Asistente virtual para el aula basado en estilos de aprendizaje utilizando herramientas de reconocimiento.

Carlos David Carreño Gomez

Erick Mauricio López Murcia

Universidad Pedagógica Nacional

Facultad De Ciencia Y Tecnología

Departamento Tecnología

Bogotá

2024

Asistente virtual para el aula basado en estilos de aprendizaje utilizando herramientas de reconocimiento.

Carlos David Carreño Gomez

Erick Mauricio López Murcia

Trabajo De Grado Para Optar Al Título De:

Licenciado En Electrónica.

Director:

David Alejandro Martínez Vásquez, Ph.D.

Universidad Pedagógica Nacional

Facultad De Ciencia Y Tecnología

Departamento Tecnología

Bogotá

2024

Agradecimientos

Agradecimientos Carlos Carreño

En primer lugar, quiero expresar mi más sincero agradecimiento a mi familia, quienes han sido mi principal fuente de apoyo y motivación a lo largo de este largo camino.

A mi papá, le agradezco profundamente por su apoyo incondicional durante toda mi carrera. Gracias por brindarme siempre las oportunidades necesarias para poder cumplir este sueño, por confiar en mí y por ser mi mayor impulso en los momentos de incertidumbre. Tu dedicación y amor han sido fundamentales en cada paso que ha dado.

A mi mamá, le doy las gracias por su constante preocupación por mi bienestar. A lo largo de estas noches de arduo trabajo, ha sido el faro que me ha guiado, dándome fuerzas cuando más las necesitaba

A mi hermano, le agradezco por ser mi fuente constante de motivación. Gracias por recordarme siempre que las metas, por más difíciles que parezcan, son alcanzables con esfuerzo y dedicación. Tu apoyo y tus palabras me han dado el aliento necesario para continuar persiguiendo mis sueños, sin importar lo complicado que fueran.

A Erick, quien luchó mano a mano conmigo para que este proyecto alcanzara su éxito. Gracias por su apoyo constante y dedicación en cada aventura de proceso.

A nuestro director, David Martínez, por orientarnos bajo su vasta experiencia y por sus sabios consejos, que permitieron que este proyecto cumpliera con lo soñado.

A mis amigos, por mantener mi motivación alta y por su apoyo incondicional en todo momento.

A mi querido y amado Toty, gracias por estar conmigo en cada una de mis noches de estudio. Tu mirada llena de amor y compañía ha sido un consuelo en los momentos más difíciles. Aunque ya no estés esencialmente, desde el cielo, este logro también es para ti. Siempre estarás en mi corazón y en cada paso que dé.

Finalmente, a Dios, gracias por ser mi guía, por darme la fortaleza, la sabiduría y la paciencia para llegar hasta aquí.

Agradecimientos Erick López.

Quiero comenzar expresando mi más profundo agradecimiento a mis padres, quienes han sido mi principal fuente de apoyo y motivación a lo largo de mi vida. Sin su amor, sacrificio y constante presencia, no habría llegado hasta aquí. Ellos me han enseñado a perseverar, a nunca rendirme y a seguir siempre hacia adelante. Gracias por ser mi pilar en cada etapa de este proceso y por brindarme la confianza y el apoyo incondicional para seguir mis sueños.

A mi compañero de trabajo, Carlos Carreño, mi agradecimiento más sincero. Gracias por aventurarte conmigo en este proyecto de desarrollo e investigación. Tu paciencia y dedicación han sido fundamentales para que pudiéramos avanzar y superar los retos que se presentaron en el camino. Compartir este trabajo contigo ha sido una experiencia increíble, y siempre valoraré la colaboración y el esfuerzo conjunto.

A mi director de trabajo de grado, David Martínez, le agradezco profundamente por su orientación y apoyo durante todo el proceso. Sin sus aportes y consejos, hubiera sido mucho más difícil resolver muchos de los obstáculos que surgieron. Su compromiso con mi formación y con el éxito de este trabajo ha sido clave, y no puedo estar más agradecido por su profesionalismo y su capacidad para guiarme de manera tan efectiva.

A la Universidad Pedagógica Nacional, quiero darle las gracias por brindarme todas las herramientas y conocimientos que hoy me permiten mirar el futuro con esperanza. Gracias por ofrecerme una formación de calidad, por prepararme como licenciado en electrónica comprometido con el desarrollo y bienestar de mis estudiantes. Esta universidad me ha proporcionado las bases para continuar aprendiendo y creciendo, y por ello siempre estaré agradecido.

Finalmente, quiero agradecer a todos mis compañeros y amigos que han estado a mi lado en este camino. Gracias por brindarme una mano cuando más lo necesitaba, por escucharme, apoyarme y compartir tanto los momentos difíciles como los más alegres. Sin su ayuda y su amistad, no estaría aquí, a punto de graduarme. Siempre he creído que somos el promedio de las personas que nos rodean, y por lo que percibo, estoy rodeado de personas increíbles que me han inspirado a seguir adelante y a dar lo mejor de mí.

Tabla de contenido

1 Resumen Ejecutivo 10

2 Justificación 11

3 Problema 12

4 Objetivos 14

4.1 Objetivo general 14

4.2 Objetivos específicos 15

5 Antecedentes 15

5.1 Estilos de Aprendizaje 15

5.1.1 Los estilos de aprendizaje en el desempeño escolar en matemática de los estudiantes de décimo año de educación general básica. 15

5.1.2 Identificación de los estilos de aprendizaje, estrategia para mejorar la formación de docentes en la escuela normal. 15

5.1.3 Estilo de aprendizaje VARK y su influencia en el rendimiento académico de los estudiantes de la carrera de pedagogía de la actividad física y deporte de la universidad técnica de Babahoyo, periodo académico octubre 2023 - marzo 2024 16

5.1.4 Estilos de aprendizaje en estudiantes universitarios: una revisión descriptiva de la literatura 16

5.2 Reconocimiento emocional en la educación 17

5.2.1 Modelo de Experiencia Afectiva de Usuario (UAX) 18

5.2.2 Rol de las Emociones en el Aprendizaje Diario 18

5.2.3 Perspectiva Interdisciplinaria: Neurociencia Afectiva en la Educación 19

5.3 Asistentes virtuales en la educación 20

5.3.1 Asistentes Virtuales en el Contexto Educativo 20

5.3.2 Asistentes Virtuales y Estilos de Aprendizaje 21

5.3.3 Avances en el Diseño de Ambientes Virtuales de Aprendizaje 22

6 Marco Conceptual 24
6.1 Asistente virtual 24
6.2 Estilos de aprendizaje 25
6.2.1 Test CHAEA 25
6.2.1.1 Estilo Activo 25
6.2.2 Test VARK 26
6.3 Orientaciones curriculares 27
6.3.1 Orientaciones curriculares para el área de tecnología e informática 28
6.3.2 Orientaciones curriculares aplicadas en AVREA 28
6.4 Desarrollo del asistente virtual 29
6.4.1 Framework de Desarrollo Django 29
6.5 Machine learning en el reconocimiento de emociones 30
6.5.1 Definición e Importancia del Reconocimiento de Emociones 31
6.6 Métodos de Detección de Emociones 32
6.6.1 Conceptos Básicos de Visión por Computadora 32
6.6.2 Detección de Rostros 32
6.6.3 Preprocesamiento de Imágenes 34
6.7 Redes Neuronales Convolucionales (CNNs) 35
6.8 Integración del Modelo en Tiempo Real 36
6.8.1 Uso de OpenCV para Captura y Procesamiento de Video 36
6.9 Herramientas y Bibliotecas Utilizadas 38
6.9.1 Keras y TensorFlow 38
6.9.2 OpenCV 38
6.9.3 Pandas 39
7 Desarrollo Metodológico 40

7.1 Exploración y selección de los modelos de estilos de aprendizaje..... 41
7.2 Adaptación del cuestionario CHAEA a la interfaz de AVREA 43
7.3 Adaptación del cuestionario VARK a la interfaz de AVREA..... 45
7.4 Diseño y desarrollo de actividades escolares según el estilo de aprendizaje de los estudiantes. 48
7.4.1 Actividad Teórica 49
7.4.2 Actividad Reflexiva 50
7.4.3 Actividad Activa 51
7.4.4 Actividad Pragmática 52
7.4.5 Actividad Visual 53
7.4.6 Actividad Auditiva 54
7.4.7 Actividad Lector/Escritor 55
7.4.8 Actividad Kinestésica 56
7.4.9 Actividad Sin Contexto 57
7.5 Reconocimiento de emociones 58
7.5.1 Entrenamiento del modelo (model.py) 59
7.5.2 Ejecución del Modelo para Reconocimiento en Tiempo Real (testCode.py)... 63
7.6 Interfaz del asistente. 67
7.6.1 Back-End con Python 67
7.6.2 Interfaz con HTML, CSS y JavaScript 68
7.6.3 Base de datos y autenticación 68
7.6.4 Estructura de la interfaz en AVREA 68
7.6.5 Diagrama de caso de uso 71
7.7 Pruebas de AVREA 72
8 Resultados Obtenidos 75

8.1 Estilos de aprendizaje de cada estudiante 75
8.2 Estilos de aprendizaje y emociones 77
9 Análisis De Los Resultados 82
9.1 Análisis de resultados: Estilos de aprendizaje 82
9.1.1 Distribución de Estilos CHAEA 83
9.1.2 Distribución de Estilos VARK 83
9.2 Análisis de Resultados: Estilos de Aprendizaje y Emociones 83
9.2.1 Emociones Predominantes 84
9.2.2 Patrones por Actividad y Estilo de Aprendizaje 84
9.2.3 Resultados por actividad 84
9.2.4 Emociones grupales según su estilo de aprendizaje 86
10 Conclusiones 87
10.1 Conclusión General 89
11 Trabajos futuros 89
12 REFERENCIAS 91
13 Anexos 96
13.1 Anexo 1 96

Tabla de ilustraciones

1. Ilustración 1: ubicaciones de 34 puntos fiduciales: tomado de (Bashyal & Venayagamoorthy, 2008) 33
2. Ilustración 2:Descripción general del sistema de reconocimiento de expresiones faciales: tomada de (Bashyal & Venayagamoorthy, 2008) 34
3. Ilustración 3: Diagrama de metodología en cascada 41
4. Ilustración 4: Vista principal de AVREA 43
5. Ilustración 5: Vista principal de AVREA: 44
6. Ilustración 6: Resultados Test CHAEA 45

7. Ilustración 7: Test CHAEA 45
8. Ilustración 8: Contextualización Cuestionario VARK 46
9. Ilustración 9: Test VARK ..... **¡Error! Marcador no definido.**
10. Ilustración 10: Resultado test CHAEA y VARK 47
11. Ilustración 11: Resultados Test CHAEA y VARK simplificado 48
12. Ilustración 12: Actividad Teórica 49
13. Ilustración 13: Actividad Reflexiva 50
14. Ilustración 14: Actividad Activo. 51
15. Ilustración 15: Actividad Pragmática 53
16. Ilustración 16: Actividad Visual 54
17. Ilustración 17: Actividad Auditiva 55
18. Ilustración 18: Actividad Lector/Escritor 56
19. Ilustración 19: Actividad Kinestésica 57
20. Ilustración 20: Actividad Sin Contexto 58
21. Ilustración 21:Muestra de imágenes correspondientes a la clase 'Happy' utilizadas en el entrenamiento del modelo 60
22. Ilustración 22:Muestra de imágenes correspondientes a la clase 'Happy' utilizadas en la validación del modelo 60
23. Ilustración 23: Diagrama de Flujo del Proceso de Entrenamiento del Modelo de Reconocimiento de Emociones 63
24. Ilustración 24: Diagrama de flujo del sistema de reconocimiento de emociones 66
25. Ilustración 25: Arquitectura de una Aplicación en Django. Tomado de GeeksforGeeks (2023) 67
26. Ilustración 26:Actividad Pragmática con Reconocimiento de Emociones en Tiempo Real 70
27. Ilustración 27: Vista final 71
28. Ilustración 28: Caso de uso de AVREA 72
29. Ilustración 29: Grafica frecuencia estilos de aprendizaje 77
30. Ilustración 30: Vista resumida del Anexo 1, organización de las emociones según la actividad por usuario 78
31. Ilustración 31: Grafica Emociones Actividad Uno 79

32. Ilustración 32: Grafica de emociones - Actividad Dos (VARK)..... 79
33. Ilustración 33: Grafica de emociones - Actividad Tres..... 80
34. Ilustración 34: Grafica de emociones del grupo a lo largo de las tres actividades..... 81
35. Ilustración 35: Emociones grupales según los estilos de aprendizaje 82

1 Resumen Ejecutivo

El objetivo principal del proyecto fue desarrollar un asistente virtual llamado AVREA (Asistente Virtual para el Reconocimiento de Estilos de Aprendizaje), basado en herramientas de reconocimiento como apoyo a los docentes en la orientación de los estudiantes de básica primaria según su estilo de aprendizaje. La introducción de este asistente virtual fue una propuesta que pretendía mejorar el proceso educativo de cada estudiante adaptándose a sus estilos de aprendizaje de forma personalizada. A través de este proyecto se investigó las características de las actividades escolares en función del estilo de aprendizaje de los estudiantes, utilizando como base teórica los estilos de aprendizaje teórico, activo, reflexivo y pragmático planteados por Honey y Alonso (1994), al igual que lo estilos visual, auditivo, lector/escrito y kinestésico. Desarrollados por Neil Fleming y Colleen Mills (1992).

Las herramientas de reconocimiento utilizadas fueron el cuestionario CHAEA (Cuestionario Honey y Alonso de Estilos de Aprendizaje) y el cuestionario VARK (Visual, Aural, Read/Write and Kinesthetic). El primero contiene 80 preguntas, mientras que el segundo incluye 16 preguntas de selección múltiple orientadas para reconocer las características y preferencias del estudiante. Además, se integró un sistema de reconocimiento facial de emociones utilizando machine learning, que identifica la emoción del estudiante en tiempo real, clasificando las expresiones faciales en categorías como feliz, neutral, triste, enojado o sorprendido, permitiendo un monitoreo inmediato del comportamiento de alumno al interactuar con el asistente.

A partir de lo anterior, se desarrolló una base de datos en Django utilizando Python para almacenar datos como el nombre, curso, edad, estilos de aprendizaje y emociones del estudiante luego de haber interactuado con la interfaz gráfica del asistente. Esta interfaz,

desarrollada mediante programación en JavaScript, CSS y HTML, brinda una experiencia interactiva al usuario al proporcionarle dos actividades específicas sobre tecnología según su estilo de aprendizaje, además de una neutral luego de haber completado el cuestionario CHAEA y VARK en el asistente.

Como resultado, se logró identificar los estilos de aprendizaje de estudiantes de grado quinto, encontrando patrones en sus preferencias de acuerdo con las teorías planteadas. Además, se implementó un monitoreo de las emociones de cada alumno, observando expresiones gestuales neutrales cuando el estudiante está concentrado y expresiones alegres al completar las actividades satisfactoriamente. También se identificó la posibilidad de reconocer una emoción adicional, correspondiente al aburrimiento, en los casos en que el estudiante muestra signos de agotamiento.

Esta investigación no solo permite comprender mejor los estilos de aprendizaje, sino que también ofrece a los docentes herramientas para adaptar sus métodos de enseñanza a las necesidades específicas de cada estudiante. Al identificar las preferencias de aprendizaje y las emociones, como la concentración o el aburrimiento, los educadores pueden intervenir de forma pertinente para mejorar tanto el rendimiento académico como el bienestar emocional de los alumnos. Generando una enseñanza más personalizada y un ambiente de aprendizaje que apoya a los estudiantes de manera íntegra.

2 Justificación

La integración de las TIC en la actividad docente se ha convertido en una demanda social y una necesidad fundamental en el entorno educativo, tanto para el profesorado como para la administración educativa. Pérez, Villalonga, Guillén y Baños (2020) afirman que el uso de herramientas tecnológicas no solo constituye un derecho para los estudiantes, sino que también facilita una enseñanza más inclusiva y adaptada a los diversos estilos de aprendizaje.

La implementación de asistentes virtuales en el aula surge como una propuesta innovadora para enfrentar los desafíos de la educación personalizada. El uso de un asistente virtual diseñado específicamente para identificar y adaptarse a los estilos de aprendizaje de cada estudiante permite que los docentes personalicen el aprendizaje de forma más eficiente,

especialmente en aulas numerosas. Esto es consistente con la investigación de Cabero y Marín (2019), quienes subrayan que las TIC pueden mejorar el aprendizaje al adaptarse a las características individuales de cada alumno, promoviendo una experiencia de aprendizaje más significativa y efectiva.

A través de este proyecto, se examinó las características de actividades escolares alineadas con los estilos de aprendizaje de los estudiantes. Para ello, el asistente virtual aplicó pruebas de diagnóstico, como el CHAEA (Honey, P. y Mumford, A., 1994) y el VARK (Fleming y Mills, 1992), para determinar el estilo de aprendizaje de cada estudiante. Además, se ha incorporado un sistema de reconocimiento facial de emociones, el cual identifica el estado emocional del estudiante en tiempo real. Esto permite ajustar la metodología de enseñanza según el compromiso y las emociones del estudiante, maximizando así la efectividad del aprendizaje personalizado.

El sistema de reconocimiento y orientación del asistente se basa en investigaciones actuales sobre la personalización del aprendizaje, y busca ofrecer una visión integral de cada estudiante al incluir aspectos cognitivos y emocionales. Esta combinación permite un apoyo más preciso a los docentes, quienes pueden concentrarse en aquellos estudiantes que necesitan atención individualizada mientras el asistente ofrece recomendaciones personalizadas. La expectativa es que esta tecnología fomente un entorno educativo más motivador y efectivo, mejorando tanto la comprensión como el rendimiento académico de los estudiantes.

Finalmente, el impacto de este proyecto fue evaluado mediante una recopilación de datos sobre la satisfacción y el rendimiento de los estudiantes. Se espera que el asistente virtual funcione como una herramienta que no solo optimice la enseñanza en términos de efectividad, sino que también fortalezca el compromiso y la motivación de los estudiantes hacia el aprendizaje.

3 Problema

El desafío que enfrentan los docentes en el aula es grande, especialmente cuando se trata de atender las necesidades de aprendizaje individuales de cada estudiante. Alonso (1994) considera que “los profesores deben reconocer las diferencias individuales de sus alumnos para personalizar su educación tratando de que sus preferencias en cuanto a los estilos de enseñanza no influyan en los estilos de aprendizaje de los alumnos”. Este es un tema de preocupación constante para los educadores, ya que cada estudiante tiene diferentes formas y ritmos de aprendizaje. En este sentido, los docentes deben encontrar maneras de reconocer y responder a estas necesidades sin comprometer la calidad de la enseñanza y el rendimiento académico del grupo.

Además, el alto número de estudiantes en el aula es uno de los principales obstáculos que los docentes enfrentan en el proceso de enseñanza. Estudios como el Proyecto STAR (Student/Teacher Achievement Ratio) en Tennessee, muestran que el tamaño de las clases tiene un impacto significativo en el rendimiento académico. Este proyecto encontró que las clases más pequeñas permiten a los docentes brindar una atención más personalizada, lo cual mejora el desempeño de los estudiantes y facilita un ambiente de aprendizaje más efectivo (Finn & Achilles, 1999). Esto también disminuye el tiempo que los docentes deben destinar a gestionar el comportamiento en el aula, permitiéndoles concentrarse en la instrucción y en atender las necesidades individuales de los estudiantes (Bethel University Online).

Cada estudiante tiene un estilo de aprendizaje preferido, lo cual representa otro reto significativo en el aula. Algunos aprenden mejor mediante la lectura, otros mediante la práctica o la observación. La identificación de estos estilos y su incorporación en la enseñanza sería ideal para mejorar la efectividad del aprendizaje, pero en aulas grandes esto es difícil de lograr, y los estudiantes pueden perderse en el proceso.

En este contexto, se requiere una estrategia que permita atender las necesidades de aprendizaje de manera personalizada, sin comprometer la calidad de la enseñanza. Una de estas estrategias es el uso de asistentes virtuales que se apoyan en tecnologías de reconocimiento para personalizar el aprendizaje. Estos asistentes virtuales pueden adaptarse a cada estudiante, basándose en su estilo de aprendizaje, y, además, reconocer las emociones del estudiante, lo cual es crucial para evaluar el impacto de las actividades y ajustarlas en tiempo real.

AVREA es el asistente virtual desarrollado en este proyecto, la solución propuesta para este problema. Implementado en un proyecto en Django, este asistente guía a los estudiantes en un recorrido de aprendizaje personalizado. Inicialmente, el estudiante realiza dos pruebas: el cuestionario CHAEA de Honey y Alonso y la prueba VARK de Fleming y Mills, que identifican el estilo de aprendizaje (teórico, activo, reflexivo y pragmático para CHAEA. Y, visual, auditivo, lector-escritor y kinestésico para VARK). Posteriormente, el asistente asigna tres actividades personalizadas: la primera orientada según el resultado de la prueba CHAEA, la segunda de acuerdo con el resultado de la prueba VARK, y la tercera, una actividad general.

Además de la personalización en base a los estilos de aprendizaje, el asistente incluye una herramienta de reconocimiento facial de emociones que evalúa el estado emocional del estudiante en tiempo real (feliz, neutral, triste, enojado o sorprendido) mientras realiza cada actividad. Esto permite al docente ajustar la orientación y el nivel de dificultad de las actividades según el nivel de satisfacción del estudiante. Este enfoque basado en el reconocimiento tanto de estilo de aprendizaje como de emoción permite una experiencia de aprendizaje más dinámica y centrada en el estudiante.

La pregunta de investigación planteada es: ¿Cómo podemos desarrollar un asistente virtual que proporcione recomendaciones y orientación personalizada de actividades según el estilo de aprendizaje de cada estudiante?

Este trabajo busca, entonces, evaluar el impacto de un asistente virtual en el aula que ofrece recomendaciones personalizadas, y si esto puede ayudar a superar las limitaciones de la enseñanza tradicional en aulas numerosas y con diversidad de estilos de aprendizaje.

