como limitación se puede considerar el tiempo reducido para llevar a cabo la investigación, lo cual no permitió recolectar un conjunto más amplio de datos. Se considera que aumentar el tamaño de la muestra permitiría obtener resultados más confiables.

6.3. Trabajo futuro

Como trabajo futuro, se propone continuar aumentando el tamaño de muestras del conjunto de datos recolectados, con la finalidad de crear un *dataset* de videos en español con sus correspondientes etiquetas de los cinco factores de la personalidad que pueda ser utilizado para diversas investigaciones.

Asimismo, se puede explorar la mejora del reconocedor evaluado usando el conjunto de datos recolectado y los resultados de las pruebas del IPIP.

Se sugiere contemplar la evaluación de reconocedores automáticos de personalidad aparente con base en la voz, buscando utilizar modelos del estado del arte pero que han sido entrenados con videos en inglés, y corroborar si los resultados son similares a los de la prueba estandarizada y en su defecto trabajar en el reentrenamiento de dichos modelos, aprovechando el *dataset* que se está formando con videos en español.

Finalmente, se pudieran integrar los reconocedores automáticos mejorados en herramientas como sistemas tutores inteligentes para personalizar la enseñanza con base a la personalidad detectada del participante.

Bibliografía

- 16Personalities*. (2021). Recuperado el 20 de junio de 2021, de <https://www.16personalities.com/>
- Abhang, P., Gawali, B., & Mehrotra, S. (2016). Emotion Recognition. doi:10.1016/B978-0-12-804490-2.00005-1
- Aggarwal, C. C. (2018). *Neural networks and deep learning*. Springer. doi:10.1007/978-3-319-94463-0
- APA. (2021). *Emoción*. En el diccionario en línea de la American Psychological Association. Recuperado el 10 de junio de 2021, de <https://dictionary.apa.org/emotion>
- Babcock, S., Wilson, C., Carducci, B., Nave, C., Fabio, A., Saklofske, D., & Stough, C. (2020). *The Wiley Encyclopedia of Personality and Individual Differences: Personality Processes and Individual* (1ra. ed., Vol. III). John Wiley & Sons Ltd. doi:10.1002/9781119547174.ch186
- Biel, J.-I., & Gatica-Perez, D. (2010). Vlogcast yourself: Nonverbal behavior and attention in social media. *International Conference on Multimodal Interfaces and the Workshop on Machine Learning for Multimodal Interaction (ICMI-MLMI '10)* (págs. Article 50, 1–4). New York, NY, USA: Association for Computing Machinery. doi:10.1145/1891903.1891964
- Biel, J.-I., & Gatica-Perez, D. (2013). The YouTube Lens: Crowdsourced Personality Impressions and Audiovisual Analysis of Vlogs. *IEEE Transactions on Multimedia*, 15(1), 41-55. doi:10.1109/TMM.2012.2225032
- BigfiveTest*. (2021). Recuperado el 23 de junio de 2021, de <https://bigfive-test.com/>
- Butt, A., Arsalan, A., & Majid, M. (2020). Multimodal Personality Trait Recognition Using Wearable Sensors in Response to Public Speaking. *IEEE Sensors Journal*, 20(12), 6532-6541. doi:10.1109/JSEN.2020.2976159
- Cannon, W. (1927). The James-Lange Theory of Emotions: A Critical Examination and an Alternative Theory. *American Journal of Psychology*, 39, 106-124. doi:10.2307/1422695
- Cárdenas López, H. M. (2019). Trabajo de tesis. *Reconocimiento multimodal de emociones orientadas al aprendizaje para tutores inteligentes en ambientes Android*.
- Celiktutan, O., Skordos, S., & Gunes, H. (2017). Multimodal Human-Human-Robot Interactions (MHHRI) Dataset for Studying Personality and Engagement. *IEEE Transactions on Affective Computing*, PP(99). doi:10.1109/TAFFC.2017.2737019
- ChaLearn. (2021). *Portal ChaLearn*. Recuperado el 25 de marzo de 2021, de <http://chalearnlap.cvc.uab.es/>