4 Objetivos

4.1 Objetivo general

Desarrollar un asistente virtual basado en herramientas de reconocimiento como apoyo a los docentes en la orientación de los estudiantes de básica primaria según su estilo de aprendizaje.

4.2 Objetivos específicos

- Explorar las características de actividades escolares según el estilo de aprendizaje de los estudiantes.
- Diseñar un sistema de reconocimiento de los estudiantes para orientarlo en actividades que favorezcan su estilo de aprendizaje.
- Evaluar el sistema de reconocimiento para proyectar su uso según el estilo de aprendizaje de los estudiantes.

5 Antecedentes

5.1 Estilos de Aprendizaje

5.1.1 Los estilos de aprendizaje en el desempeño escolar en matemática de los estudiantes de décimo año de educación general básica.

Los estilos de aprendizaje han sido un campo de estudio fundamental en la educación, no solo en los niveles básicos de primaria y secundaria, sino también en la educación media y superior. Esto es especialmente relevante en áreas como la matemática, donde su influencia en el rendimiento académico es notable. Esto se evidencia en el trabajo "Los estilos de aprendizaje en el desempeño escolar en matemática de los estudiantes de décimo año de educación general básica" desarrollado por Vera Briones (2018), en el que se identifica el bajo rendimiento académico en matemáticas, en parte por el desconocimiento de los estilos de aprendizaje. Para ello, desarrollaron un software en Visual Basic que utiliza el cuestionario de Honey y Alonso para identificar dichos estilos y orientar la planificación educativa, mejorando las estrategias pedagógicas del docente basadas en las características de sus estudiantes.

5.1.2 Identificación de los estilos de aprendizaje, estrategia para mejorar la formación de docentes en la escuela normal.

Además del área de matemáticas, en el Benemérito Instituto Normal del Estado (BINE) de Puebla, México, al mando de Murrieta Ortega, R. (2021) se llevó a cabo en 2021 un estudio para identificar los estilos de aprendizaje de 69 estudiantes de primer semestre de

la Licenciatura en Enseñanza y Aprendizaje en Telesecundaria utilizando el cuestionario CHAEA. Los resultados revelaron una preferencia mayoritaria por el estilo de aprendizaje activo, seguido por el pragmático, teórico y reflexivo. Estos hallazgos fueron clave para orientar la planificación educativa, permitiendo a los docentes desarrollar estrategias más personalizadas para cada estudiante. El estudio demuestra que, en la educación superior, los estilos de aprendizaje influyen de manera significativa en el desarrollo académico de los estudiantes en diversas carreras.

5.1.3 Estilo de aprendizaje VARK y su influencia en el rendimiento académico de los estudiantes de la carrera de pedagogía de la actividad física y deporte de la universidad técnica de Babahoyo, periodo académico octubre 2023 - marzo 2024

Por otro lado, la reciente investigación de Calderón y Rosales, A. (2024) en la carrera de Pedagogía de la Actividad Física y Deporte utilizando el modelo VARK revela que existe una gran diversidad en las preferencias de estilos de aprendizaje de los estudiantes. A partir de estos hallazgos, los autores proponen estrategias específicas, como el uso de material gráfico para los estudiantes visuales, aprendizaje en grupo para los auditivos, toma de apuntes y participación en foros para los lectores/escritores, y pruebas activas para los cinestésicos.

5.1.4 Estilos de aprendizaje en estudiantes universitarios: una revisión descriptiva de la literatura

Sin embargo, los estilos de aprendizaje, además de manifestarse en carreras pedagógicas, también están involucrados en el campo de la salud. En una investigación realizada por Cira, P., Quispe-Paiva, M., Carhuas, I. y Ríos, C. (2021), titulada “Estilos de aprendizaje en estudiantes universitarios: una revisión descriptiva de la literatura”, se emplearon tres cuestionarios de estilos de aprendizaje: CHAEA, VARK y el inventario de Kolb, aplicados a estudiantes de ciencias de la salud, medicina y ciencias sociales. Los resultados mostraron que, con el uso del cuestionario CHAEA, los estudiantes de ciencias de la salud presentaron una preferencia predominante por el estilo de aprendizaje reflexivo. En

cuanto al inventario de Kolb, el estilo convergente fue el más común entre los estudiantes de medicina, observándose también que el género femenino tendía a inclinarse hacia el estilo divergente. Finalmente, con el cuestionario VARK, la mayoría de los estudiantes de ciencias sociales mostraron una preferencia por un estilo de aprendizaje que combina diferentes enfoques

5.2 Reconocimiento emocional en la educación

El reconocimiento emocional en el ámbito educativo ha emergido como un campo de estudio crucial, no solo para mejorar la enseñanza personalizada, sino también para optimizar el aprendizaje de los estudiantes y promover un ambiente de apoyo emocional. Este enfoque, cada vez más presente en investigaciones pedagógicas, plantea preguntas esenciales: ¿Cómo impactan las emociones en el rendimiento académico? ¿Hasta qué punto la identificación de emociones puede ayudar a adaptar la enseñanza?

En este contexto, la literatura revisada brinda una visión integral y detallada sobre la relevancia del análisis emocional en las aulas. "El análisis emocional", que abarca desde el uso de tecnologías avanzadas como el reconocimiento facial hasta innovaciones en biometría y machine learning, puede ser un aliado poderoso para entender mejor el comportamiento y el estado emocional de los estudiantes. Estas tecnologías permiten identificar emociones clave (como la alegría, el estar neutral, la sorpresa o el enojo) en tiempo real; y, a partir de esa información, los docentes pueden ajustar su metodología para satisfacer las necesidades de cada estudiante.

Además, el reconocimiento emocional va más allá de la simple identificación de expresiones faciales. Esta práctica permite crear una retroalimentación constante en el aula, estableciendo relaciones significativas entre la respuesta emocional de los estudiantes y su progreso académico. Por ejemplo, un estudiante que muestra "frustración" durante una lección de matemáticas puede requerir una explicación adicional o una actividad práctica que le permita abordar la materia desde otro ángulo.

El análisis emocional, mediante tecnologías como el reconocimiento facial y métodos biométricos, no solo facilita una comprensión más profunda del estado anímico de los

estudiantes, sino que abre una ventana hacia una enseñanza verdaderamente personalizada, en la que cada emoción cuenta y contribuye a un aprendizaje más efectivo y significativo.

5.2.1 Modelo de Experiencia Afectiva de Usuario (UAX)

En primer lugar, el artículo de Torres-Carrión et al. (2017) presenta el modelo de Experiencia Afectiva de Usuario (UAX), que se enfoca en la computación afectiva y su aplicación en entornos de aula gamificada. Este modelo utiliza sensores biométricos para captar datos fisiológicos de los estudiantes, lo que permite identificar su estado emocional en tiempo real. La implementación de UAX en aulas gamificadas demuestra cómo la gamificación, junto con la interacción gestual, puede influir positivamente en el estado emocional de los alumnos. El estudio destaca que, al adaptar los recursos didácticos en función de las variaciones emocionales, se puede mejorar significativamente la atención y el compromiso de los estudiantes en el proceso de aprendizaje. Esto subraya la importancia de conocer las emociones de los alumnos para facilitar un entorno de aprendizaje más efectivo y atractivo (Torres-Carrión et al., 2017).

5.2.2 Rol de las Emociones en el Aprendizaje Diario

Continuando con esta temática, Iglesias Torres (2018) propone una reflexión profunda sobre la presencia de las emociones a lo largo de la jornada escolar. Este trabajo enfatiza la necesidad de implementar métodos de análisis emocional, como el reconocimiento facial, para captar el estado emocional de los estudiantes durante las actividades educativas. La autora argumenta que el reconocimiento emocional no solo puede mejorar la personalización de la enseñanza, sino que también es fundamental para comprender cómo las emociones influyen en el aprendizaje diario. Según Iglesias Torres (2018), al identificar y responder a las emociones de los estudiantes, los docentes pueden ajustar sus métodos de enseñanza en tiempo real, lo que resulta en una experiencia de aprendizaje más inclusiva y adaptativa. Además, este enfoque permite anticipar y mitigar posibles barreras emocionales que podrían interferir con el rendimiento académico, promoviendo así un ambiente educativo más saludable y productivo.

5.2.3 Perspectiva Interdisciplinaria: Neurociencia Afectiva en la Educación

Finalmente, Herrera Torres y Buitrago Bonilla (2019) amplían la discusión al abordar las emociones en la educación desde una perspectiva interdisciplinaria que incluye el análisis facial y la neurociencia afectiva. Este artículo resalta la obra de Paul Ekman en el estudio de las emociones universales y su relevancia para la educación, proporcionando una base sólida para el reconocimiento de patrones emocionales en el aula. Además, se menciona la teoría del perfil emocional del cerebro de Richard Davidson, que añade una dimensión neurocientífica al entendimiento de cómo las variaciones en el perfil emocional individual pueden influir en la receptividad de los estudiantes frente a diferentes estilos de enseñanza. El estudio también destaca programas educativos como PATHS (Promoting Alternative Thinking Strategies), que son efectivos para promover el bienestar emocional de los estudiantes, reforzando así la idea de que el reconocimiento emocional es fundamental para el desarrollo integral de los alumnos (Herrera Torres & Buitrago Bonilla, 2019). Esta perspectiva interdisciplinaria subraya la importancia de integrar conocimientos de neurociencia y psicología en el diseño de estrategias educativas que respondan de manera efectiva a las necesidades emocionales de los estudiantes.

la revisión de estos estudios revela un consenso sobre la importancia del reconocimiento emocional y su potencial para transformar la educación. La investigación evidencia que el análisis emocional no solo permite adaptar el contenido a las necesidades emocionales de los estudiantes, sino que también contribuye a su bienestar general y al desarrollo de competencias socioemocionales. Estos enfoques promueven una educación más personalizada y efectiva, justificando así la necesidad de seguir investigando en este ámbito para desarrollar y optimizar prácticas educativas que beneficien integralmente a los estudiantes. La integración de tecnologías de reconocimiento emocional en el aula no solo apoya la personalización del aprendizaje, sino que también fomenta un entorno educativo más motivador y receptivo, alineándose con los objetivos de mejorar la comprensión y el rendimiento académico de los alumnos.

5.3 Asistentes virtuales en la educación

Los asistentes virtuales han ganado un lugar significativo en la vida cotidiana, simplificando tareas, organizando información y proporcionando acceso rápido a datos. Su avance se ha fundamentado en las tecnologías de la industria 4.0, donde la inteligencia artificial (IA) permite mejorar la interacción entre humanos y máquinas, posibilitando experiencias de usuario más naturales. MÁH Figueroa, RGV Báez y JOC Rangel (2020) exploran esta interacción en el contexto de asistentes virtuales y destacan cómo la IA mejora la comprensión y respuesta a las necesidades humanas, logrando una interacción efectiva con un uso óptimo de recursos tecnológicos.

En este ámbito, Corvalán, Gómez y Arrua (2022) desarrollaron un sistema de automatización con dos placas Raspberry Pi: una para el almacenamiento y procesamiento de información facial, y otra para el funcionamiento del asistente virtual en entornos domésticos. Este sistema, compatible con iOS y Android, emplea software libre y programación en Python, logrando un 99,99% de efectividad en reconocimiento facial con un tiempo de procesamiento de 11,78 segundos. Este estudio demuestra la viabilidad de integrar reconocimiento facial en sistemas de control domótico de bajo costo y alta confiabilidad, lo cual puede extenderse a aplicaciones educativas y de interacción en el hogar.

Del mismo modo, Navas Ten (2020) presenta dos enfoques de reconocimiento facial sin considerar la profundidad del rostro: el primero se enfoca en la reducción de datos mediante el análisis de los elementos principales del rostro, y el segundo emplea redes neuronales profundas tipo convolucionales. El segundo método obtuvo un 98,9% de precisión en pruebas de clasificación de rostros, superando al primer método que alcanzó un 96% de efectividad. Estos resultados sugieren que, aunque ambos métodos son viables, el uso de redes neuronales profundas puede mejorar significativamente la precisión en el reconocimiento facial, lo cual resulta prometedor para el desarrollo de asistentes educativos personalizados que identifiquen y adapten la enseñanza a los estudiantes.

5.3.1 Asistentes Virtuales en el Contexto Educativo

En educación, los asistentes virtuales han demostrado potencial para mejorar el aprendizaje. Aguilar Mejía (2022) desarrolló un chatbot educativo enfocado en física básica

para estudiantes universitarios de primer año. Este asistente abordaba conceptos teóricos y leyes de Newton, logrando que 63 de 126 estudiantes de ingeniería reportaran una mejora significativa en su comprensión de los temas abordados, medida mediante evaluaciones cuantitativas. Esto refleja el impacto positivo que los asistentes virtuales pueden tener en el entendimiento de materias complejas.

De igual manera, Manjarrez y Echeverri (2020) implementaron un asistente virtual para apoyar a los estudiantes del Politécnico Colombiano Jaime Isaza Cadavid en tareas académicas, sin necesidad de supervisión humana. Este asistente permitió a los estudiantes optimizar su experiencia académica al reducir tiempos en procesos administrativos y académicos, demostrando el valor de estos sistemas en instituciones de educación superior.

En niveles escolares, Casos, Romero y Cieza (2022) desarrollaron un asistente virtual para mejorar el aprendizaje de anatomía en estudiantes de quinto y sexto grado. Empleando la metodología Mobile-D, que incluye etapas de exploración, producción y pruebas, lograron un incremento en el interés y comprensión de la anatomía entre los estudiantes. Esto se reflejó en una mayor búsqueda de información sobre el cuerpo humano y un aumento en el rendimiento académico, evidenciando que los asistentes virtuales pueden ser un recurso eficaz en la educación básica.

5.3.2 Asistentes Virtuales y Estilos de Aprendizaje

La diversidad en los estilos de aprendizaje de los estudiantes plantea desafíos en la enseñanza, especialmente en áreas complejas. Campaña, Castro, Guerrero y Hernández (2018) desarrollaron un software educativo para la enseñanza de conceptos geométricos en matemáticas, promoviendo un aprendizaje significativo a través del uso de "Dr. Geo y Kig". El software ayudó a los estudiantes a entender construcciones geométricas y motivó a los profesores a utilizar las TIC, mejorando así el proceso pedagógico.

En el contexto de la educación a distancia, donde la interacción directa es limitada, Sobrevilla (2021) diseñó un asistente virtual que actúa como tutor y selecciona objetos de aprendizaje basados en los estilos y características de cada estudiante. Este asistente ayuda a mitigar el desapego en la educación remota, al brindar soporte y orientación personalizada.

Por otro lado, Gil Vera (2021) desarrolló una metodología para prever el rendimiento académico en cursos virtuales. Su enfoque considera variables académicas y personales, construyendo una base de datos y modelos de predicción que muestran alta precisión. Este tipo de metodología puede contribuir al desarrollo de asistentes virtuales que no solo brinden apoyo educativo, sino que también identifiquen factores que afectan el rendimiento estudiantil, permitiendo una intervención oportuna.

5.3.3 Avances en el Diseño de Ambientes Virtuales de Aprendizaje

La evolución de los ambientes virtuales de aprendizaje (AVA) ha transformado significativamente las prácticas educativas en los últimos años, ofreciendo nuevas oportunidades y desafíos para educadores y estudiantes. A medida que estas plataformas se vuelven más accesibles y sofisticadas, su capacidad para impactar el aprendizaje se incrementa, respaldada por una variedad de investigaciones que destacan tanto los beneficios como las áreas de mejora de los AVA.

Peralta Caballero y Díaz Barriga (2010) subrayan la importancia de las interacciones comunicativas dentro de estos entornos, argumentando que el aprendizaje mediado por tecnología no se trata solo de un acceso a contenidos digitales, sino de cómo se facilitan y guían los procesos de comunicación y colaboración entre los estudiantes y el docente. Para ellos, un diseño psicopedagógico adecuado es crucial, ya que permite la construcción de experiencias de aprendizaje más efectivas y adaptadas a las necesidades de los estudiantes, promoviendo la autonomía y el pensamiento crítico a través de la interacción estructurada.

En el ámbito de la educación superior, Castro (2013) analiza el rol de las tecnologías de la información y la comunicación (TIC) y su capacidad para mejorar el compromiso de los estudiantes, así como para desarrollar habilidades transversales que son esenciales en el entorno actual. Castro sostiene que el aprendizaje se ve fortalecido cuando se construye en contextos relevantes, donde los errores son interpretados como valiosas oportunidades pedagógicas para la reflexión y la mejora continua. Este enfoque fomenta una cultura de aprendizaje continuo, en la que los estudiantes pueden aplicar sus conocimientos en situaciones prácticas y relevantes.

Por otro lado, Parra Robledo (2017) observa que los ambientes virtuales de aprendizaje colaborativo no solo contribuyen a la motivación de los estudiantes, sino que también son esenciales para desarrollar competencias digitales clave. Estos entornos permiten que los estudiantes interactúen y colaboren, fortaleciendo así habilidades de trabajo en equipo y competencias tecnológicas que serán valiosas en el ámbito profesional. Además, las dinámicas colaborativas en AVA fomentan el pensamiento crítico y la resolución de problemas, habilidades cada vez más demandadas en la sociedad digital.

En cuanto al uso de tecnologías emergentes en el aprendizaje, Sanz et al. (2017) presentan la Teoría Cognitiva del Aprendizaje Multimedia, que se centra en cómo el uso de herramientas visuales y auditivas en los AVA puede mejorar la comprensión y retención de información. Argumentan que tecnologías como la realidad aumentada pueden enriquecer el proceso de enseñanza, proporcionando una experiencia inmersiva que facilita la asimilación de conceptos complejos. Este enfoque promueve el aprendizaje multisensorial y permite a los estudiantes interactuar con los contenidos de manera dinámica, aumentando su interés y motivación por el aprendizaje.

En el campo de la inteligencia artificial (IA) aplicada a la educación, Saz-Pérez y Pizà-Mir (2024) investigan el uso de la IA generativa, como ChatGPT, en el aula. Aunque esta tecnología ofrece beneficios significativos, tales como la personalización de los contenidos y la asistencia en tiempo real, los autores también subrayan los desafíos éticos que plantea su implementación. Entre ellos se encuentran cuestiones como la privacidad de los datos de los estudiantes y el riesgo de dependencia excesiva en estos sistemas. Saz-Pérez y Pizà-Mir (2024) enfatizan la necesidad de desarrollar estrategias pedagógicas personalizadas y un marco ético que regule el uso de la IA en el contexto educativo.

Finalmente, la investigación en asistentes virtuales y el uso de tecnologías como el reconocimiento facial muestra un amplio campo de aplicaciones que podrían transformar el aprendizaje. Estos avances tecnológicos ofrecen la posibilidad de personalizar el proceso educativo y de hacer que el aprendizaje sea más inclusivo y adaptado a las necesidades individuales de cada estudiante. Sin embargo, es fundamental un enfoque consciente y responsable en su integración, que considere tanto el diseño pedagógico como la diversidad de estilos de aprendizaje, para asegurar que estas herramientas se utilicen de manera ética y en beneficio del desarrollo integral del estudiante.

6 Marco Conceptual

6.1 Asistente virtual

Un asistente virtual es un programa de software inteligente basado en tecnologías de inteligencia artificial y procesamiento del lenguaje natural. Está diseñado para interactuar de manera conversacional con los usuarios y brindar asistencia en diversas tareas y consultas. Los asistentes virtuales tienen la capacidad de comprender y responder a las solicitudes de los usuarios de forma contextualmente relevante, proporcionando información, realizando acciones y ofreciendo recomendaciones. Microsoft (2020).

Los asistentes virtuales representan una innovación tecnológica que ha transformado radicalmente la manera en que interactuamos con la información y llevamos a cabo nuestras actividades diarias. Desde su concepción inicial hasta su desarrollo actual, estos programas informáticos han evolucionado significativamente para satisfacer las crecientes demandas de los usuarios en el mundo moderno. Según Accom (2024), un asistente virtual se define como un "programa informático diseñado para facilitar el trabajo y la vida general de los usuarios, a través de la respuesta a sus preguntas y la realización de tareas concretas". Esta definición encapsula la esencia de estos agentes virtuales, cuya función principal es simplificar y mejorar la experiencia del usuario a través de la automatización de tareas y la provisión de información o servicios.

La importancia de los asistentes virtuales en la vida contemporánea es evidente en su amplia gama de aplicaciones y su capacidad para mejorar la eficiencia y la productividad en diferentes contextos. Tal como señala Sánchez (2024), estos programas son herramientas valiosas que contribuyen significativamente a la gestión del tiempo, la atención al cliente, la automatización de tareas, la investigación y análisis de datos, así como la integración con otros sistemas. Esta versatilidad los convierte en aliados indispensables tanto en entornos laborales como en el ámbito personal, donde su presencia se ha vuelto cada vez más habitual.

En el ámbito educativo, los asistentes virtuales han comenzado a desempeñar un papel importante en el proceso de enseñanza y aprendizaje. Como señala Blanco (2023), estos programas pueden ayudar a los estudiantes a adquirir habilidades básicas, como lectura y matemáticas, al proporcionar una herramienta de administración alternativa y facilitar la

ejecución de elementos clave de cursos en línea. Además, ofrecen la ventaja de ofrecer aprendizaje personalizado, adaptándose al ritmo del estudiante y a sus áreas de interés o dificultad (T2ó, 2021). Esta capacidad de adaptación y personalización es esencial para abordar las diversas necesidades de los estudiantes y maximizar su potencial de aprendizaje.

Por lo tanto, los asistentes virtuales representan una herramienta fundamental en la era digital, que ha revolucionado la forma en que interactuamos con la tecnología y llevamos a cabo nuestras actividades diarias. Su capacidad para mejorar la eficiencia, proporcionar asistencia personalizada y facilitar la realización de tareas cotidianas los posiciona como recursos indispensables en una amplia variedad de contextos, incluido el entorno educativo.

6.2 Estilos de aprendizaje

Cada persona tiene una manera única de aprender, conocida como estilo o preferencia de aprendizaje, que le permite procesar la información de forma más efectiva y adaptada a sus características individuales. Diversos modelos teóricos intentan explicar estos estilos de aprendizaje, los cuales se forman a partir de la combinación de preferencias individuales del estudiante y las estrategias que los docentes implementan en sus prácticas de enseñanza. Estos enfoques permiten adaptar los métodos educativos para mejorar el proceso de aprendizaje y asegurar que la enseñanza responda a las necesidades y fortalezas de cada estudiante (Perlado Lamo de Espinosa, Barroso Tristán, & Trujillo Vargas, 2023).

6.2.1 Test CHAEA

Los estilos de aprendizaje son definidos como los rasgos cognitivos, afectivos y fisiológicos que sirven como indicadores relativamente estables de cómo los alumnos perciben, interactúan y responden a sus ambientes de aprendizaje (Honey, P., & Mumford, A., 1994). Mediante esto, las categorías de estilos de aprendizaje son:

6.2.1.1 Estilo Activo

Las personas con un estilo de aprendizaje activo se involucran sin prejuicios en nuevas experiencias. Son abiertos y entusiastas ante nuevas tareas, les gusta vivir el presente,

y se sienten motivadas por la novedad y los desafíos, buscando constantemente nuevas actividades (Honey, P., & Mumford, A., 1994).

6.2.1.2 Estilo Reflexivo

A quienes poseen un estilo reflexivo les agrada observar las experiencias desde diversas perspectivas. Recolectan y analizan datos antes de llegar a conclusiones y prefieren considerar todas las alternativas antes de actuar, observando cuidadosamente la actuación de los demás (Honey, P., & Mumford, A., 1994).

6.2.1.3 Estilo Teórico

Las personas de estilo teórico a integrar las observaciones en teorías complejas y lógicas. Buscan la perfección y abordan los problemas de manera sistemática, valorando la coherencia y evitando la subjetividad y la ambigüedad (Honey, P., & Mumford, A., 1994).

6.2.1.4 Estilo Pragmático

Los pragmáticos se caracterizan por su enfoque en la aplicación práctica de las ideas. Tienden a actuar con rapidez ya experimentar con proyectos nuevos, adoptando una actitud enfocada en la efectividad y la mejora continua (Honey, P., & Mumford, A., 1994).

6.2.2 Test VARK

Los estilos de aprendizaje se definen como las tendencias cognitivas, afectivas y fisiológicas que actúan como indicadores estables de cómo los estudiantes perciben, procesan e interactúan con su entorno de aprendizaje (Fleming & Mills, 1992). En este contexto, el modelo VARK categoriza los estilos de aprendizaje en cuatro modalidades específicas:

6.2.2.1 Estilo Visual

Los estudiantes con un estilo visual prefieren la información presentada a través de gráficos, diagramas y otros recursos visuales. Este estilo favorece el uso de representaciones gráficas para organizar y recordar información de manera estructurada. Según Fleming y Mills (1992), estos aprendices se benefician significativamente al ver representaciones visuales que facilitan la comprensión del contenido.

6.2.2.2 Estilo Auditivo

Los aprendices auditivos tienden a captar mejor la información cuando la reciben de manera oral. Este estilo se basa en la escucha activa, como conferencias y discusiones, lo que facilita la retención de conceptos. Fleming y Mills (1992) destacan que estos estudiantes comprenden mejor cuando la información es verbalizada.

6.2.2.3 Estilo Lector/Escritor

Este estilo está dirigido a aquellos estudiantes que aprenden de manera más efectiva cuando interactúan con materiales escritos. La lectura y la escritura sobre el contenido les permite comprender mejor y organizar sus pensamientos. Según Fleming y Mills (1992), este estilo de aprendizaje enfatiza la importancia de los textos y las notas escritas en el proceso educativo.

6.2.2.4 Estilo Kinestésico

Los estudiantes kinestésicos prefieren aprender a través de la experiencia directa y la acción. Este estilo está relacionado con la participación en actividades prácticas, lo que permite a los estudiantes aprender mediante la experimentación y el movimiento. Fleming y Mills (1992) afirman que estos estudiantes absorben la información de manera más eficaz cuando pueden interactuar mutuamente con el contenido.

6.3 Orientaciones curriculares

Las Orientaciones Curriculares son guías fundamentales que mejoran la calidad pedagógica en las áreas clave y obligatorias de la educación preescolar, básica y media. Su objetivo principal es fortalecer los fundamentos de estas áreas mediante su conexión con otros documentos y la respuesta a las tendencias educativas actuales y las necesidades de los estudiantes. Abordan el desarrollo integral de los estudiantes, promoviendo un proceso educativo sistémico, sostenible, inclusivo y transformador, que a su vez contribuye a la formación de los docentes y asegura los derechos de la población escolar (Ministerio de Educación Nacional, 2022).

6.3.1 Orientaciones curriculares para el área de tecnología e informática

Las Orientaciones Curriculares para el área de tecnología e informática en educación básica y media, presentadas por el Ministerio de Educación Nacional en 2022, buscan fomentar el desarrollo de competencias tecnológicas e informáticas entre los estudiantes del país. Estas orientaciones suceden a la Guía No 30 de 2008 y se elaboraron a través de un proceso participativo que involucró a actores clave de diferentes regiones, con base en una exhaustiva revisión de fuentes nacionales e internacionales. Este nuevo marco busca actualizar y adaptar los conceptos relacionados con la tecnología, la informática y las TIC, así como mejorar la organización curricular, las estrategias didácticas y la evaluación, para optimizar los aprendizajes de los estudiantes en un contexto educativo cambiante. (Ministerio de Educación Nacional, 2022).

6.3.2 Orientaciones curriculares aplicadas en AVREA

En el desarrollo de las actividades tecnológicas para estudiantes de primaria básica, se han tenido en cuenta las directrices establecidas en las orientaciones curriculares para el área de tecnología, proporcionadas por el Ministerio de Educación Nacional (2022). Estas orientaciones incluyen componentes, competencias y evidencias de aprendizaje. En el caso de AVREA, se seleccionan las siguientes orientaciones para guiar el diseño de las actividades:

Componente: Uso y apropiación de la Tecnología e Informática (T&I).

Competencia: Aprovecho las potencialidades de algunos productos tecnológicos en la realización de actividades en diversos contextos.

Evidencia de aprendizaje:

- Clasifico artefactos existentes en mi entorno con base en características tales como materiales, forma, estructura, función, entre otras.
- Utilizo tecnologías de la información y la comunicación disponibles en mi entorno para el desarrollo de diversas actividades.
- Aprovecho contenidos, herramientas y dispositivos digitales en el desarrollo de estrategias de comunicación para el aprendizaje y desarrollo personal.

- Utilizo las funcionalidades, utilidades y características de algunos productos tecnológicos en mis actividades diarias.

6.4 Desarrollo del asistente virtual

6.4.1 Framework de Desarrollo Django

Django es un framework avanzado para el desarrollo web basado en Python, que prioriza la rapidez en la creación de aplicaciones, así como la simplicidad y eficiencia en su diseño. Esta estructura, creada por desarrolladores expertos, facilita el proceso al gestionar aspectos complejos del desarrollo, lo que permite a los programadores centrarse en la construcción de aplicaciones sin tener que reinventar soluciones ya existentes. Además, al ser de código abierto y gratuito, Django es accesible y flexible, lo que lo convierte en una opción ideal para una amplia variedad de proyectos que realizamos. (Django Software Foundation, s.f.).

6.4.1.1 Modelos

Los modelos en Django son responsables de definir la estructura de la base de datos de una aplicación. Permiten la creación de tablas y relaciones entre datos a través de clases que definen los campos y comportamientos de los datos. Django proporciona un sistema ORM (Object-Relational MapPoint) que facilita la interacción con la base de datos de manera eficiente (Django Software Foundation, s.f.).

6.4.1.2 Vistas

Una vista, o función de vista, es una función en Python que recibe una solicitud web y envía una respuesta web como resultado. Esta respuesta puede ser el contenido HTML de una página, una redirección, un error 404, un documento XML, una imagen, entre otras cosas. La función de vista puede incluir cualquier lógica necesaria para generar dicha respuesta. El código que la implementa puede ubicarse en cualquier lugar dentro de su ruta de Python, sin requisitos adicionales. Sin embargo, por convención, se coloca el código de las vistas en un

archivo llamado views.py, dentro de su proyecto o directorio de aplicación. (Django Software Foundation, s.f.).

6.4.1.3 Plantillas y administración

Los templates o plantillas en Django son archivos que definen la estructura HTML de la interfaz de usuario. Se utilizan para separar la lógica de presentación de la aplicación, permitiendo que los desarrolladores puedan crear páginas web dinámicas que muestran información proveniente de la base de datos o de otros recursos (Django Software Foundation, s.f.).

Por su parte, El admin de Django es una interfaz de administración que permite gestionar el contenido de una aplicación web de manera sencilla. Se genera automáticamente a partir de los modelos, ofreciendo una interfaz visual para crear, editar y eliminar datos de la base de datos sin necesidad de escribir código adicional (Django Software Foundation, s.f.).

6.5 Machine learning en el reconocimiento de emociones

La inteligencia artificial (IA) está evolucionando a pasos agigantados, y dentro de este avance, la combinación del aprendizaje automático y el reconocimiento de emociones está ganando cada vez más protagonismo. Esta área de estudio busca que las máquinas no solo realicen tareas complejas, sino que también puedan “entender” cómo nos sentimos, permitiendo una interacción más cercana y personalizada entre humanos y computadoras.

Imagínate una aplicación que pueda detectar si alguien está triste o estresado solo por su tono de voz o por la expresión en su rostro. Esto ya no es solo ciencia ficción. Al usar algoritmos de aprendizaje automático, las computadoras pueden identificar patrones en nuestras expresiones, movimientos, y hasta en la forma en que escribimos, para interpretar emociones como alegría, tristeza, frustración, entre otras. El objetivo no es reemplazar la empatía humana, sino mejorar la experiencia de uso de la tecnología para que esta se adapte a nuestras emociones, haciéndonos sentir comprendidos y acompañados.

Las aplicaciones de esta tecnología son prometedoras: desde asistentes virtuales más "empáticos" hasta herramientas de apoyo en salud mental y plataformas de educación personalizadas que ajusten sus respuestas según el estado emocional del usuario. Sin embargo, este avance plantea preguntas importantes: ¿Cómo podemos asegurar que esta tecnología entienda bien las emociones sin malinterpretarlas? ¿Y cómo garantizamos que se respete la privacidad de los usuarios?

Estos son algunos de los desafíos que surgen, y resolverlos es clave para que el reconocimiento emocional en IA sea realmente beneficioso. Se está trabajando en métodos cada vez más avanzados para mejorar la precisión de los algoritmos y en regulaciones que protejan a los usuarios. Al final, el propósito es que las máquinas no solo realicen tareas, sino que interactúen con nosotros de una manera más humana y que nos brinde una experiencia enriquecedora

6.5.1 Definición e Importancia del Reconocimiento de Emociones

El reconocimiento de emociones es un área de la inteligencia artificial que se enfoca en identificar y analizar los estados emocionales de las personas a través de señales como el habla, las expresiones faciales y otros indicadores fisiológicos. Esta tecnología, desarrollada mediante técnicas avanzadas de aprendizaje automático, ha ganado atención debido a su capacidad para mejorar la interacción entre humanos y máquinas, adaptándose al estado emocional del usuario y proporcionando una experiencia más cercana y personalizada.

Distintos enfoques en el aprendizaje automático, como las redes neuronales recurrentes (RNN) y convolucionales (CNN) como la que se utiliza para crear AVREA, han mostrado resultados prometedores en la clasificación de emociones, especialmente a través de la voz, logrando altos niveles de precisión (Kumar, M.S et al., 2023). Estas técnicas han sido exploradas para identificar emociones como el interés y el aburrimiento en contextos educativos, permitiendo que los sistemas monitoreen el estado emocional de los estudiantes y optimicen el aprendizaje al adaptarse a sus necesidades emocionales (Villegas-Ch. W et al., 2023).

La detección emocional es especialmente relevante en el ámbito de la computación afectiva, donde se buscan métodos de reconocimiento más completos y contextuales, como

el seguimiento ocular, para interpretar las emociones y aplicarlas en áreas como la salud, la educación y el neuromarketing (Zheng Lim et al., 2020).

La investigación en esta área, por lo tanto, no solo destaca los avances técnicos, sino también el potencial del reconocimiento de emociones para transformar la manera en que las máquinas interactúan con los seres humanos, permitiendo un entendimiento más profundo de los estados emocionales y mejorando la calidad de los servicios en diversas áreas.

6.6 Métodos de Detección de Emociones

6.6.1 Conceptos Básicos de Visión por Computadora

La visión por computadora es fundamental en el reconocimiento de emociones, ya que permite analizar y clasificar expresiones faciales mediante técnicas avanzadas de aprendizaje profundo. Entre estos métodos, destacan las redes neuronales convolucionales (CNNs) por su capacidad para procesar imágenes y extraer características faciales importantes. Estas redes permiten analizar patrones espaciales y temporales, lo cual es esencial para identificar emociones en expresiones faciales de manera precisa (Li & Deng, 2020). A medida que los modelos de aprendizaje profundo se optimizan, sus aplicaciones en áreas como salud, educación y servicios al cliente también se diversifican, incrementando su relevancia en la interacción humano-computadora (Déniz, Bueno, Salido, & De la Torre, 2011).

6.6.2 Detección de Rostros

La detección de rostros es el primer paso crítico en el reconocimiento de emociones y se centra en identificar y localizar áreas faciales en imágenes o videos. Este proceso implica el uso de técnicas como la detección de características faciales clave (ojos, nariz, boca) a través de métodos basados en CNNs y la extracción de "landmarks" o puntos específicos del rostro (Ilustración 1). Estas técnicas mejoran la capacidad del sistema para analizar expresiones faciales en diversas posiciones y condiciones de iluminación, optimizando la precisión del reconocimiento de emociones (Bashyal & Venayagamoorthy, 2008). Además, los métodos de histograma de gradientes orientados (HOG) y transformadas de Fourier proporcionan alineación y homogeneidad en los datos de entrada, lo que facilita la extracción confiable de las características necesarias para clasificar emociones (Déniz et al., 2011).

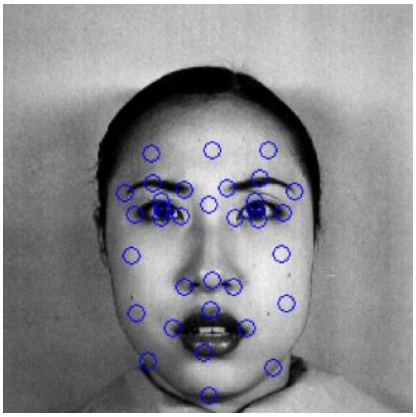

Ilustración 1: ubicaciones de 34 puntos fiduciales: tomado de (Bashyal & Venayagamoorthy, 2008)

Para ilustrar el flujo de trabajo en un sistema de reconocimiento de emociones basado en visión por computadora, podemos imaginar el proceso dividido en varias etapas, representadas como bloques (como se muestra en la ilustración 2). En primer lugar, la cámara detecta el rostro en una imagen o video, identificando y localizando las áreas faciales clave. Este primer paso, llamado detección de rostros, es crucial y permite reconocer zonas como los ojos, la nariz y la boca. A través de técnicas avanzadas como redes neuronales convolucionales (CNN) y la extracción de "landmarks" o puntos específicos del rostro, se aumenta la precisión del sistema para capturar expresiones faciales en diversas condiciones, como diferentes ángulos e iluminación (Bashyal & Venayagamoorthy, 2008).

Una vez que se detecta el rostro, la imagen pasa a un bloque de procesamiento de imagen, donde se realizan ajustes para mejorar su calidad. Aquí se aplican técnicas como el histograma de gradientes orientados (HOG) y transformadas de Fourier, que facilitan una alineación y homogeneidad en los datos de entrada (Déniz et al., 2011). Este paso permite estandarizar la imagen para asegurar que las siguientes fases reciban una entrada uniforme y libre de ruidos, optimizando la precisión de todo el sistema.

El siguiente bloque es el de extracción de características (feature extraction), en el que se seleccionan y extraen las características clave del rostro, tales como la forma de los ojos o las curvas de la boca. Estas características son cruciales para diferenciar entre diferentes emociones. Finalmente, la información extraída se envía al bloque de clasificación, donde se aplican algoritmos que determinan la emoción específica entre categorías como

neutral, happy (felicidad), sad (tristeza), surprise (sorpresa), angry (enojo), disgust (disgusto) y fear (miedo).

Este flujo, desde la detección inicial hasta la clasificación final, asegura que el sistema de reconocimiento de emociones no solo identifique rostros, sino que también analice y clasifique las emociones con precisión en tiempo real.

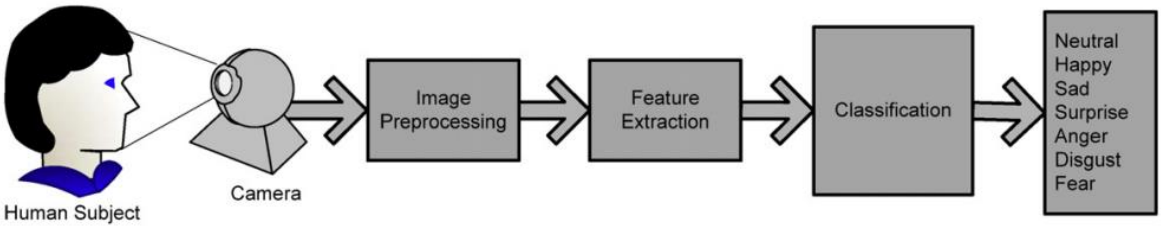

Ilustración 2:Descripción general del sistema de reconocimiento de expresiones faciales: tomada de (Bashyal & Venayagamoorthy, 2008)

6.6.3 Preprocesamiento de Imágenes

El preprocesamiento de imágenes es una fase fundamental en los sistemas de reconocimiento de emociones, ya que tiene como objetivo preparar las imágenes de entrada para que sean adecuadas y consistentes, permitiendo al modelo realizar un análisis más preciso. Este proceso incluye varios pasos críticos, tales como la normalización de las intensidades de los píxeles, el ajuste de la escala y la eliminación del ruido visual. La normalización ajusta las intensidades de los píxeles de las imágenes, asegurando que todos los valores de entrada se encuentren en un rango similar, lo que facilita que las redes neuronales convolucionales (CNNs) aprendan de manera más eficiente. Por otro lado, el ajuste de la escala asegura que todas las imágenes se presenten con el mismo tamaño, lo que es crucial para la coherencia en los procesos de análisis. La eliminación del ruido visual, como el desenfoque o los artefactos innecesarios, mejora la calidad de las imágenes y hace que el sistema sea más robusto a cambios inesperados en el entorno (Sariyanidi, Gunes, & Cavallero, 2015).

Además de estos pasos básicos, el preprocesamiento también incluye técnicas avanzadas que optimizan la capacidad del modelo para generalizar ante diferentes

condiciones externas, como la variabilidad en la iluminación, la posición o el fondo. El desafío de las variaciones en la iluminación y en el contexto es significativo, ya que las emociones pueden ser difíciles de reconocer cuando las condiciones del entorno cambian. En este sentido, el preprocesamiento garantiza que las imágenes sean lo más uniformes posible antes de ser procesadas por el sistema de clasificación, lo cual aumenta la fiabilidad del sistema en aplicaciones prácticas. Por ejemplo, un modelo de reconocimiento de emociones bien preprocesado será más efectivo incluso en entornos con iluminación deficiente o fondos distractores, mejorando la precisión general de la clasificación (Déniz et al., 2011).

Así, el preprocesamiento no solo prepara las imágenes para el análisis, sino que también fortalece la capacidad del sistema para identificar emociones de manera precisa y consistente, independientemente de las variaciones que puedan ocurrir en el mundo real. Este proceso asegura que los modelos sean más robustos, eficientes y aplicables a escenarios del mundo real, lo que es crucial para el rendimiento en aplicaciones de reconocimiento de emociones.

6.7 Redes Neuronales Convolucionales (CNNs)

Las redes neuronales convolucionales (CNN) son modelos avanzados de aprendizaje automático especialmente diseñados para extraer características de datos estructurados en cuadrículas, como imágenes y vídeos. Esto las hace especialmente adecuadas para tareas de reconocimiento de patrones, ya que pueden identificar y clasificar características relevantes en los datos de entrada. Según Jiang y Zavala (2021), las CNN emplean operaciones de convolución, donde se aplican operadores específicos sobre los datos de entrada. Estos operadores actúan como filtros que resaltan ciertas características visuales, como bordes, texturas y patrones específicos, mejorando la capacidad del modelo para captar aspectos distintivos en las imágenes.

La aplicabilidad de las CNN va más allá del procesamiento de imágenes; pueden manejar datos estructurados en cuadrículas de otros tipos, lo que permite emplearlas en campos tan diversos como la predicción de series temporales, el análisis de voz y otras áreas que utilizan datos con estructura reticular. Este tipo de flexibilidad ha permitido que las CNN se extiendan a muchas aplicaciones diferentes. Por ejemplo, Izquierdo-Valladarez y Cuenca-

Tapia (2020) destacan el uso de CNN en el desarrollo de sistemas de reconocimiento de objetos para personas con discapacidad visual, una aplicación que ilustra cómo estas redes pueden mejorar la vida diaria y promover la accesibilidad. Quiroga (2020) también describe la utilización de CNN en la clasificación de formas de la mano, mostrando cómo pueden reconocer e interpretar detalles sutiles en los datos.

El proceso de entrenamiento de las CNN se basa en la optimización de los operadores de convolución, que se afinan a lo largo de varias iteraciones para minimizar el error entre las predicciones del modelo y los resultados esperados. Este entrenamiento incluye varias etapas, tales como la recolección de datos, el procesamiento de imágenes, el entrenamiento del modelo y su posterior validación para asegurar su precisión y generalización en nuevas tareas (Izquierdo-Valladarez & Cuenca-Tapia, 2020). Durante la recolección y procesamiento de datos, las imágenes se preparan para ser consistentes y de alta calidad, lo que facilita la extracción de características precisas por parte de la red.