- Code. (2021). *Visual Studio Code*. Recuperado el 20 de junio de 2021, de <https://code.visualstudio.com/>
- CSS. (2021). *Hojas de estilo en cascada*. Recuperado el 15 de junio de 2021, de <https://developer.mozilla.org/es/docs/Web/CSS>
- Damasio, A. R. (1994). *Descartes Error: Emotion, Reason, and the Human Brain*. New York: Avon Books.
- El-Batal, H., & Darwish, H. (2020). Personality Traits Recognition Through Twitter's Profile Picture. *La Revista Árabe de Investigación en Medios y Comunicación*, 2020, 42-71. doi:10.21608/jkom.2020.120347
- Ertel, W. (2017). *Introduction to artificial intelligence* (Segunda ed.). Springer International Publishing. doi:10.1007/978-3-319-58487-4
- Escalante, H. J., Guyon, I., Escalera, S., Junior, J., Madadi, M., Baró, X., . . . Lier, R. (2017). Design of an explainable machine learning challenge for video interviews. *International Joint Conference on Neural Networks (IJCNN) 2017*, (págs. 3688-3695). doi:10.1109/IJCNN.2017.7966320
- Escalante, H. J., Kaya, H., Salah, A., Escalera, S., Gucluturk, Y., Guclu, U., . . . Lier, R. (2018). Explaining First Impressions: Modeling, Recognizing, and Explaining Apparent Personality from Videos. *IEEE Transactions on Affective Computing, PP*. doi:10.1109/TAFFC.2020.2973984
- Farnadi, G., Sitaraman, G., Sushmita, S., Celli, F., Kosinski, M., Stillwell, D., . . . De Cock, M. (2016). Computational personality recognition in social media. *User Modeling and User-Adapted Interaction*, 26. doi:10.1007/s11257-016-9171-0
- Firestore. (2021). Recuperado el 10 de junio de 2021, de <https://firebase.google.com/?hl=es>
- García Retana, J. Á. (2012). La educación emocional, su importancia en el proceso de aprendizaje. *Educación*, 36(1), 97-109. Obtenido de <https://revistas.ucr.ac.cr/index.php/educacion/article/view/455/9906>
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (Segunda ed.). Canada: O'Reilly Media, Inc.
- Goldberg, L. R. (1992). The development of markers for the Big-Five factor structure. *Psychological Assessment*, 4(1), 26-42. doi:10.1037/1040-3590.4.1.26
- Goldberg, L. R. (1999). A broad-bandwidth, public domain, personality inventory measuring the lower-level facets of several five-factor models. *Personality Psychology in Europe*, 7, 7-28.
- Goldberg, L. R., Johnson, J. A., Eber, H. W., Hogan, R., Ashton, M. C., Cloninger, C. R., & Gough, H. C. (2006). The International Personality Item Pool and the future of public-domain personality measures. *Journal of Research in Personality*, 40, 84-96.

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. Obtenido de <http://www.deeplearningbook.org>
- Gross, M. N., & Cupani, M. (2016). Adaptación de los 100 ítems IPIP para medir los cinco grandes factores. *Revista Mexicana de Psicología*, 33(1), 17-29.
- HTML. (2021). *HTML, Lenguaje de etiquetas de hipertexto*. Recuperado el 15 de junio de 2021, de <https://developer.mozilla.org/es/docs/Web/HTML>
- IPIP. International Personality Item Pool: A Scientific Collaboratory for the Development of Advanced Measures of Personality Traits and Other Individual Differences*. (2021). Recuperado el 03 de Junio de 2021, de <http://ipip.ori.org/>
- Jalote, P. (2008). *A concise introduction to software engineering*. London: Springer. doi:10.1007/978-1-84800-302-6
- JavaScript*. (2021). Recuperado el 15 de junio de 2021, de <https://developer.mozilla.org/es/docs/Web/JavaScript>
- JSON. (2021). *JSON, JavaScript Object Notation*. Recuperado el 15 de junio de 2021, de <https://www.json.org/json-es.html>
- Junior, J., Gucluturk, Y., Perez, M., Guclu, U., Andujar, C., Baró, X., . . . Escalera, S. (2019). First Impressions: A Survey on Vision-based Apparent Personality Trait Analysis. *IEEE Transactions on Affective Computing*, 1-1. doi:10.1109/TAFFC.2019.2930058
- King, D. E. (07 de 2009). Dlib-ml: A Machine Learning Toolkit. *Journal of Machine Learning Research*, 10, 1755-1758. doi:10.1145/1577069.1755843
- Laverdière, O., Gamache, D., Morin, A. J., & Diguier, L. (2020). French adaptation of the Mini-IPIP: A short measure of the Big Five. *European Review of Applied Psychology*, 70, 100512. doi:10.1016/j.erap.2019.100512
- McKeown, G., Valstar, M., Cowie, R., Pantic, M., & Schroder, M. (2012). The SEMAINE Database: Annotated Multimodal Records of Emotionally Colored Conversations between a Person and a Limited Agent. *IEEE Transactions on Affective Computing*, 3(1), 5-17. doi:10.1109/T-AFFC.2011.20
- Merriam-Webster. (2021). *Emoción*. En *diccionario Merriam-Webster.com*. Recuperado el 10 de 06 de 2021, de <https://www.merriam-webster.com/dictionary/emotion>
- Myers, I. B., & Myers, P. B. (1995). *Gifts differing: understanding personality type*. Mountain View, California, USA: Davies-Black Publishing.
- Negnevitsky, M. (2011). *Artificial Intelligence* (Tercera ed.). Pearson.
- Oktaba, H. (2010). *SQUARE: Modelo actualizado de las características de calidad*. Recuperado el 8 de junio de 2021, de <https://sg.com.mx/revista/29/square-caracteristicas-calidad>