Además, existen diversas arquitecturas de CNN que se han optimizado para diferentes tareas y que han mostrado excelentes resultados. Algunas de las arquitecturas más conocidas son VGG16D, ResNet e Inception, cada una de ellas diseñada para abordar desafíos específicos en la clasificación de imágenes (Quiroga, 2020). Por ejemplo, ResNet es particularmente efectiva en problemas de clasificación de imágenes complejas, debido a su capacidad para manejar redes más profundas sin caer en problemas de degradación de precisión, mientras que Inception incorpora múltiples filtros de diferentes tamaños en cada capa, mejorando la capacidad de la red para capturar características a distintas escalas.

6.8 Integración del Modelo en Tiempo Real

6.8.1 Uso de OpenCV para Captura y Procesamiento de Video

El uso de OpenCV para la captura y el procesamiento de video en tiempo real ha revolucionado múltiples aplicaciones, especialmente en el campo de la detección de objetos y el reconocimiento facial. Este software permite implementar sistemas capaces de analizar imágenes y videos en tiempo real de manera eficiente, lo cual es esencial para aplicaciones como la vigilancia, las interfaces hombre-máquina y la realidad aumentada. Un ejemplo notable es el algoritmo Viola-Jones, un método ampliamente usado dentro de OpenCV para

la detección de rostros. Este algoritmo escanea imágenes en escala de grises para localizar patrones específicos asociados con rostros humanos y es extremadamente rápido, ya que se basa en la identificación de características como los bordes y texturas faciales (Entrena S & Javier R, 2012).

Además, OpenCV se destaca no solo en plataformas de escritorio sino también en plataformas móviles. En una implementación en dispositivos Android, OpenCV mostró ventajas significativas en términos de velocidad de procesamiento y ahorro energético al compararse con una implementación personalizada, lo que ilustra su potencial para el desarrollo de aplicaciones en dispositivos móviles (Saipullah, K. 2012). Esta flexibilidad y eficiencia en dispositivos con recursos limitados hace que OpenCV sea una herramienta ideal para aplicaciones móviles que requieren análisis de video en tiempo real, como los sistemas de seguridad doméstica o el control de acceso a través de la identificación facial.

Cuando se requiere una detección de objetos más avanzada, OpenCV se puede integrar con marcos de aprendizaje profundo como Caffe. Este enfoque expande las capacidades de OpenCV permitiendo no solo la detección de rostros, sino también la identificación, localización y clasificación de una variedad de objetos en tiempo real. Este proceso, que combina OpenCV y Caffe, utiliza redes neuronales profundas para reconocer categorías complejas de objetos en imágenes y videos, mejorando así la precisión y adaptabilidad en aplicaciones de visión artificial (Vaishali & Singh, 2019). Por ejemplo, en el caso de una webcam que analiza la escena en tiempo real, el modelo entrenado en Caffe puede identificar varios objetos, como personas, vehículos y señales, proporcionando una categorización inmediata para cada elemento en la imagen.

Estas capacidades de OpenCV no solo facilitan la creación de sistemas de reconocimiento de emociones en tiempo real, sino que también pueden implementarse en sectores como la seguridad y la interacción humano-máquina. La rapidez en la detección y clasificación permite que los sistemas puedan responder en tiempo real a diversos estímulos visuales, posibilitando un amplio rango de aplicaciones, desde aplicaciones de seguridad en el hogar hasta dispositivos de asistencia para personas con discapacidad visual.

6.9 Herramientas y Bibliotecas Utilizadas

6.9.1 Keras y TensorFlow

Keras y TensorFlow son bibliotecas fundamentales en el desarrollo de modelos de aprendizaje profundo. TensorFlow, desarrollado por Google Brain, es una biblioteca de código abierto que permite crear y entrenar modelos de redes neuronales a gran escala con una gran capacidad de personalización, lo cual es esencial en aplicaciones que requieren precisión, como el reconocimiento de emociones en imágenes y video (Abadi et al., 2016). TensorFlow maneja grandes volúmenes de datos y facilita el cálculo de operaciones matemáticas complejas a través de la GPU y la CPU, optimizando el rendimiento en el entrenamiento de modelos complejos (Martínez et al., 2020). Esta biblioteca se destaca por su flexibilidad y soporte para una amplia variedad de arquitecturas de redes neuronales, lo que permite ajustar y escalar modelos según las necesidades del proyecto.

Keras, por otro lado, es una API de alto nivel para redes neuronales construida sobre Tensor Flow, diseñada para simplificar el desarrollo de modelos de aprendizaje profundo. La integración de Keras con TensorFlow permite a los desarrolladores experimentar con distintas arquitecturas de redes neuronales de manera sencilla, proporcionando un entorno accesible y eficiente para quienes buscan crear prototipos rápidamente sin sacrificar potencia computacional (Chollet, 2015). Keras permite a los usuarios trabajar con una sintaxis simplificada, lo que reduce la complejidad en la implementación de modelos complejos, siendo útil tanto para investigadores como para desarrolladores en la creación de modelos de clasificación de imágenes y secuencias de video en tiempo real (Brownlee, 2019).

6.9.2 OpenCV

OpenCV (Open Source Computer Vision Library) es una biblioteca de código abierto ampliamente utilizada en aplicaciones de visión artificial y procesamiento de imágenes. Diseñada inicialmente por Intel, OpenCV se ha convertido en una herramienta esencial para el desarrollo de sistemas de detección y reconocimiento visual en tiempo real debido a su velocidad y eficiencia. Entre sus aplicaciones destacan la detección de rostros, la segmentación de objetos y la extracción de características, funciones críticas en el análisis de

video para el reconocimiento de emociones (Bradski & Kaehler, 2008). OpenCV permite el procesamiento de imágenes en diferentes plataformas, incluidas las móviles, proporcionando herramientas para realizar ajustes en imágenes, como el cambio de escala, la conversión de color y la eliminación de ruido (Pulli, 2012).

Esta biblioteca también es compatible con algoritmos avanzados de aprendizaje profundo cuando se combina con marcos como TensorFlow, permitiendo la detección de patrones complejos en imágenes y videos. Por ejemplo, el algoritmo de Viola-Jones, implementado en OpenCV, es uno de los métodos más populares para la detección de rostros en tiempo real, utilizado en diversas aplicaciones de seguridad y entretenimiento (Viola & Jones, 2001). La integración de OpenCV con otros marcos de aprendizaje profundo lo convierte en una herramienta robusta y adaptable a múltiples entornos, desde la investigación hasta aplicaciones comerciales.

6.9.3 Pandas

Pandas es una biblioteca de Python especializada en la manipulación y análisis de datos, y es especialmente útil en el manejo de grandes volúmenes de datos estructurados, como los generados en el procesamiento de imágenes para el reconocimiento de emociones. Con su capacidad para gestionar estructuras de datos como DataFrames y Series, Pandas facilita la organización, limpieza y transformación de datos antes de pasarlos a los modelos de aprendizaje automático (McKinney, 2010). Esta biblioteca permite realizar operaciones de agregación, filtrado y ordenamiento de datos de forma eficiente, lo cual es crucial en proyectos donde se requiere un preprocesamiento intensivo de los datos de entrada, como en el reconocimiento facial y la clasificación de emociones.

Pandas es esencial para la fase de preparación de datos, ya que permite la normalización de los datos y la extracción de características necesarias para el entrenamiento de redes neuronales. Además, su capacidad para integrarse con otras bibliotecas de Python como NumPy y SciPy, así como con herramientas de visualización como Matplotlib y Seaborn, hace que Pandas sea una herramienta completa para el análisis exploratorio de datos (Wes McKinney, 2017). En el contexto del reconocimiento de emociones, Pandas permite gestionar grandes cantidades de datos etiquetados, facilitando la supervisión de los datos de

entrenamiento y ayudando a los investigadores a preparar datos estructurados para modelos de aprendizaje profundo de manera efectiva.

7 Desarrollo Metodológico

La metodología empleada en este trabajo de grado se fundamentó en el modelo en cascada, una estrategia que organiza las actividades en etapas secuenciales para garantizar un desarrollo estructurado y eficiente. Como punto de partida, se realizó la exploración y selección de los modelos teóricos CHAEA y VARK, herramientas esenciales para identificar los estilos de aprendizaje de los estudiantes. A continuación, se adaptaron estos cuestionarios a la interfaz de AVREA, integrándolos de manera efectiva al sistema.

En la siguiente etapa, se diseñaron actividades escolares personalizadas para cada estilo de aprendizaje identificado, asegurando que el contenido fuera pertinente y efectivo. Además, se desarrolló un modelo de reconocimiento de emociones en tiempo real, lo que añadió una dimensión interactiva y emocional al asistente virtual. Para implementar la interfaz del asistente, se utilizaron tecnologías como Python, HTML, CSS, JavaScript y una base de datos para la gestión de usuarios, garantizando una experiencia funcional y segura.

El proceso concluyó con pruebas exhaustivas para validar la funcionalidad del sistema, lo que permitió evaluar su efectividad. Los resultados obtenidos evidenciaron la distribución de los estilos de aprendizaje y su relación con las emociones detectadas, ofreciendo una base sólida para el análisis y las conclusiones del trabajo.

La Ilustración 3 (Diagrama de metodología en cascada) ofrece una representación gráfica del desarrollo metodológico, destacando las actividades realizadas en el modelo en cascada. En el gráfico, cada actividad se identifica por un color que señala su relación con uno de los objetivos específicos. Además, el orden en el que se presentan las actividades refleja fielmente la secuencia seguida durante el desarrollo del proyecto, lo que demuestra cómo se aplicó de manera consistente la metodología en cascada para cumplir los objetivos planteados.

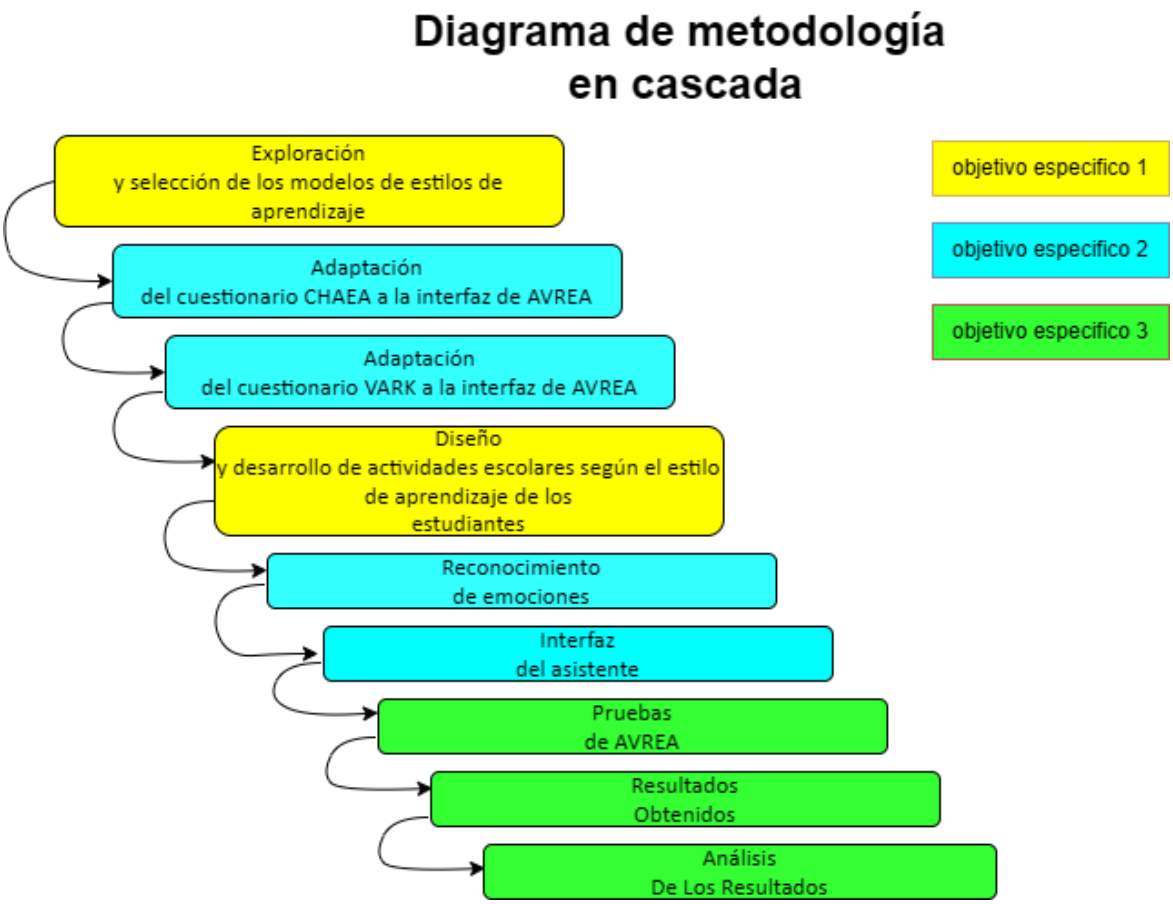

Ilustración 3: Diagrama de metodología en cascada

7.1 Exploración y selección de los modelos de estilos de aprendizaje

En el ámbito educativo, los estilos de aprendizaje son un tema en constante desarrollo, ya que diversos autores han propuesto teorías que fundamentan modelos, métodos y recursos para identificar los estilos de aprendizaje de las personas. Sin embargo, algunas teorías han cobrado mayor relevancia debido a su eficacia y precisión. Una de ellas es el modelo de Kolb, basado en el aprendizaje experiencial, que propone cuatro estilos principales: convergente, divergente, asimilador y acomodador, los cuales dependen de cómo las personas prefieren percibir y procesar la información (Kolb, 1984).

Por otro lado, el CHAEA (Cuestionario Honey-Alonso de Estilos de Aprendizaje) clasifica los estilos de aprendizaje en cuatro categorías: activo, reflexivo, teórico y pragmático. Este modelo se basa en la idea de que los individuos abordan el proceso de aprendizaje de diferentes maneras, lo que les permite adaptar sus estrategias según su estilo preferido (Honey, P., & Mumford, A., 1994).

De manera similar, el modelo VARK, propuesto por Neil Fleming en 1992, identifica cuatro estilos de aprendizaje: visual, auditivo, lectura/escritura y kinestésico. Este modelo sugiere que las personas aprenden mejor según sus preferencias sensoriales: los visuales prefieren gráficos, los auditivos aprenden mejor escuchando, los lectores/escritores a través de textos, y los kinestésicos mediante actividades prácticas. (Fleming y Mills, 1992),

Finalmente, se ha optado por utilizar las teorías de CHAEA y VARK debido a su amplia aplicación en investigaciones sobre estilos de aprendizaje, así como su utilidad para diseñar estrategias pedagógicas adaptadas a las necesidades de los estudiantes.

A partir de lo anterior, se desarrolló una plantilla gráfica llamada home.html, como se muestra en la ilustración 4. Su diseño se creó utilizando HTML, JavaScript y CSS. En esta vista, se encuentra un banner que permanece visible con el mensaje AVREA (Asistente Virtual para el Reconocimiento de Estilos de Aprendizaje).

El fondo de la página es blanco, con un marco azul que aporta un contraste agradable, mejorando la legibilidad y la estética general de la vista. Este tono de azul no solo brinda una sensación de calma y claridad, sino que también destaca los elementos clave de la interfaz, facilitando la navegación y mejorando la experiencia visual del usuario.

Además, esta vista de bienvenida cuenta con un título que dice “Bienvenido a AVREA” y, debajo de él, tres contenedores azules con información que explican la finalidad del programa. Estos contenedores están acompañados por un robot en formato GIF, lo que hace la experiencia más amena para el usuario.

Más abajo, se encuentran dos botones azules. El primero tiene el texto “Ver resultados test” y su función es redireccionar al usuario a una vista donde podrá ver los resultados del test. Si el usuario aún no ha completado esta actividad, será remitido a una vista diferente donde se le indicará cómo hacerlo. El segundo botón contiene el texto “Comenzar Test”, y su función es redirigir al usuario a una nueva vista donde se le explicará en qué consiste el cuestionario CHAEA.

Ilustración 4: Vista principal de AVREA

7.2 Adaptación del cuestionario CHAEA a la interfaz de AVREA

Después de seleccionar los modelos de estilo de aprendizaje, se desarrolló una adaptación del cuestionario CHAEA y VARK para implementarlo en AVREA. En la ilustración 5, se muestra una vista previa del Test CHAEA, en la que se contextualiza al usuario sobre la teoría propuesta por Honey y Alonso, brindando una explicación breve de los estilos activo, reflexivo, teórico y pragmático. Esta información se presenta de forma clara y concisa, facilitando al usuario la comprensión de los conceptos antes de comenzar la prueba. Al final de la sección informativa, se incluye un botón con el mensaje “Empezar test CHAEA”, que permite al usuario iniciar el cuestionario directamente.

Ilustración 5: Vista principal de AVREA:

Al comenzar el test de Honey y Alonso, la ilustración 6 muestra cómo el usuario dispone de ocho pestañas, cada una con diez preguntas cerradas de sí o no, correspondientes al test. Para responder, el usuario debe seleccionar la opción deseada haciendo clic en el botón de radio disponible. El diseño permite navegar entre las pestañas con total libertad, y el programa señala la pestaña en la que se encuentra el usuario al cambiar su color a morado. Para finalizar el ejercicio, es necesario presionar el botón “Continuar test” y haber respondido todas las preguntas. En caso de que alguna pregunta quede sin responder, el programa indicará cuál es y el usuario deberá navegar entre las pestañas para completar la respuesta faltante.

Una vez que el usuario ha finalizado correctamente el test de Honey y Alonso, el asistente mostrará los resultados en un recuadro azul, donde se indicará cuántos puntos obtuvo en cada estilo de aprendizaje, tal como se ilustra en la ilustración 7. Este diseño sigue el mismo enfoque interactivo y visual que el de las pestañas del test, asegurando una experiencia fluida y coherente para el usuario. Tras visualizar los resultados, se habilitará un botón de color verde con el mensaje “Ir al test 2”, cuya función es redirigir al usuario al

cuestionario VARK, permitiendo continuar con la evaluación de estilos de aprendizaje de manera ordenada y eficiente.

Ilustración 7: Test CHAEA

Ilustración 6: Resultados Test CHAEA

7.3 Adaptación del cuestionario VARK a la interfaz de AVREA

Después de finalizar correctamente el Test CHAEA, el asistente redirige al usuario al cuestionario VARK, como se ilustra en la ilustración 8. Antes de comenzar este test, el sistema presenta una vista previa en la que se explica de manera breve los estilos de aprendizaje visual, auditivo, lector/escritor y kinestésico, proporcionando al usuario un contexto básico y accesible para entender las categorías evaluadas. Esta información se

presenta de forma clara y concisa, acompañada de un botón con el mensaje “Empezar test VARK”, que permite al usuario iniciar la evaluación.

A diferencia del Test CHAEA, el Test VARK está compuesto por cuatro secciones, cada una con cuatro preguntas de opción múltiple, diseñadas para identificar las preferencias de aprendizaje del usuario, según se muestra en la ilustración 9. Para responder, el usuario debe seleccionar la opción que considere más adecuada, navegando entre las secciones de manera sencilla e intuitiva. Una vez que el cuestionario ha sido completado, el usuario deberá presionar el botón “Terminar test” para finalizar la evaluación.

Ilustración 9: Contextualización Cuestionario VARK

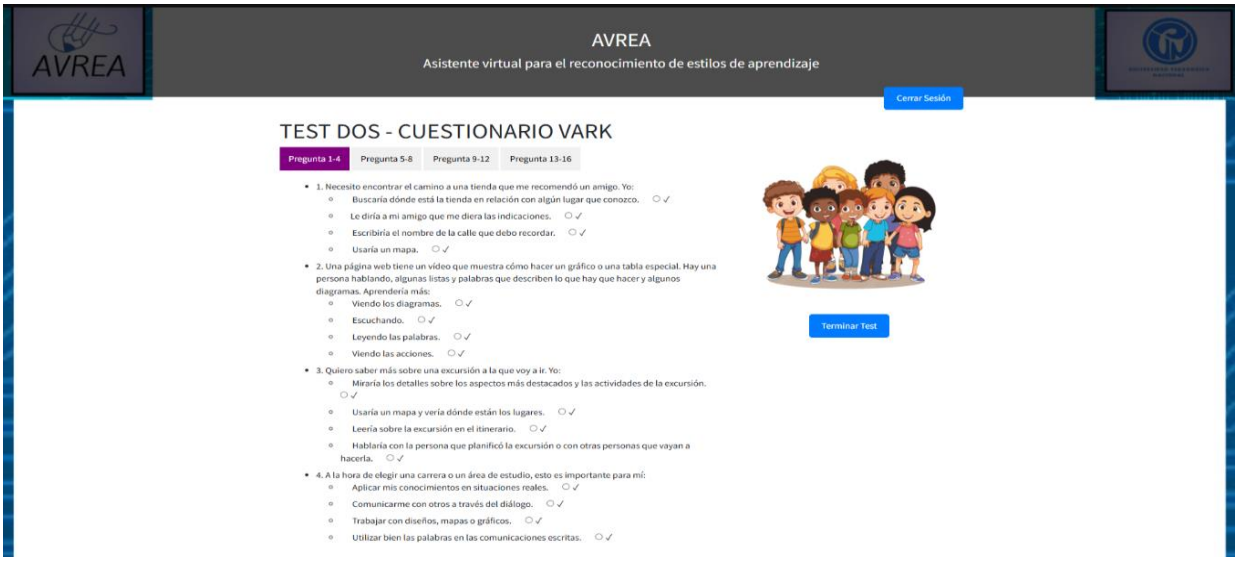

Ilustración 8: Test VARK

Al concluir el Test VARK, el sistema mostrará un resumen completo de los resultados obtenidos en ambos cuestionarios: un recuadro azul con el desglose de puntos para cada estilo de aprendizaje en el Test CHAEA, y otro recuadro con los resultados del Test VARK. Además, se incluirá un tercer recuadro que destacará el estilo de aprendizaje predominante según ambas teorías, permitiendo al usuario identificar de forma clara y precisa sus preferencias de aprendizaje. Este enfoque integrado facilita al usuario una experiencia organizada y enriquecedora, asegurando una comprensión completa de sus resultados.

Es importante resaltar que, además de los resultados, se habilitará un botón con el nombre de la actividad seguido del estilo de aprendizaje predominante obtenido en la primera teoría. Este botón llevará al usuario a una vista diferente donde desarrollará una serie de ejercicios sobre temas de tecnología, como se observa en la ilustración 10.

Ilustración 10: Resultado test CHAEA y VARK

En caso de que el usuario haya completado los test, pero no haya iniciado las actividades, no las haya completado o haya cerrado la sesión, podrá hacer clic en el botón de "Ver resultados" que se encuentra en la vista ofrecida por el home. Cuando esto ocurra,

AVREA mostrará los resultados de manera más sencilla, tal como se ilustra en la ilustración 11, donde se destacarán los estilos predominantes obtenidos sin mostrar el puntaje que aparecía en la ilustración 9, y se incluirá una serie de animaciones más llamativas.

Ilustración 11: Resultados Test CHAEA y VARK simplificado

7.4 Diseño y desarrollo de actividades escolares según el estilo de aprendizaje de los estudiantes.

Para el diseño de las actividades sobre tecnología, se incorporaron diversos recursos como imágenes, textos, audios, entre otros, para garantizar que cada ejercicio abarcara las características esenciales de los diferentes estilos de aprendizaje. Las actividades vinculadas a la teoría CHAEA guiarán al usuario hacia las actividades correspondientes al modelo VARK, creando así un enfoque integral para abordar diversos estilos de aprendizaje. Posteriormente, se desarrollará una actividad sin contexto, la cual concluirá con el ejercicio centrado en la tecnología.

7.4.1 Actividad Teórica

La actividad teórica se centra en proporcionar a los usuarios una definición clara sobre el concepto de tecnología, especialmente diseñada para aquellos con un estilo de aprendizaje teórico, quienes prefieren aprender mediante explicaciones detalladas. Después de la definición, los usuarios deben responder tres preguntas usando sus propias palabras, con un límite de hasta 255 caracteres por respuesta. Al ingresar cada respuesta, el contenedor correspondiente se vuelve verde, lo que indica que la respuesta ha sido registrada correctamente. Una vez respondidas todas las preguntas, el sistema habilita un botón de "Guardar respuesta". Al hacer clic en este botón, se muestra un mensaje de confirmación, y se activa un botón para avanzar a la siguiente actividad.

Esta actividad está alineada con el componente de Uso y Apropiación de la Tecnología e Informática (T&I), y promueve la competencia de aprovechar las potencialidades de productos tecnológicos en diversas actividades. A través de esta actividad, los usuarios trabajan con tecnologías disponibles en su entorno, clasifican artefactos según sus características y utilizan dispositivos digitales para mejorar la comunicación y el desarrollo personal. Todo este proceso queda plasmado en la Ilustración 12, que muestra el flujo de la actividad y la interacción del usuario con el sistema.

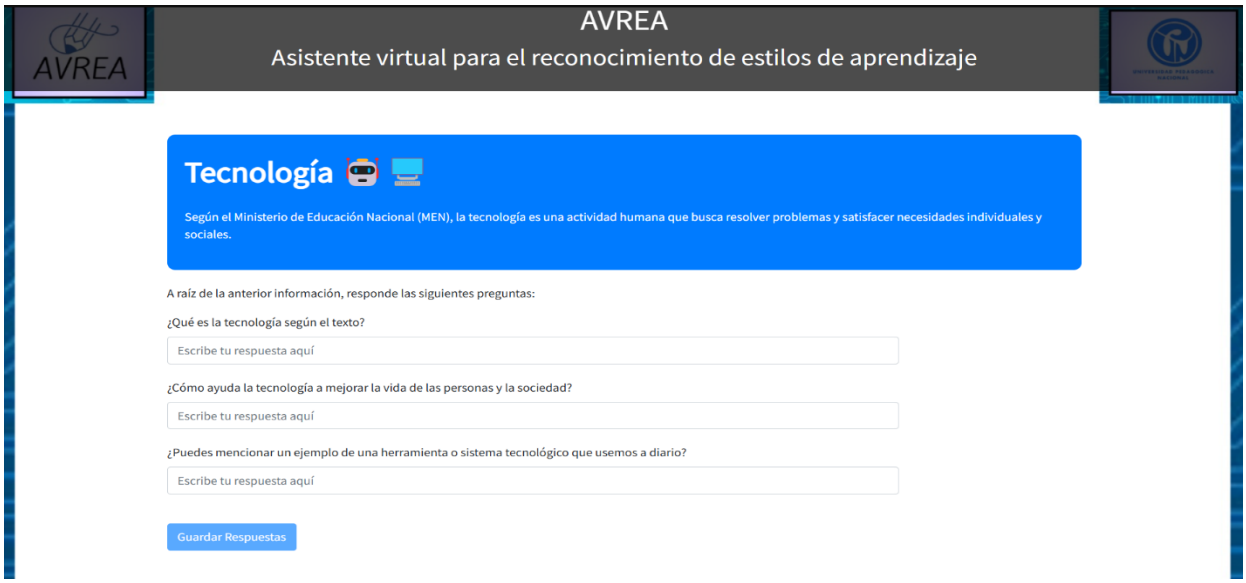

Ilustración 12: Actividad Teórica

7.4.2 Actividad Reflexiva

La actividad reflexiva centrada en la historia de "Pedro y la Tecnología" está diseñada para fomentar una reflexión profunda en los usuarios, particularmente aquellos con un estilo de aprendizaje reflexivo, quienes tienden a preferir procesar la información y analizarla cuidadosamente antes de emitir juicios o respuestas. En este contexto, la historia muestra cómo la tecnología ha influido positivamente en la vida de Pedro, mejorando aspectos como la comunicación, la conectividad y su crecimiento académico. Después de leer la historia, los usuarios deben reflexionar sobre cómo la tecnología ha impactado en sus propias vidas, y responder a tres preguntas en sus propias palabras. La ilustración 13 acompaña este proceso visualizando cómo la tecnología se integra en la vida diaria de los personajes, proporcionando un contexto visual que refuerza el mensaje de la historia.

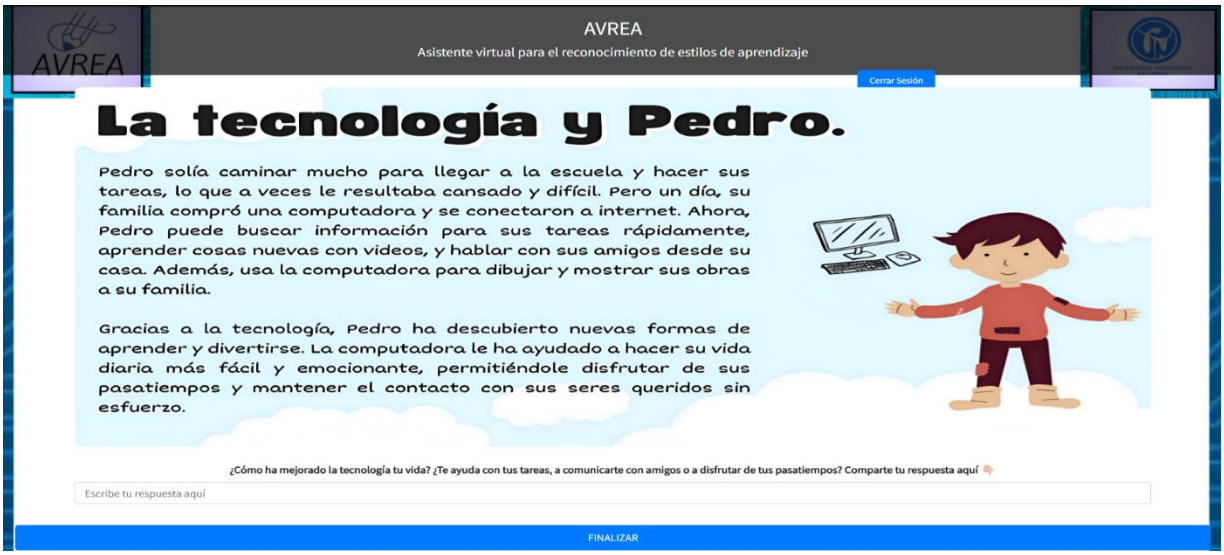

Ilustración 13: Actividad Reflexiva

Este enfoque resulta especialmente beneficioso para los usuarios con el estilo reflexivo, ya que les permite tomar su tiempo para pensar y elaborar respuestas detalladas. Al ser una actividad que invita a la reflexión personal, favorece la comprensión profunda y el aprendizaje significativo, elementos clave para este tipo de aprendices. Además, al final de la actividad, el sistema permite a los usuarios revisar y confirmar sus respuestas antes de proceder a la siguiente etapa, lo que refuerza aún más el proceso reflexivo.

La actividad reflexiva permite a los usuarios, especialmente aquellos con un estilo de aprendizaje reflexivo, analizar cómo la tecnología mejora su vida diaria, especialmente en comunicación y aprendizaje. Al estar alineada con el componente de Uso y Apropiación de la Tecnología e Informática (T&I), promueve el uso de herramientas tecnológicas para el desarrollo personal, ayudando a los usuarios a reflexionar y aplicar el conocimiento tecnológico en su entorno.

7.4.3 Actividad Activa

La actividad activa se estructura en 4 filas que favorecen la interacción directa con los usuarios. En la primera fila, se presentan 4 imágenes de elementos tecnológicos (teléfono fijo, máquina de escribir, radio y reproductor de DVD). La segunda fila contiene el nombre de cada uno de estos elementos en contenedores, mientras que la tercera fila está compuesta por 4 contenedores vacíos donde los usuarios deben arrastrar los nombres desde la segunda fila a la correspondiente en la tercera, según la información proporcionada en la cuarta fila. La ilustración 14 muestra cómo se organizan las imágenes y los contenedores, facilitando la visualización del proceso de emparejamiento para los usuarios.

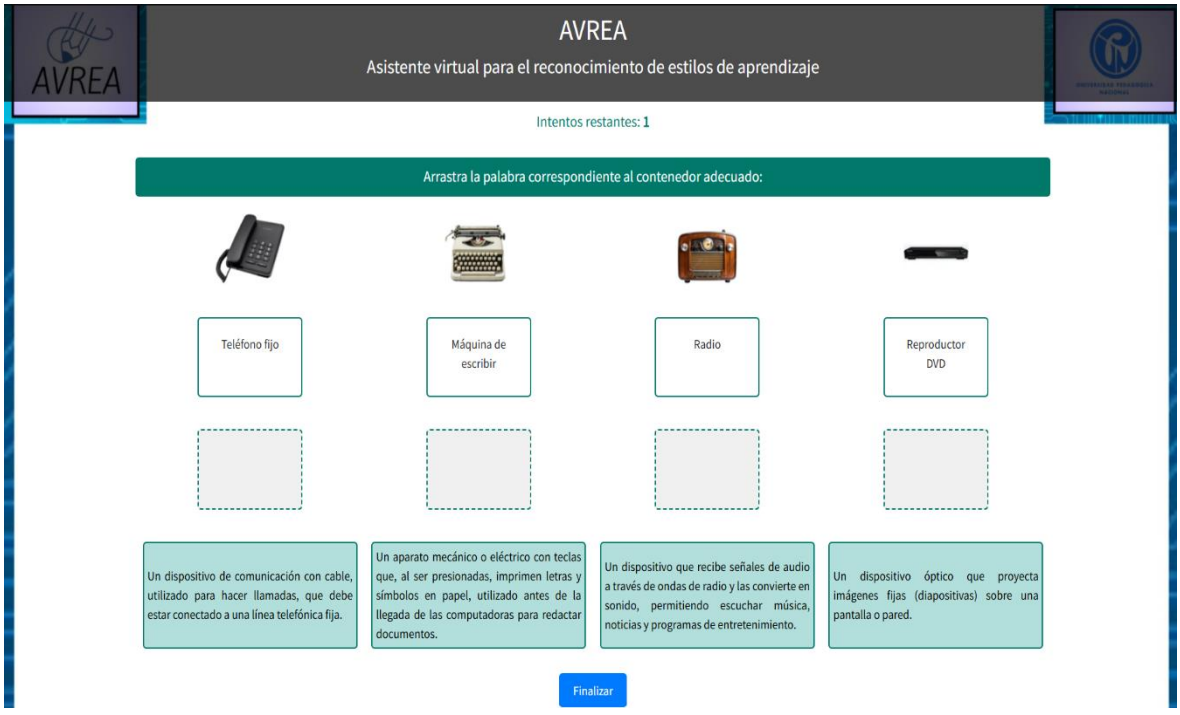

Ilustración 14: Actividad Activo.

Esta dinámica permite a los usuarios, especialmente aquellos con un estilo de aprendizaje activo, aprender a través de la acción directa, favoreciendo la participación y la toma de decisiones rápidas. Los usuarios tienen solo dos oportunidades para realizar el emparejamiento correctamente, y al presionar el botón "Finalizar", el sistema verifica sus respuestas. Si la respuesta es correcta, los contenedores de la fila 3 se ponen en verde; si alguna respuesta es incorrecta, el contenedor correspondiente se resalta en rojo, indicando el error. Este enfoque fomenta la participación, el aprendizaje a través de la prueba y el error, y el refuerzo positivo, ideal para los usuarios con un estilo de aprendizaje activo.

Esta actividad está diseñada para alinearse con el estilo de aprendizaje activo, ya que promueve una participación directa e involucramiento práctico de los usuarios al emparejar conceptos con elementos visuales. Este enfoque fomenta la experimentación y el aprendizaje a través de la acción, elementos esenciales para los aprendices activos. Al mismo tiempo, se vincula con el componente de Uso y Apropiación de la Tecnología e Informática (T&I), integrando herramientas digitales y actividades dinámicas que potencian habilidades como clasificar artefactos y aplicar tecnologías en contextos prácticos y significativos.

7.4.4 Actividad Pragmática

La actividad pragmática está diseñada para fomentar la aplicación práctica de conceptos tecnológicos, vinculándose directamente con el estilo de aprendizaje pragmático, que se enfoca en resolver problemas concretos y generar soluciones efectivas. En la primera etapa, se propone al usuario identificar un elemento tecnológico que pueda emplearse para clavar una puntilla en una superficie, como una pared. El usuario debe escribir el nombre del elemento en un contenedor destinado a esta acción y guardar su respuesta presionando el botón "Guardar respuesta".

En la segunda etapa, el usuario debe dibujar el elemento tecnológico descrito en una pizarra digital que dispone de ocho colores, incluidos negro, rojo y azul, y dos opciones de borrado: leve y parcial. Este paso permite al usuario plasmar el objeto con el mayor detalle posible, promoviendo habilidades de representación gráfica y creatividad. La ilustración 15

presenta con mayor detalle la visual de la pizarra y sus herramientas. Al finalizar el dibujo, el usuario cierra la actividad al hacer clic en el botón "Finalizar actividad".

Este enfoque está directamente relacionado con el estilo pragmático, ya que fomenta la resolución de problemas prácticos y la experimentación activa. A su vez, se alinea con el componente de Uso y Apropiación de la Tecnología e Informática (T&I), al promover el uso eficiente de herramientas tecnológicas en situaciones cotidianas, el desarrollo de estrategias creativas y la capacidad de aplicar conocimientos en contextos reales

Ilustración 15: Actividad Pragmática

7.4.5 Actividad Visual

La actividad visual está diseñada para que los usuarios identifiquen las partes de un ordenador representadas en una imagen numerada del 1 al 4 (pantalla, teclado, ratón y CPU). Al igual que se muestra en la ilustración 16, los participantes deben escribir los nombres correspondientes en contenedores numerados que coinciden con cada parte del ordenador. Al presionar el botón "Guardar respuestas", el sistema valida la información ingresada, resaltando en verde los aciertos y en rojo los errores. Este enfoque fomenta la corrección inmediata y el aprendizaje visual.

Esta actividad beneficia a los aprendices visuales al usar imágenes claras y detalladas, reforzando la relación entre conceptos gráficos y sus nombres. Además, fortalece habilidades de observación y asociación, esenciales para este estilo de aprendizaje. Tras la revisión, el botón cambia a "Siguiente actividad", guiando al usuario hacia una nueva experiencia denominada "Sin contexto".

Asimismo, el enfoque se vincula al componente de Uso y Apropiación de la Tecnología e Informática (T&I), integrando herramientas visuales para mejorar la comprensión y aplicación de conceptos en situaciones prácticas y significativas.

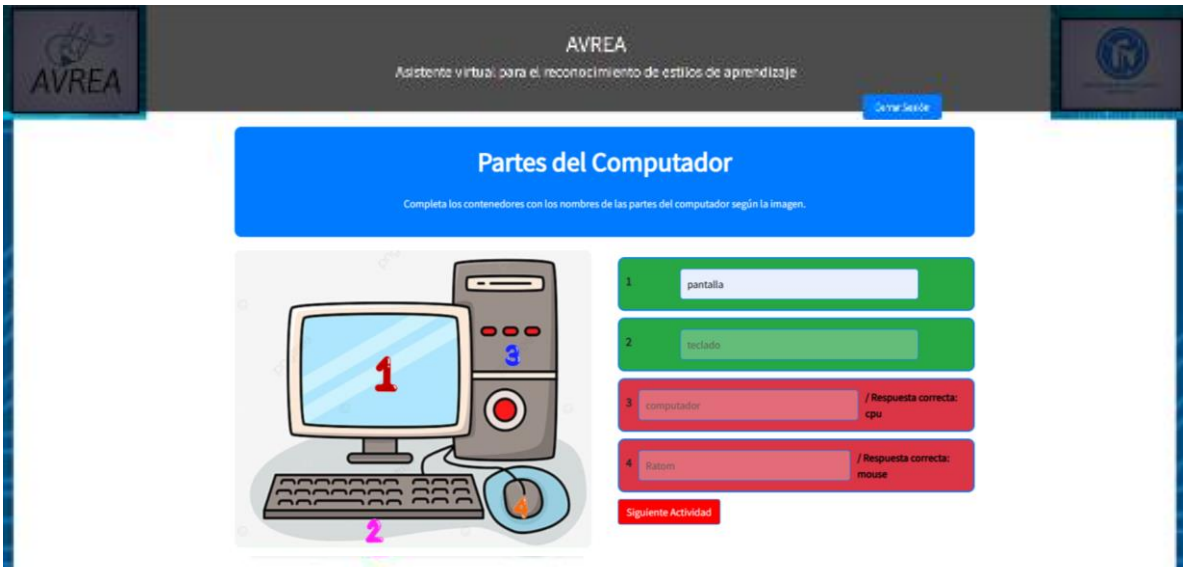

Ilustración 16: Actividad Visual

7.4.6 Actividad Auditiva

Esta actividad auditiva utiliza una barra de reproducción con funciones de reproducir, pausar, reiniciar, adelantar y retroceder un audio que narra una historia sobre cómo la tecnología mejora la vida de las personas. Tras escuchar el audio, los participantes deben reflexionar y responder con sus palabras a preguntas como: ¿Cómo ha mejorado la tecnología tu vida? o ¿De qué manera te ha ayudado con tus tareas? Las respuestas se ingresan en un cuadro azul diseñado para facilitar la escritura.

Una vez completada la respuesta, el botón "Finalizar actividad" se habilita, permitiendo al usuario guardar su respuesta. Al hacerlo, es dirigido automáticamente a una nueva actividad denominada "Sin contexto", con el propósito de facilitar la escritura , como se ejemplifica en la ilustración 17.

Ilustración 17: Actividad Auditiva

Este enfoque es ideal para aprendices auditivos, quienes tienden a retener mejor la información presentada en formato oral. Les permite conectar conceptos escuchados con experiencias personales, fomentando la reflexión crítica y el uso del lenguaje escrito como medio de análisis. Además, la actividad se vincula al componente de Uso y Apropiación de la Tecnología e Informática (T&I), aprovechando herramientas auditivas para mejorar habilidades de comprensión y expresión en contextos educativos significativos.

7.4.7 Actividad Lector/Escritor

La actividad para usuarios con un estilo de aprendizaje lector/escritor se basa en la interacción con un texto presentado en una imagen, donde se describe cómo la Inteligencia Artificial (IA) ha transformado el mundo y las ventajas que ha traído consigo. Los usuarios deben analizar el contenido y reflexionar sobre su significado, lo cual se complementa con dos tareas de escritura: en un primer contenedor, los usuarios deben describir cómo imaginan

el futuro de la vida diaria con la IA, y en un segundo contenedor, deben expresar qué impacto consideran que la IA tendrá en nuestras vidas a largo plazo. Una vez completadas las tareas en ambos contenedores, el botón "Finalizar actividad" se habilita, permitiendo al usuario guardar sus respuestas. Al hacerlo, es dirigido automáticamente a una nueva actividad denominada "Sin contexto", diseñada para continuar desarrollando habilidades de análisis y expresión escrita, como se ejemplifica en la ilustración 18.

Esta actividad promueve el aprendizaje lector/escritor al combinar la lectura comprensiva con la expresión escrita, estimulando el análisis crítico y la capacidad de articular ideas de manera clara y estructurada. Además, está alineada con el componente de Uso y Apropiación de la Tecnología e Informática (T&I), al integrar herramientas digitales para reflexionar sobre conceptos avanzados y relacionarlos con contextos cotidianos.

Ilustración 18: Actividad Lector/Escritor

7.4.8 Actividad Kinestésica

La actividad diseñada para usuarios con un estilo de aprendizaje kinestésico se centra en un juego de adivinanzas de palabras que fomenta la interacción activa mediante la selección de letras y el procesamiento de pistas relacionadas con conceptos de tecnología e informática. Los usuarios reciben retroalimentación inmediata sobre la corrección de sus

elecciones, lo que refuerza el aprendizaje a través del ensayo y error, una estrategia clave para los aprendices kinestésicos.