- OpenCV. (2021). *Sitio Web de OpenCV*. Obtenido de <https://opencv.org/>
- Openpsychometrics. (2021). Recuperado el 23 de junio de 2021, de <https://openpsychometrics.org/>
- Patterson, J., & Gibson, A. (2017). *Deep learning* (Primera ed.). O'Reilly Media, Inc.
- Pekrun, R. (2008). The Impact of Emotions on Learning and Achievement: Towards a Theory of Cognitive/Motivational Mediator. *Applied Psychology*, 41, 359 - 376. doi:10.1111/j.1464-0597.1992.tb00712.x
- Picard, R. W. (2000). *Affective computing*. The MIT Press.
- Picard, R. W., Vyzas, E., & Healey, J. (2001). Toward machine emotional intelligence: analysis of affective physiological state. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(10), 1175-1191. doi:10.1109/34.954607
- Pizzolli, D., & Strapparava, C. (2019). Personality Traits Recognition in Literary Texts. *Proceedings of the Second Workshop on Storytelling* (págs. 107-111). Association for Computational Linguistics. doi:10.18653/v1/W19-3411
- Ponce-López, V., Chen, B., Olliu, M., Corneanu, C., Clapés, A., Guyon, I., . . . Escalera, S. (10 de 2016). ChaLearn LAP 2016: First Round Challenge on First Impressions - Dataset and Results. *European Conference on Computer Vision*.
- RAE. (2021). Definición de emoción. Recuperado el 18 de junio de 2021, de <https://dle.rae.es/emoci%C3%B3n>
- React. (2021). *Biblioteca React.js*. Recuperado el 15 de junio de 2021, de <https://es.reactjs.org/>
- Restrepo, S. (2019). Emociones, intencionalidad y racionalidad práctica: Un contraste de las teorías de las emociones de William James y Antonio Damasio. *Ideas y Valores*, 68, 13-36. doi:10.15446/ideasyvalores.v68n170.77686
- Sanchez-Cortes, D., Aran, O., Mast, M., & Gatica-Perez, D. (s.f.). A Nonverbal Behavior Approach to Identify Emergent Leaders in Small Groups. *IEEE Transactions on Multimedia*, 14(3), 816–832. doi:10.1109/tmm.2011.2181941
- Seguridad Firebase. (2021). Recuperado el 14 de junio de 2021, de <https://firebase.google.com/support/privacy>
- Stillwell, D., Matz, S., Kosinski, M., & Nave, G. (2017). Psychological targeting as an effective approach to digital mass persuasion. *Proceedings of the National Academy of Sciences of the United States of America*, 114(48), 12714-12719. doi:10.1073/pnas.1710966114
- Subramaniam, A., Patel, V., Mishra, A., Balasubramanian, P., & Mittal, A. (11 de 2016). Bi-modal First Impressions Recognition using Temporally Ordered Deep Audio and Stochastic Visual Features. 337-348. doi:10.1007/978-3-319-49409-8_27