La naturaleza dinámica de la actividad, que incluye acciones repetitivas, límites de intentos y la manipulación constante de opciones, permite a los usuarios aprender mientras interactúan parcialmente con el contenido. Una vez completadas las tres preguntas, el botón "Siguiente Actividad" se habilita, dirigiendo al usuario a la actividad "Sin contexto", como se muestra en la ilustración 19.

Al combinar movimiento, acción y resolución práctica, la actividad no solo se adapta a las características cinestésicas, sino que también se alinea con el componente de Uso y Apropiación de la Tecnología e Informática (T&I), promoviendo un aprendizaje significativo mediante la interacción directa con los contenidos.

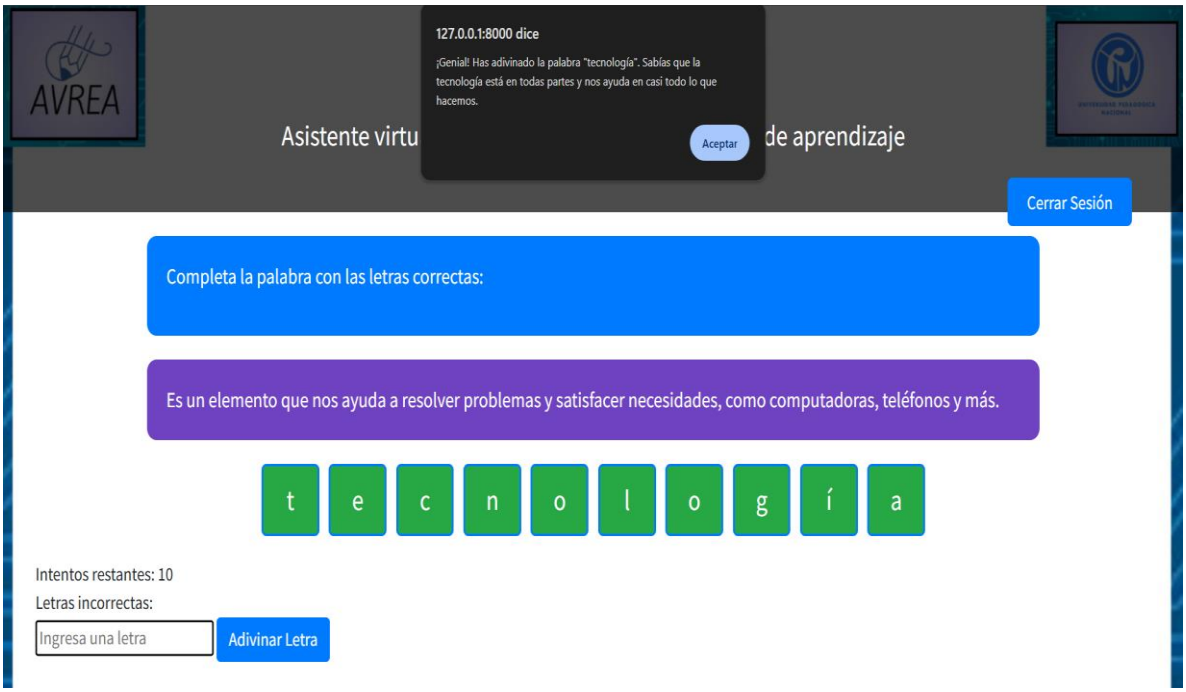

Ilustración 19: Actividad Kinestésica

7.4.9 Actividad Sin Contexto

La actividad "Sin contexto" combina diversos estilos de aprendizaje mediante el uso de pistas escritas, auditivas y visuales, promoviendo la reflexión, acción práctica y aplicación directa de conceptos. Los reflexivos analizan las pistas antes de actuar, los cinestésicos

interactúan fuertemente arrastrando palabras a contenedores, los pragmáticos conectan conceptos con situaciones reales, y los visuales se apoyan en imágenes de referencia.

Como se muestra en la ilustración 20, la actividad organiza contenedores específicos para palabras, áreas de recepción y retroalimentación, facilitando una experiencia interactiva y estructurada. Al finalizar, los usuarios pueden ver sus resultados y avanzar a la siguiente sección mediante el botón "Siguiente actividad" , marcando el cierre dentro de AVREA. Esta actividad integra estilos de aprendizaje y el componente de Uso y Apropiación de la Tecnología e Informática (T&I) , fomentando habilidades tecnológicas en un entorno práctico.

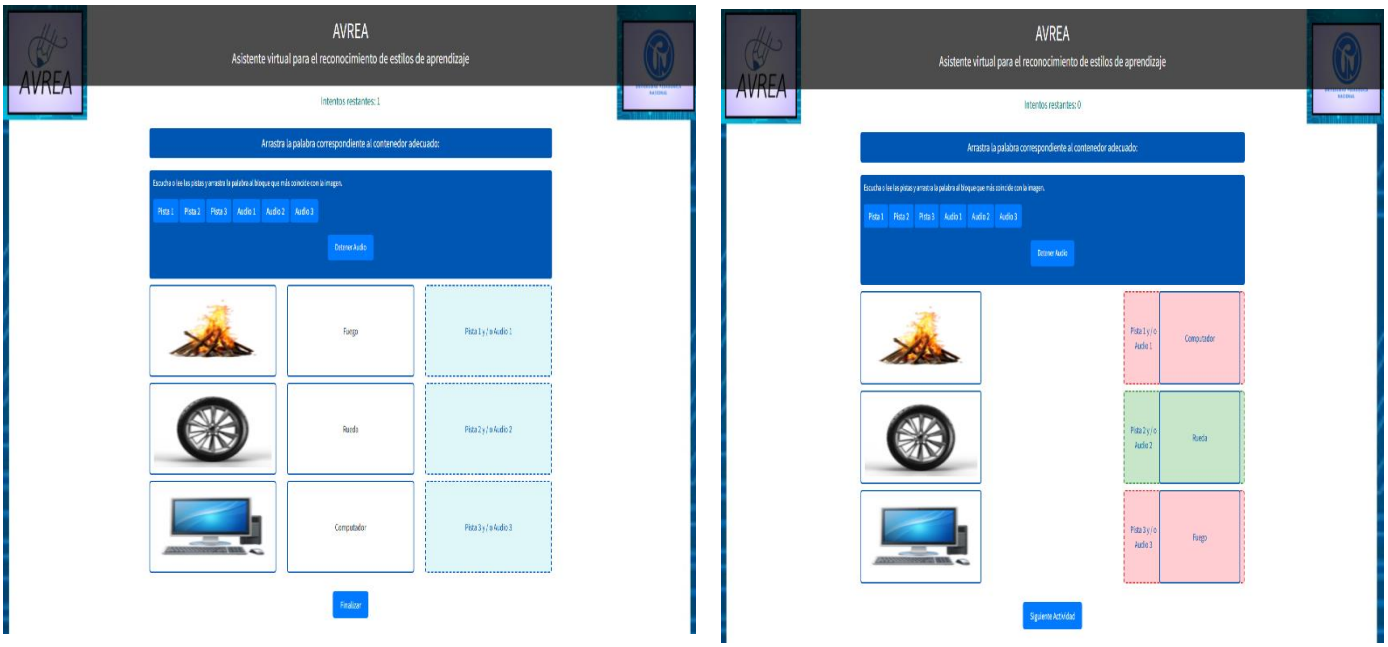

Ilustración 20: Actividad Sin Contexto

7.5 Reconocimiento de emociones

En esta parte de la metodología se muestra el entrenamiento y ejecución de un modelo de reconocimiento de emociones basado en redes neuronales convolucionales (CNN). Este modelo tiene como objetivo clasificar emociones humanas a partir de imágenes faciales y realizar predicciones en tiempo real. A continuación, se describen los pasos seguidos para entrenar el modelo, implementarlo en un entorno de ejecución en vivo.

7.5.1 Entrenamiento del modelo (model.py)

En esta fase se muestra cómo se entrenó el modelo de redes neuronales convolucionales (CNN) para la clasificación de emociones en imágenes faciales. El modelo debe ser capaz de reconocer emociones como *Angry*, *Happy*, *Neutral*, *Sad* y *Surprise* con una alta precisión.

7.5.1.1 Descripción del Dataset

El dataset utilizado para el entrenamiento del modelo es *fer2013*, uno de los conjuntos de datos más utilizados para la clasificación de emociones en imágenes faciales. Este dataset fue creado con el objetivo de ofrecer una amplia variedad de expresiones faciales etiquetadas que permitan entrenar modelos para el reconocimiento de emociones en rostros humanos.

7.5.1.1.1 Fuente:

El dataset fue descargado del repositorio de GitHub de Karan Sethi, quien publicó un artículo titulado *Emotion Detection Using OpenCV and Keras* en Medium, en el que se presenta el uso de este dataset para tareas de reconocimiento de emociones Sethi, Karan. (2020).

7.5.1.1.2 Clases de Emoción:

El dataset contiene imágenes etiquetadas con 7 categorías de emociones, sin embargo, se seleccionaron 5 emociones para este proyecto, que son las siguientes:

- **Angry (Enfadado)**: Expresión facial que muestra un rostro enojado, con cejas fruncidas y ojos muy abiertos.
- **Happy (Feliz)**: Expresión que muestra una sonrisa y una postura facial relajada.
- **Neutral (Neutral)**: Expresión facial sin cambios emocionales significativos, como una cara neutral.
- **Sad (Triste)**: Expresión con cejas caídas, ojos tristes y boca hacia abajo.
- **Surprise (Sorpresa)**: Expresión facial caracterizada por una boca abierta y ojos agrandados, generalmente de asombro.

7.5.1.1.3 Distribución de Datos:

El dataset contiene un total de **35,887 imágenes**, de las cuales:

- **Datos de entrenamiento:** El conjunto de datos está compuesto por un total de 24,256 imágenes, distribuidas entre las cinco clases seleccionadas (Angry, Happy, Neutral, Sad y Surprise). Se presenta en la ilustración 21 una muestra de imágenes correspondientes a la clase "feliz", utilizadas en el entrenamiento del modelo.

Ilustración 21:Muestra de imágenes correspondientes a la clase 'Happy' utilizadas en el entrenamiento del modelo

- **Datos de validación:** El conjunto de datos de validación está compuesto por 3,006 imágenes, distribuidas entre las distintas clases. A continuación, se presenta la ilustración 22 en la que se puede observar una muestra de imágenes correspondientes a la clase "Happy", utilizadas para la validación del modelo.

Ilustración 22:Muestra de imágenes correspondientes a la clase 'Happy' utilizadas en la validación del modelo

Cada imagen tiene un tamaño de **48x48 píxeles** en escala de grises, lo cual facilita el procesamiento computacional y mantiene los detalles relevantes de las expresiones faciales.

7.5.1.1.4 Características del Dataset:

- **Resolución de las imágenes:** Las imágenes tienen una resolución fija de 48x48 píxeles. Esto se debe a que el dataset fue preprocesado previamente para asegurar que todas las imágenes tengan el mismo tamaño, lo que facilita la entrada en el modelo.
- **Escala de color:** Todas las imágenes están en escala de grises, lo que elimina la necesidad de procesar canales de color y permite que el modelo se concentre exclusivamente en las características faciales.
- **Tamaño del conjunto de datos:** El conjunto de datos contiene más de **35,000 imágenes** de 5 emociones diferentes, lo que lo convierte en un conjunto de datos robusto para entrenar modelos de reconocimiento de emociones.

7.5.1.1.5 Preprocesamiento del Dataset:

Para preparar los datos para el modelo, se realizaron las siguientes transformaciones:

- **Normalización de valores de píxeles:** Los valores de píxeles de las imágenes fueron escalados al rango [0, 1], lo que facilita el entrenamiento al evitar valores demasiado grandes que podrían dificultar la convergencia del modelo.
- **Aumento de datos (Data Augmentation):** Para aumentar la diversidad del conjunto de entrenamiento y reducir el sobreajuste, se aplicaron técnicas de aumento de datos, como rotación, traslación, aumento y volteo horizontal. Esto permite al modelo generalizar mejor y no memorizar patrones específicos de las imágenes de entrenamiento.

7.5.1.2 Model.py

Una vez que los datos fueron preparados, se construyó el modelo de red neuronal convolucional (CNN), compuesto por una serie de capas convolucionales, cada una seguida de una función de activación ReLU y una capa de Batch Normalization. Estas capas fueron clave para extraer características importantes de las imágenes faciales y estabilizar el proceso de entrenamiento. Tras cada conjunto de capas convolucionales, se incorporaron capas de MaxPooling para reducir la dimensionalidad de las activaciones y minimizar el riesgo de

sobreajuste. Adicionalmente, se implementaron capas de Dropout para prevenir el sobreajuste durante el entrenamiento.

El modelo se configuró con capas densas al final para realizar la clasificación de las emociones en cinco categorías: angry, happy, neutral, sad y surprise. La capa de salida utilizó la activación softmax, que generó las probabilidades correspondientes a cada clase de emoción.

Con el modelo definido, se procedió a su compilación. Se utilizó el optimizador Adam debido a su eficiencia en problemas de optimización complejos como este, junto con la función de pérdida categorical crossentropy, adecuada para la clasificación multiclase. Para ayudar a que el modelo no se reajustara a los datos de entrenamiento, se implementaron varios callbacks. ModelCheckpoint permitió guardar los mejores pesos basados en la pérdida de validación, EarlyStopping detuvo el entrenamiento si no había mejoras durante tres épocas consecutivas, y ReduceLROnPlateau ajustó la tasa de aprendizaje si la pérdida de validación dejaba de mejorar.

El entrenamiento se ejecutó durante 25 épocas, validando el modelo al final de cada época con el conjunto de datos de validación. Esto permitió asegurarse de que el modelo no se estuviera reajustando a los datos de entrenamiento y que su rendimiento se mantuviera generalizable. Al finalizar el entrenamiento, el modelo fue guardado junto con sus mejores pesos, asegurando que los resultados óptimos se conservaran para su posterior uso en la predicción de emociones en tiempo real.

El siguiente diagrama de flujo visualizado en la ilustración 23 se describe el proceso completo de entrenamiento y evaluación del modelo de reconocimiento de emociones a partir de imágenes faciales utilizando redes neuronales convolucionales (CNN). A través de una serie de etapas secuenciales, se preparan los datos, se construye la arquitectura del modelo, se lleva a cabo el entrenamiento y se realiza la evaluación final, incluyendo la validación y el almacenamiento del modelo con los mejores pesos. Cada paso está diseñado para garantizar la efectividad del modelo en la clasificación de emociones a partir de imágenes faciales.

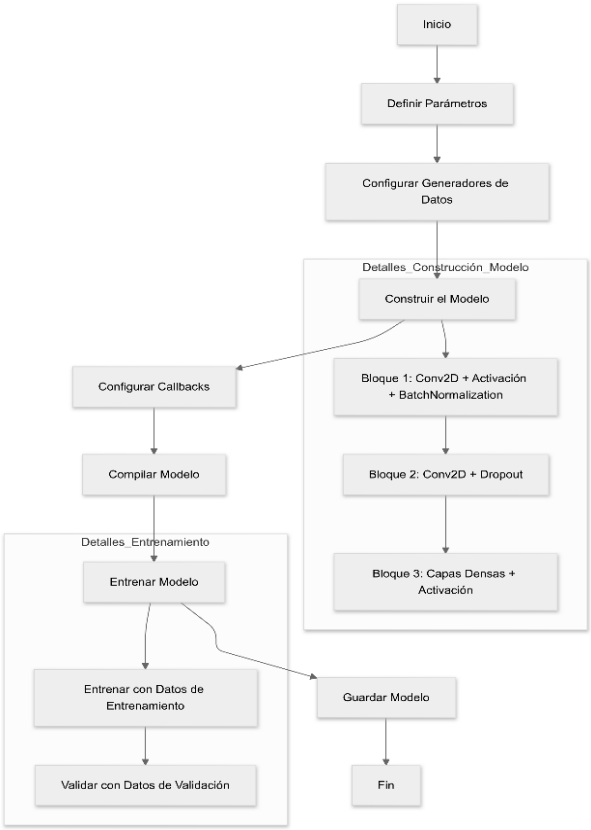

Ilustración 23: Diagrama de Flujo del Proceso de Entrenamiento del Modelo de Reconocimiento de Emociones

7.5.2 Ejecución del Modelo para Reconocimiento en Tiempo Real (testCode.py)

En esta fase se implementó el modelo entrenado para la detección de emociones en tiempo real, utilizando un flujo de video en vivo proveniente de una cámara web. El objetivo era aplicar el modelo entrenado para reconocer y clasificar las emociones faciales mientras se procesaban imágenes en vivo, lo que permitiera interactuar de forma dinámica con el asistente virtual. Para ello, se realizaron varios pasos que incluyen la detección de rostros en tiempo real, el preprocesamiento de las imágenes capturadas, la clasificación de emociones y la visualización de los resultados.

7.5.2.1 Detección de Rostros

Se utilizó el clasificador Haar Cascade para la detección de rostros en las imágenes capturadas por la cámara. Este clasificador es eficiente para identificar rostros humanos en diversas condiciones de iluminación y ángulos.

7.5.2.2 Preprocesamiento en Tiempo Real

Una vez que el rostro es detectado, se extrae y redimensiona a un tamaño de 48x48 píxeles para que coincida con las dimensiones de las imágenes utilizadas durante el entrenamiento. Luego, las imágenes se normalizan para asegurar que los valores de píxeles estén en el rango adecuado para el modelo, es decir, entre 0 y 1.

7.5.2.3 Clasificación de Emociones

Con la imagen preprocesada, se carga el modelo previamente entrenado (EmotionDetectionModel.h5) y se utiliza para predecir la emoción correspondiente. Este paso involucra pasar la imagen a través de las capas del modelo para obtener una probabilidad para cada clase de emoción.

7.5.2.4 Visualización

El resultado de la predicción se visualiza en la pantalla en tiempo real, mostrando un cuadro alrededor del rostro y etiquetando la emoción detectada. Esto permite que el sistema interactúe directamente con el usuario al mostrar las emociones identificadas, como se muestra en la tabla 1 “visualización de emociones”.

Visualización de emociones

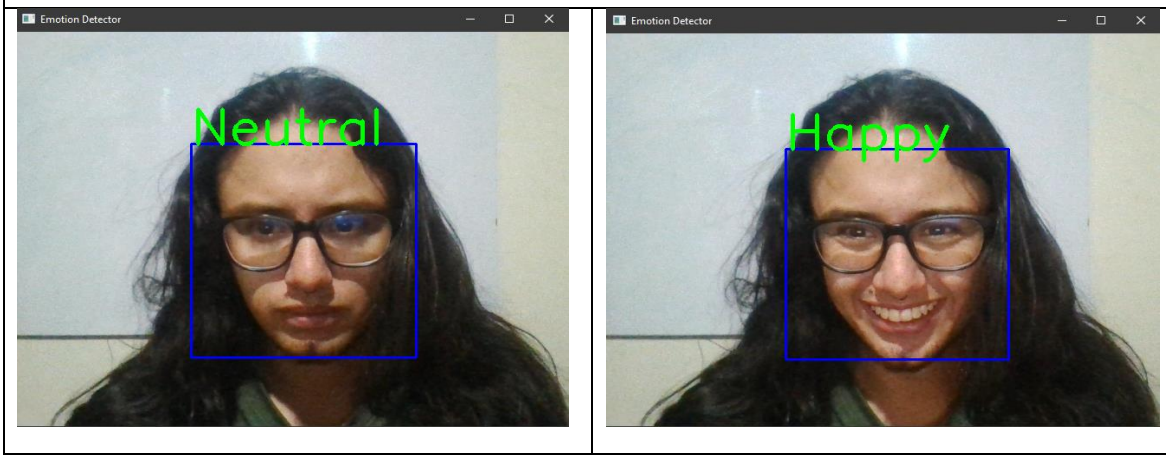

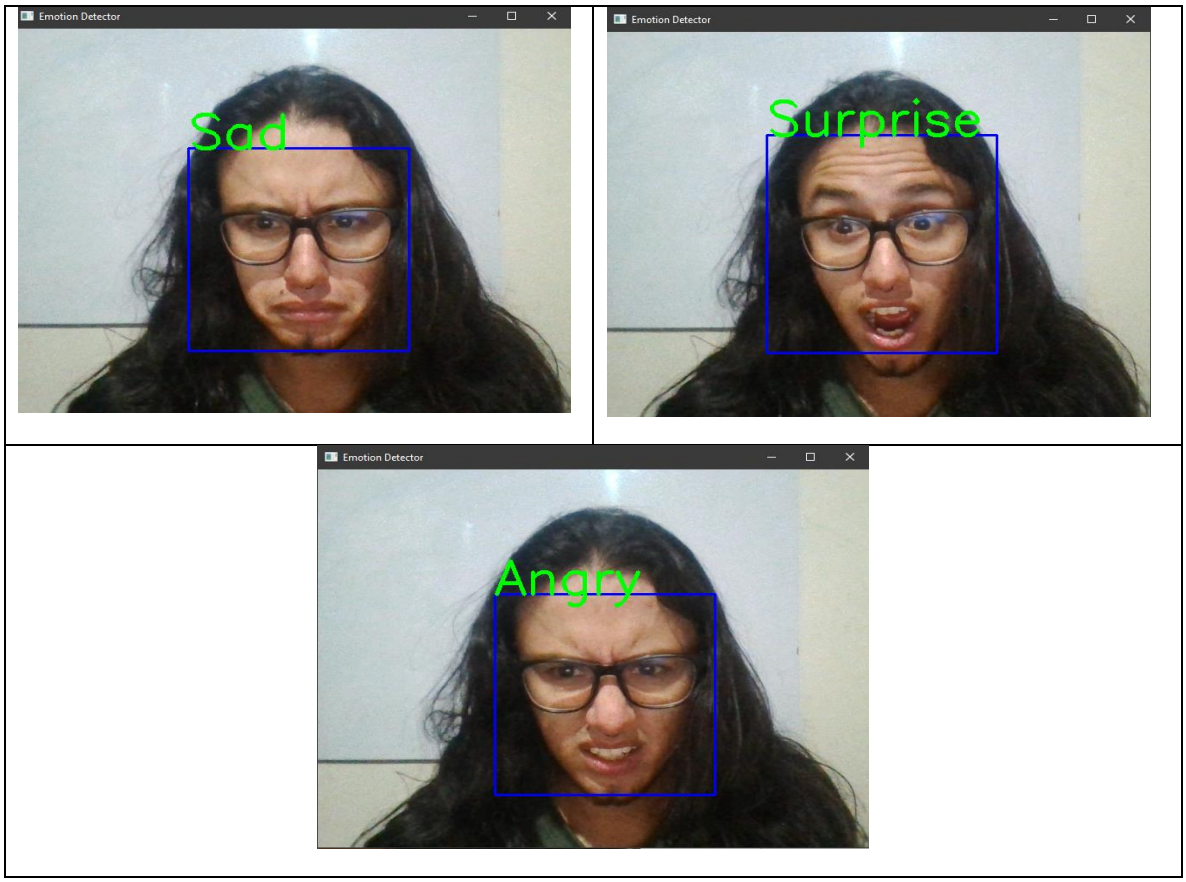

Tabla 1: Visualización de emociones

7.5.2.5 Cargue de Datos al Archivo Excel

El sistema de reconocimiento de emociones no solo detecta y clasifica emociones en tiempo real, sino que también registra esta información junto con las marcas de tiempo correspondientes en un archivo Excel. Este proceso garantiza que los resultados se guarden de forma estructurada y puedan ser consultados posteriormente. Durante la ejecución, el sistema registra cada emoción detectada en un diccionario, que incluye la fecha y hora exacta en que se detectó la emoción y la etiqueta de la emoción identificada, como Angry, Happy, Neutral, Sad, o Surprise. Además, si el sistema detecta un cambio en la actividad en curso (proveniente de un archivo externo valor.txt), este cambio también se registra con la marca de tiempo correspondiente.