- Suen, H. -Y., Hung, K. -E., & Lin, C. -L. (2019). TensorFlow-based Automatic Personality Recognition Used in Asynchronous Video Interviews. *IEEE Access*, 1-1. doi:10.1109/ACCESS.2019.2902863
- Swamynathan, M. (2017). *Mastering Machine Learning with Python in Six Steps*. doi:10.1007/978-1-4842-2866-1
- Ventura, C., Masip, D., & Lapedriza, À. (2017). Interpreting CNN Models for Apparent Personality Trait Regression. *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW) 2017*, (págs. 1705-1713). Honolulu, HI, USA. doi:10.1109/CVPRW.2017.217
- Vinciarelli, A., & Mohammadi, G. (2014). A Survey of Personality Computing. *IEEE Transactions on Affective Computing*, 5. doi:10.1109/TAFFC.2014.2330816
- Yu, J., Markov, K., & Karpov, A. (2019). Speaking Style Based Apparent Personality Recognition. *Speech and Computer. SPECOM 2019. Lecture Notes in Computer Science. 11658*, págs. 540-548. Springer. doi:10.1007/978-3-030-26061-3_55
- Zatarain Cabada, R., Barrón Estrada, M. L., & Cárdenas López, H. M. (2019). Reconocimiento multimodal de emociones orientadas al aprendizaje. *Research in Computer Science*, 153-165.
- Zatarain Cabada, R., Rodriguez Rangel, H., Barron Estrada, M., & Cardenas Lopez, H. (2020). Hyperparameter optimization in CNN for learning-centered emotion recognition for intelligent tutoring systems. *Soft Computing*, 24, 7593-7602. doi:10.1007/s00500-019-04387-4

Anexos

A. Ítems de la prueba IPIP-50

#	Pregunta	Atributo
1	Soy el alma de la fiesta	(1+)
2	Siento poca preocupación por los demás.	(2-)
3	Siempre estoy preparado.	(3+)
4	Me estreso fácilmente.	(4-)
5	Tengo un rico vocabulario.	(5+)
6	No hablo mucho.	(1-)
7	Me interesa la gente.	(2+)
8	Dejo mis pertenencias por ahí.	(3-)
9	Estoy relajado la mayor parte del tiempo.	(4+)
10	Tengo dificultad para entender ideas abstractas.	(5-)
11	Me siento cómodo con la gente.	(1+)
12	Insulto a la gente.	(2-)
13	Presto atención a los detalles.	(3+)
14	Me preocupo por las cosas.	(4-)
15	Tengo una imaginación vívida.	(5+)
16	Me mantengo en el fondo del escenario.	(1-)
17	Simpatizo con los sentimientos de los demás.	(2+)
18	Hago un desastre de las cosas.	(3-)
19	Rara vez me siento triste.	(4+)
20	No me interesan las ideas abstractas.	(5-)
21	Inicio conversaciones.	(1+)
22	No me interesan los problemas de los demás.	(2-)
23	Hago las tareas de inmediato.	(3+)
24	Me perturban fácilmente.	(4-)
25	Tengo ideas excelentes.	(5+)
26	Tengo poco que decir.	(1-)
27	Tengo un corazón bondadoso.	(2+)
28	A menudo se me olvida poner las cosas en su lugar.	(3-)
29	Me molesto fácilmente.	(4-)
30	No tengo una buena imaginación.	(5-)
31	Hablo con mucha gente diferente en las fiestas.	(1+)
32	No estoy realmente interesado en los demás.	(2-)
33	Me gusta el orden.	(3+)
34	Cambio mucho mi estado de ánimo.	(4-)
35	Soy rápido para entender las cosas.	(5+)
36	No me gusta llamar la atención.	(1-)
37	Tomo tiempo para los demás.	(2+)
38	Evito mis deberes.	(3-)
39	Tengo frecuentes cambios de humor.	(4-)
40	Uso palabras difíciles.	(5+)

#	Pregunta	Atributo
41	No me importa si soy el centro de atención.	(1+)
42	Siento las emociones de los demás.	(2+)
43	Sigo un horario.	(3+)
44	Me irrito con facilidad.	(4-)
45	Paso tiempo reflexionando sobre las cosas.	(5+)
46	Estoy tranquilo con los extraños.	(1-)
47	Hago que la gente se sienta a gusto.	(2+)
48	Soy exigente en mi trabajo.	(3+)
49	A menudo me siento triste.	(4-)
50	Estoy lleno de ideas.	(5+)

La columna atributo identifica el factor al que corresponde el ítem en cuestión (líneas abajo se muestra la tabla de correspondencias) y el signo + o - indica el carácter de la pregunta. Si la pregunta es positiva recibe 1 punto la opción totalmente en desacuerdo; 2 puntos la opción parcialmente en desacuerdo; 3 puntos la opción ni de acuerdo, ni en desacuerdo; 4 puntos la opción parcialmente de acuerdo y finalmente, 5 puntos la opción totalmente de acuerdo. Si la pregunta es negativa se invierten los puntajes.

- 1) E- Extroversión / Sociabilidad
- 2) A- Amabilidad
- 3) C- Responsabilidad
- 4) N- Neuroticismo
- 5) O- Apertura