Al finalizar la ejecución, todos los datos recopilados se estructuran en un DataFrame haciendo uso de la librería Pandas. Este DataFrame se guarda automáticamente en un archivo Excel, ubicado en la ruta especificada. Este archivo permite un análisis posterior, ya sea para

evaluar el desempeño del modelo o para integrar los resultados con otros módulos, como el asistente virtual AVREA. La ruta de guardado del archivo Excel puede configurarse según las necesidades del usuario, y en este caso se encuentra en: C:/Users/User/OneDrive-UniversidadPedagogicaNacional/Documentos/django_proyectos/proyecto2/proyecto/datosemociones/emotion_data.xlsx. Esto asegura que los datos se almacenen de manera centralizada y accesible para otros procesos del sistema.

7.5.2.6 Flujo General del Sistema de Reconocimiento de Emociones

El diagrama de flujo mostrado en la Ilustración 24 muestra el funcionamiento general del sistema de reconocimiento de emociones, desde la fase de entrenamiento del modelo hasta su implementación en tiempo real. Este flujo detalla las decisiones clave y los pasos involucrados, como la configuración de parámetros, el procesamiento de datos, y el uso del modelo entrenado para analizar las emociones capturadas en video. El proceso está dividido en dos ramas principales las cuales son el entrenamiento el cual incluye el preprocesamiento de datos, la configuración y entrenamiento del modelo CNN, y el guardado del modelo entrenado. Luego se tiene la detección en tiempo real, el cual se encarga de la carga del modelo entrenado, el uso de la cámara para capturar rostros, la predicción de emociones y el registro de resultados en un archivo Excel.

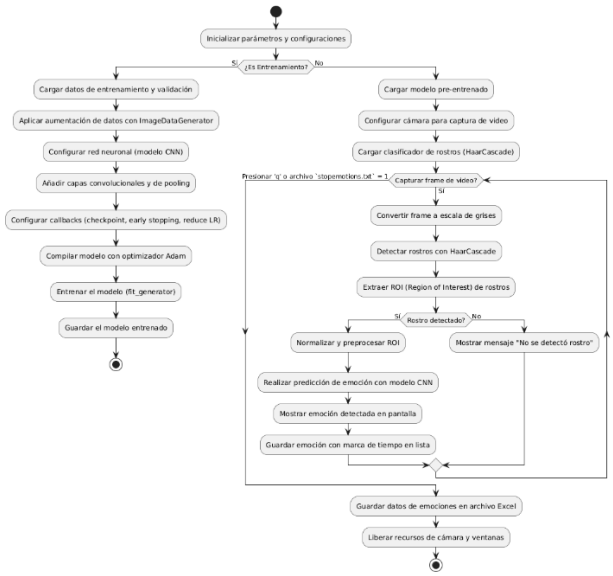

Ilustración 24: Diagrama de flujo del sistema de reconocimiento de emociones

7.6 Interfaz del asistente.

La interfaz de AVREA se diseñó y desarrolló utilizando el framework Django, una herramienta poderosa y versátil para crear aplicaciones web robustas y escalables. Django nos permite estructurar el desarrollo de manera clara mediante el uso del patrón Modelo-Vista-Controlador (MVC), adaptado como Modelo-Vista-Template (MVT) en este framework. Este enfoque garantiza una separación lógica entre la gestión de datos, la lógica de control y la presentación visual, proporcionando una base sólida para integrar las funcionalidades del asistente AVREA.

¿Cómo funciona Django en AVREA?

7.6.1 Back-End con Python

En Django, el núcleo de la aplicación está escrito en Python, un lenguaje que facilita la implementación de la lógica de negocio, la gestión de bases de datos y la creación de vistas dinámicas.

- Modelos: Definen la estructura de los datos y sus relaciones, gestionando de manera eficiente la información de las pruebas, los usuarios y las actividades.
- Vistas: El sistema de vistas en Django maneja la lógica para procesar las solicitudes de los usuarios, recuperar datos desde los modelos y enviarlos a las plantillas para su presentación.
- Control de rutas: Django utiliza URLs para conectar solicitudes específicas con las vistas apropiadas, facilitando la navegación por la aplicación.

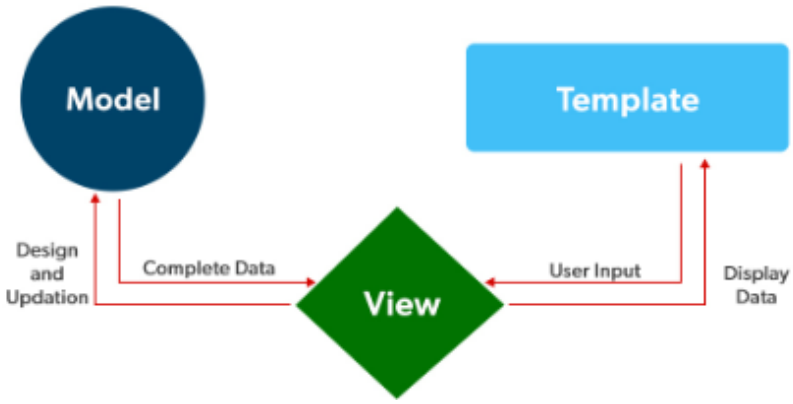

Ilustración 25: Arquitectura de una Aplicación en Django. Tomado de GeeksforGeeks (2023)

La ilustración 25 " Arquitectura de una Aplicación en Django", muestra la estructura básica de una aplicación en Django, destacando tres componentes principales: Modelos (que definen la estructura de los datos y sus relaciones), Vistas (que gestionan la lógica de la aplicación y procesan las solicitudes de los usuarios) y Control de rutas (que conecta las solicitudes de URL con las vistas correspondientes). Django utiliza Python para gestionar la lógica de trabajo, las bases de datos y la creación de vistas dinámicas, facilitando el desarrollo rápido de aplicaciones web.

7.6.2 Interfaz con HTML, CSS y JavaScript

La interfaz visual se construyó mediante código HTML, complementado con CSS para los estilos y JavaScript para mejorar la experiencia interactiva del usuario. Las plantillas de Django generan páginas dinámicas, permitiendo que los datos sean cargados en tiempo real según las interacciones del usuario. Elementos como formularios, botones de navegación y mensajes de retroalimentación están diseñados para mantener una interacción fluida e intuitiva.

7.6.3 Base de datos y autenticación

Django se conecta a una base de datos centralizada que almacena los datos de los usuarios, resultados de los test capturados durante las interacciones. Además, se implementó un sistema de autenticación seguro que permite gestionar el acceso a las distintas vistas de la aplicación, garantizando que solo los usuarios registrados puedan acceder a ciertas funciones, como los resultados de los test y las actividades.

7.6.4 Estructura de la interfaz en AVREA

7.6.4.1 Home

La página de inicio de AVREA es la primera vista con la que el usuario interactúa al ingresar a la plataforma. Su diseño está enfocado en ser simple y funcional, buscando captar la atención del usuario y orientarlo hacia las opciones disponibles. En la parte introductoria, se ofrece una breve explicación sobre el propósito del asistente, destacando su enfoque en la identificación de estilos de aprendizaje y la integración del reconocimiento emocional durante las actividades. La página incluye varios botones principales: Iniciar

Sesión/Registrarse, que dirige a la vista de autenticación y solo es visible si el usuario no ha iniciado sesión; Cerrar Sesión, que aparece cuando el usuario está autenticado y permite finalizar la sesión desde cualquier vista; Comenzar Test, que lleva al usuario a la vista donde se describe el primer test (CHAEA) y se inicia el proceso de evaluación; y Ver Resultados, que, si los test ya han sido realizados, dirige a la página donde se presentan los resultados obtenidos y se ofrece la opción de comenzar las actividades. Si los test aún no se han completado, este botón muestra un mensaje indicando que es necesario realizar los test antes de acceder a esta opción como se puede observar en la ilustración 4.

7.6.4.2 Autenticación

La autenticación en AVREA es un componente fundamental para asegurar que solo los usuarios registrados puedan acceder a las funciones avanzadas de la plataforma. Esta vista incluye un formulario sencillo que permite al usuario registrarse o iniciar sesión utilizando un nombre de usuario y una contraseña. La validación de datos se realiza en tiempo real, verificando la autenticidad de las credenciales, y si se presentan errores, como un usuario no registrado o contraseñas incorrectas, se muestran mensajes claros y útiles para guiar al usuario. Además, la seguridad es una prioridad en esta vista, ya que Django gestiona las sesiones de manera segura, implementando mecanismos de cifrado y protegiendo contra vulnerabilidades comunes, como los ataques de fuerza bruta o inyección SQL.

7.6.4.3 Vistas dinámicas

En AVREA, los test cuentan con vistas dinámicas diseñadas para guiar al usuario a través de un proceso estructurado que facilita la identificación de sus estilos de aprendizaje. El Test CHAEA introduce al usuario al concepto de estilos de aprendizaje a través de cuatro categorías principales: Activo, Reflexivo, Teórico y Pragmático. Las preguntas del test están diseñadas de manera interactiva para identificar el estilo predominante de cada usuario, y al finalizar, se presentan los resultados con descripciones detalladas del estilo identificado. Por otro lado, el Test VARK evalúa las preferencias sensoriales de aprendizaje, abarcando las modalidades Visual, Auditiva, Lector/Escritor y Kinestésica. Cada pregunta incluye opciones multimedia que permiten al usuario identificar sus preferencias de manera más precisa. Al

concluir, el test muestra un resumen claro del estilo predominante y prepara al usuario para continuar con las actividades. Además, todas estas vistas están integradas al sistema de modelos de Django, lo que permite almacenar los resultados en tiempo real y facilitar futuras consultas o análisis del perfil de aprendizaje del usuario.

7.6.4.4 Actividades

Las actividades personalizadas son fundamentales en la experiencia de AVREA, diseñadas según los resultados obtenidos en los test CHAEA y VARK. Estas se desarrollan en tres etapas: la primera se adapta al estilo de aprendizaje identificado en el Test CHAEA, la segunda complementa con el estilo sensorial determinado por el Test VARK, y la tercera tiene un enfoque general para consolidar y evaluar el aprendizaje global. El sistema de reconocimiento de emociones se activa al inicio de las actividades y se apaga automáticamente al finalizar la tercera etapa , monitoreando en tiempo real las emociones del usuario durante todo el proceso. Cada actividad ofrece retroalimentación inmediata y una interfaz que permite avanzar fácilmente al siguiente paso, garantizando una experiencia educativa enriquecedora y personalizada.

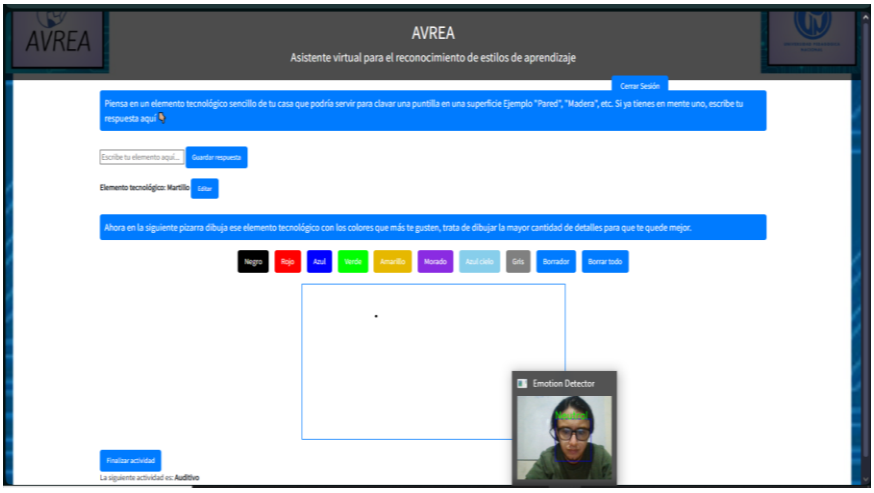

Ilustración 26:Actividad Pragmática con Reconocimiento de Emociones en Tiempo Real

En la ilustración 26, se observa al usuario interactuando con la actividad correspondiente al estilo de aprendizaje pragmático, diseñada específicamente según los

resultados del Test CHAEA. En la parte inferior derecha, se puede visualizar el sistema de reconocimiento de emociones en funcionamiento, monitoreando las expresiones faciales del usuario en tiempo real. Además, en la parte inferior izquierda, junto al botón "Finalizar Actividad", se indica cuál será la siguiente actividad, proporcionando una navegación clara y guiada dentro del flujo del sistema AVREA.

7.6.4.5 Vista Final

En la ilustración 27 se puede observar la vista final de AVREA la cual, marca el cierre de la experiencia, dejando una impresión positiva en el usuario. Incluye un mensaje de agradecimiento que reconoce su tiempo y esfuerzo durante las actividades y los test, un botón para cerrar sesión de manera segura, como se puede visualizar en la siguiente ilustración.

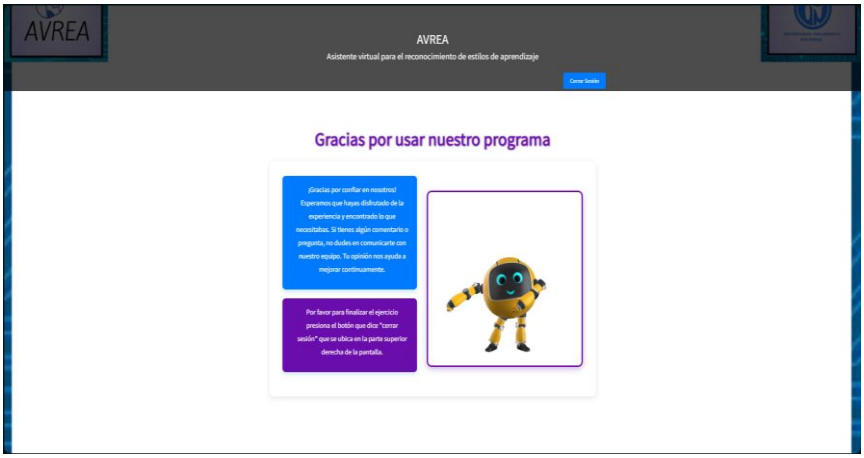

Ilustración 27: Vista final

7.6.5 Diagrama de caso de uso

El diagrama de caso de uso visualizado en la ilustración número 28 se describe el flujo de interacción de un usuario con el sistema AVREA, que comienza en la página de inicio donde puede iniciar sesión, ver resultados de test previos o realizar nuevos test. Tras completar el Test CHAEA y el Test VARK, el usuario recibe resultados y accede a actividades de aprendizaje personalizadas, enfocadas en sus estilos de aprendizaje. El sistema también reconoce las emociones del usuario en tiempo real durante las actividades, proporcionando un análisis adicional. Al finalizar las actividades, el usuario recibe un mensaje de agradecimiento.

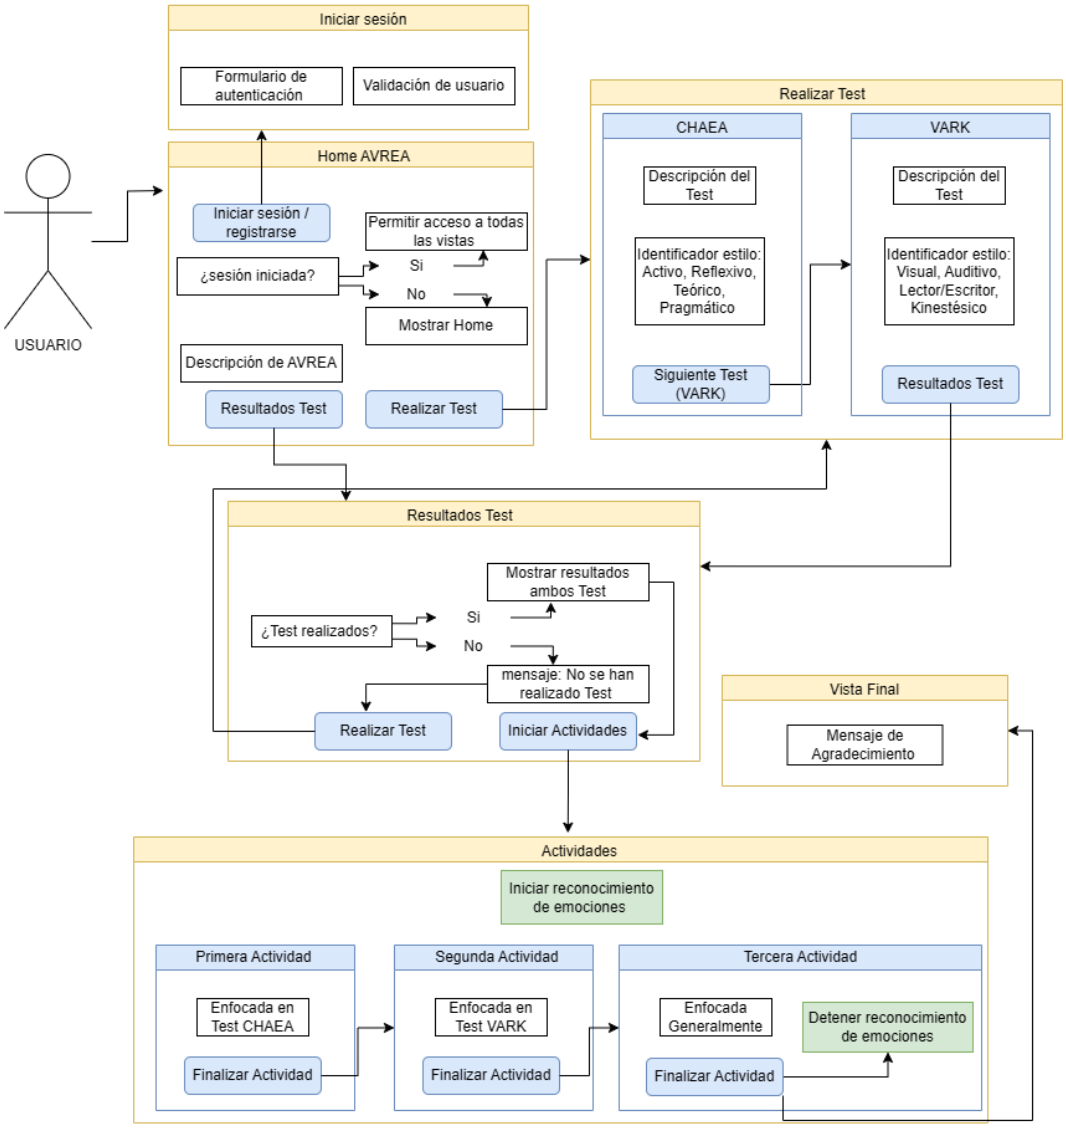

Ilustración 28: Caso de uso de AVREA

7.7 Pruebas de AVREA

AVREA fue puesta a prueba con el objetivo principal de evaluar su sistema de reconocimiento y su capacidad para adaptar las actividades de aprendizaje según el estilo de aprendizaje de los estudiantes. El sistema se basó en dos teorías: la de Honey y Alonso, que distingue entre estilos activos, reflexivos, teóricos y pragmáticos; y la de Fleming (VARK), que categoriza los estilos de aprendizaje en visual, auditivo, lector/escritor y kinestésico.

Las pruebas fueron realizadas con 25 estudiantes de 5° grado, con edades entre 9 y 11 años, de un colegio, donde se utilizaron los test de estilos de aprendizaje para orientar las actividades de acuerdo con las características cognitivas de cada estudiante. Mientras los estudiantes interactúan con las actividades adaptadas, AVREA también realiza un análisis en tiempo real de sus emociones, evaluando su estado de ánimo y reacciones para mejorar la experiencia de aprendizaje en función de su estado emocional. Este enfoque busca no solo adaptar las actividades a los estilos de aprendizaje, sino también tener en cuenta las emociones de los estudiantes, brindando una experiencia educativa personalizada y efectiva.

El proceso comenzó con el registro de usuario en AVREA, en el que los estudiantes proporcionaron información básica como nombre, usuario y contraseña. Estos datos fueron almacenados en la base de datos de Django para diferenciar a cada participante. Después del registro, los estudiantes accedieron a la pantalla de bienvenida, cuya estructura se explica en la Ilustración 4: Vista principal de AVREA. En este espacio, se brindó una introducción breve sobre el propósito de AVREA y su funcionamiento.

Posteriormente, los estudiantes completaron dos test de estilos de aprendizaje: CHAEA (Honey y Alonso) y VARK (Fleming). Gracias a las adaptaciones realizadas en el programa, AVREA fue capaz de implementar la lógica de estas teorías para identificar los estilos de aprendizaje predominantes en cada estudiante. Con esta información, AVREA direcciona al usuario a un conjunto de tres actividades, estructuradas de la siguiente manera: Dos actividades personalizadas, cada una orientada al estilo predominante según las teorías de CHAEA y VARK. y una actividad "sin contexto", diseñada para combinar elementos de distintos estilos de aprendizaje.

Mientras los estudiantes realizaban las actividades como se muestra en la tabla 2, el sistema de reconocimiento de emociones de AVREA estuvo activo en todo momento. Este sistema registró expresiones emocionales en tiempo real, analizando el estado de ánimo del usuario según cada actividad, pero permaneció minimizado para evitar distracciones.

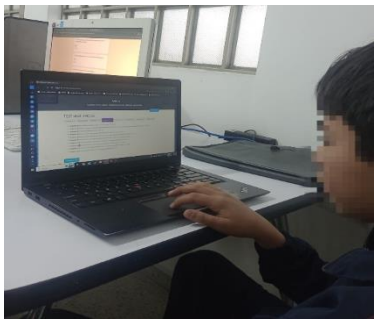	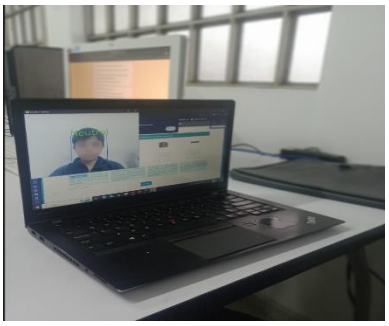	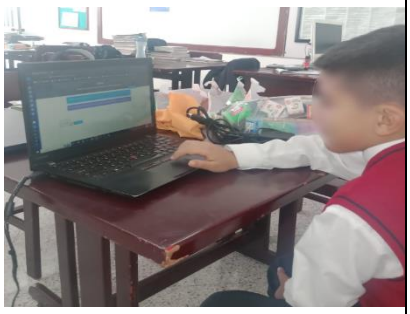
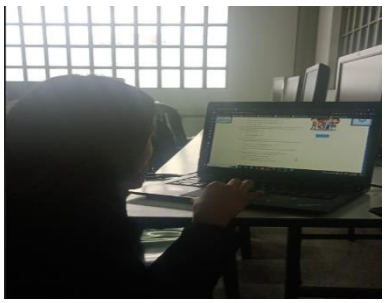	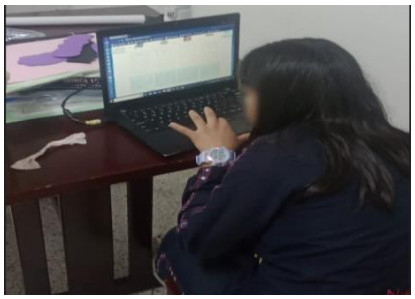	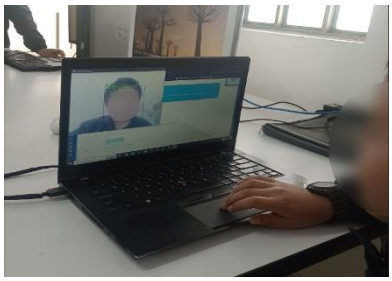
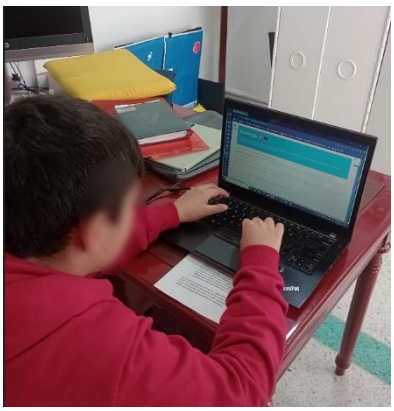	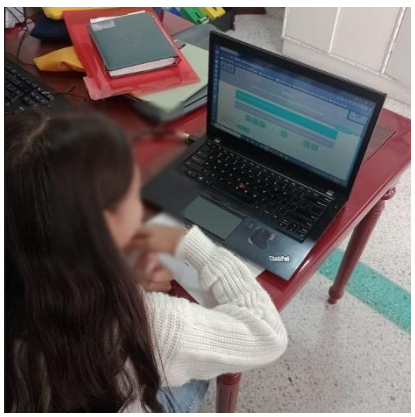	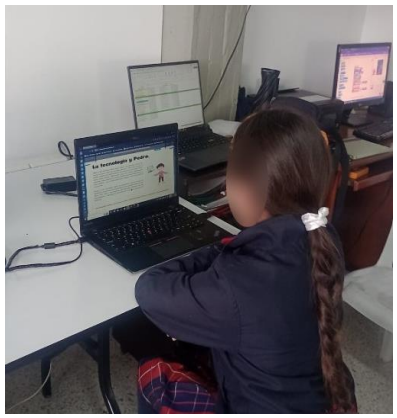

Tabla 2 : Estudiantes utilizando AVREA

Al finalizar las actividades, AVREA generó un archivo Excel que recopiló las emociones registradas, permitiendo almacenar la información necesaria para realizar el análisis de datos directamente en este archivo. Para facilitar este análisis, se programaron algunas celdas en Excel que automatizaban el conteo del número de veces que cada emoción se repitió durante las actividades, con el objetivo de observar su variación a lo largo del tiempo. Las emociones se registraron en un rango de 6 a 8 muestras por segundo, asegurando

un seguimiento preciso del estado emocional de los estudiantes mientras interactuaban con el sistema.

Adicionalmente, los estilos de aprendizaje predominantes identificados mediante los test fueron almacenados en la base de datos de Django. Esta información puede ser consultada por los docentes y administradores con permisos autorizados, proporcionando un recurso clave para personalizar estrategias pedagógicas y evaluar el impacto del sistema en el aprendizaje de los estudiantes.

8 Resultados Obtenidos

8.1 Estilos de aprendizaje de cada estudiante

A partir de las 25 pruebas realizadas con estudiantes de grado quinto en AVREA, se recopiló información clave sobre los estilos de aprendizaje predominantes de cada usuario. La Tabla 3 presenta una síntesis de los estilos de aprendizaje asignados a cada estudiante según los resultados de cada test.

Usuario	Test CHAEA	Test VARK
ab5to	Teórico	Escritor/Lector
ag5toB	Reflexivo	Kinestésico
al5to	Reflexivo	Kinestésico
as5toB	Activo	Kinestésico
dc5to	Activo	Auditivo
dd5toB	Teórico	Kinestésico
dd5to	Pragmático	Kinestésico
dm5to	Activo	Kinestésico
id5to	Activo	Kinestésico
im5to	Activo	Auditivo
im5toB	Reflexivo	Kinestésico
ir5to	Activo	Auditivo
jc5toB	Activo	Auditivo
lj5toB	Activo	Kinestésico
ll5to	Activo	Auditivo
lr5to	Activo	Kinestésico

mb5to	Activo	Kinestésico
mg5to	Activo	Kinestésico
mg5to1	Reflexivo	Kinestésico
mh5to	Reflexivo	Auditivo
ml5toB	Activo	Visual
mn5toB	Teórico	Kinestésico
nm5toB	Teórico	Kinestésico
sc5to	Reflexivo	Kinestésico
sc5to2	Activo	Auditivo

Tabla 3:Usuarios y su estilo de aprendizaje

En esta sección se presentan los resultados del análisis de los estilos de aprendizaje predominantes, obtenidos de los 25 estudiantes. Cada estudiante fue evaluado en dos dimensiones principales: los estilos identificados por el Test CHAEA (Teórico, Activo, Reflexivo, Pragmático) y los estilos del Test VARK (Auditivo, Visual, Escritor/Lector, Kinestésico) como se evidencia en la tabla 4.

Estilo de aprendizaje CHAEA	**Número reconocimientos**
Teórico	4
Activo	14
Reflexivo	6
Pragmático	1
Estilo de aprendizaje VARK	**Número reconocimientos**
Auditivo	7
Visual	1
Escritor/Lector	1
Kinestésico	16

Tabla 4: Conteo estilos de aprendizaje

Para visualizar estos resultados de manera clara, se elaboró una gráfica (ilustración 29) que evidencia la frecuencia con la que cada estilo de aprendizaje se repite dentro del grupo. Esta representación gráfica complementa la tabla de datos y facilita la identificación de patrones en las preferencias de aprendizaje de los estudiantes.

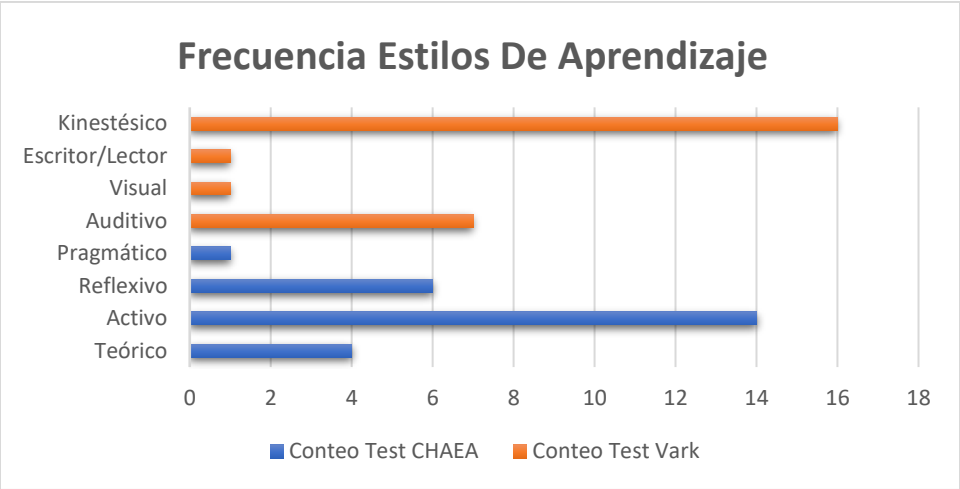

Ilustración 29: Grafica frecuencia estilos de aprendizaje

Los datos reflejan que los estilos Activo y Reflexivo son los más comunes en el Test CHAEA, mientras que el estilo Kinestésico destaca en el Test VARK . Esta información es esencial para desarrollar estrategias pedagógicas adaptadas que potencien el aprendizaje individual y grupal.

8.2 Estilos de aprendizaje y emociones

Por otro lado, se realizó una clasificación que detalla la cantidad de veces que se manifestó cada emoción según la actividad predominante desarrollada por el estudiante. Esta clasificación incluye el análisis de las emociones Happy, Sad, Surprise, Angry y Neutral en cada una de las actividades propuestas. En el Anexo 1, específicamente en la hoja denominada “Datos AVREA”, se presenta una clasificación detallada de la frecuencia de cada emoción según la actividad y para cada usuario. Por su parte, la ilustración 30 funciona como un pequeño adelanto de este anexo, mostrando la organización de las emociones en tablas por actividad, usuario, y una gráfica que destaca cuál fue la emoción más predominante.

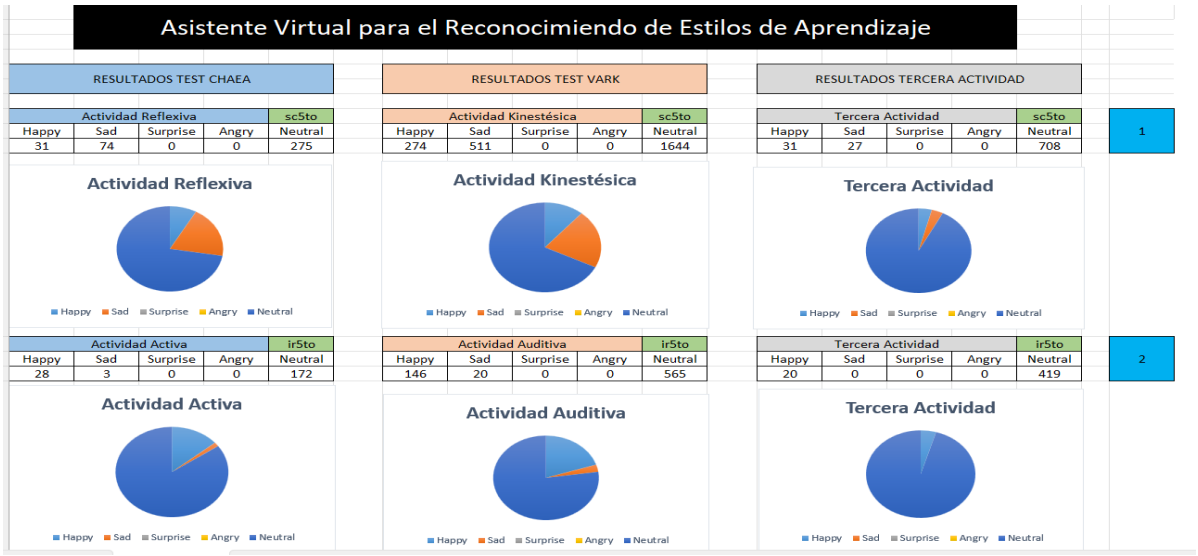

Ilustración 30: Vista resumida del Anexo 1, organización de las emociones según la actividad por usuario

A continuación, se llevó a cabo un análisis más detallado del comportamiento de las emociones, esta vez enfocado en las teorías de aprendizaje CHAEA y VARK, con respecto a las emociones generales manifestadas por el grupo de 25 estudiantes. Este análisis permitió observar cómo las emociones del grupo se desarrollaron y se vieron influenciadas por los diferentes enfoques de aprendizaje propuestos por ambas teorías. A través de este planteamiento, se logró comprender cómo las emociones de los estudiantes se relacionaron con las características de cada teoría, destacando patrones emocionales comunes dentro del grupo. Este estudio brinda una visión más profunda de cómo los estilos y enfoques de aprendizaje impactan en las respuestas emocionales de los estudiantes.

Para complementar este análisis, las tablas 5, 6, 7 junto con las ilustraciones 31, 32 y 33 presentadas a continuación detallan la frecuencia de las emociones en relación con los estilos de aprendizaje propuestos por las teorías CHAEA y VARK. En este sentido, la Actividad 1 corresponde al análisis según la teoría CHAEA, la Actividad 2 está enfocada en la teoría VARK, y la Actividad 3 amplía el análisis de las emociones en relación con otras características. Estas tablas permiten visualizar cómo cada emoción se asocia a los diferentes enfoques de aprendizaje, proporcionando un análisis que muestra la influencia de las preferencias de los estudiantes sobre su expresión emocional durante las actividades, y cómo estas emociones varían según su estilo de aprender.

Emociones Actividad Uno (CHAEA)				
Happy	Sad	Surprise	Angry	Neutral
5302	683	47	275	10856

Tabla 5: Emociones Actividad Uno CHAEA

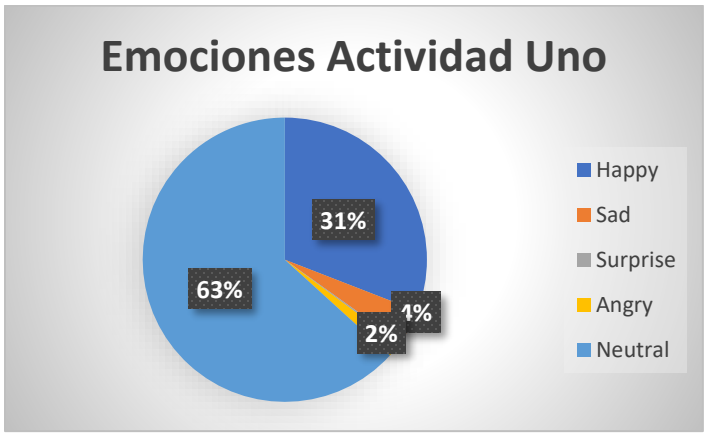

Ilustración 31: Grafica Emociones Actividad Uno

Emociones Actividad Dos (VARK)				
Happy	Sad	Surprise	Angry	Neutral
6498	709	2	0	13915

Tabla 6: Emociones de la actividad dos (VARK)

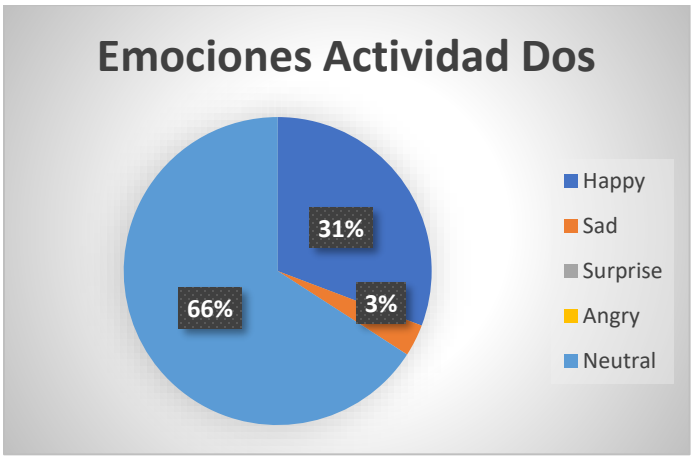

Ilustración 32: Grafica de emociones - Actividad Dos (VARK)

Emociones Actividad Tres				
Happy	Sad	Surprise	Angry	Neutral
2285	221	4	25	12182

Tabla 7: Emociones de la actividad Tres

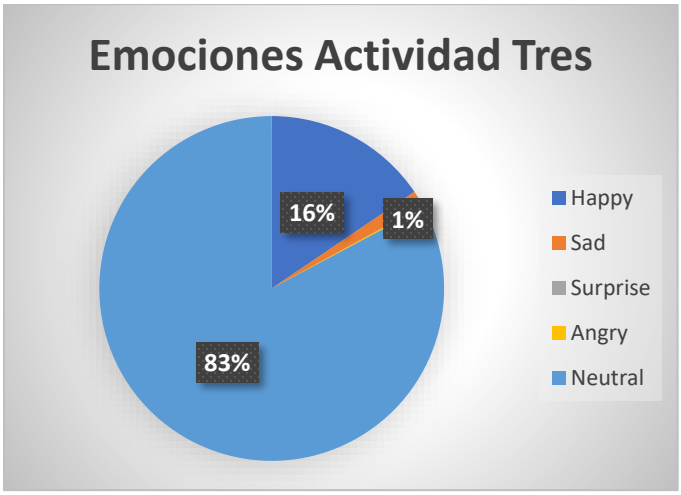

Ilustración 33: Grafica de emociones - Actividad Tres

Además, se realizó un análisis general de las emociones de los estudiantes a lo largo de las tres actividades, con el fin de determinar si su comportamiento experimentó algún cambio positivo, negativo o neutral. Este análisis general se llevó a cabo mediante la organización de todas las muestras clasificadas para cada emoción, permitiendo así observar las variaciones emocionales de los estudiantes a lo largo de las actividades. Para comprender con mayor detalle estos resultados, la tabla 8 y la ilustración 34 presentan la muestra total de las emociones Happy, Sad, Surprise, Angry y Neutral, junto con el porcentaje de relevancia que cada emoción tuvo en la experiencia de los estudiantes. Este enfoque proporciona una visión clara de cómo las emociones influyeron en el desarrollo de las actividades y en el comportamiento general del grupo.

Emociones Totales				
Happy	Sad	Surprise	Angry	Neutral
14085	1613	53	300	36953

Tabla 8: Emociones de todo el grupo a lo largo de las tres actividades

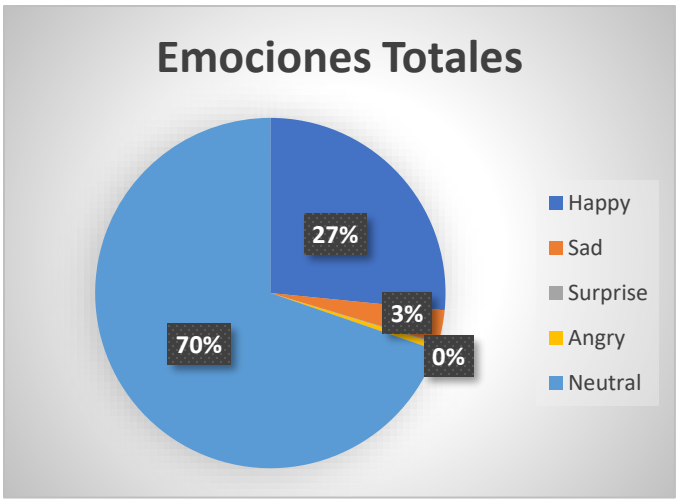

Ilustración 34: Grafica de emociones del grupo a lo largo de las tres actividades

Después de haber analizado las emociones grupales de los estudiantes durante las tres actividades, se decidió clasificar dichas emociones por actividad, como se muestra en la tabla 9.

Total de muestras por emoción según el estilo de aprendizaje					
Estilo De Aprendizaje	**Happy**	**Sad**	**Surprise**	**Angry**	**Neutral**
Teórico	664	59	7	0	1466
Activo	3368	501	26	0	6374
Reflexivo	1145	141	6	0	3092
Pragmático	82	56	8	0	199
Auditivo	2038	28	0	0	3297
Visual	312	0	0	0	535
Escritor/Lector	83	17	0	0	643
Kinestésico	4065	649	2	0	9229

Tabla 9: Emociones grupales según los estilos de aprendizaje

Esta tabla detalla el número total de muestras que representan cada emoción, destacando cómo estas se manifiestan en la realización de cada actividad. Los datos recopilados ofrecen una visión integral del comportamiento emocional del grupo, permitiendo observar las tendencias emocionales específicas en cada ejercicio.

A partir de esta información, la ilustración 35 utiliza un gráfico de barras para mostrar cómo se distribuyen las emociones según los estilos de aprendizaje en cada actividad. Este enfoque destaca la predominancia de ciertas emociones, así como la ausencia o menor

intensidad de otras, según las muestras recolectadas. De esta manera, se ilustra cómo los estilos de aprendizaje no solo influyen en la dinámica de las actividades, sino también en las respuestas emocionales de los estudiantes, permitiendo analizar con mayor claridad la relación entre ambos factores.

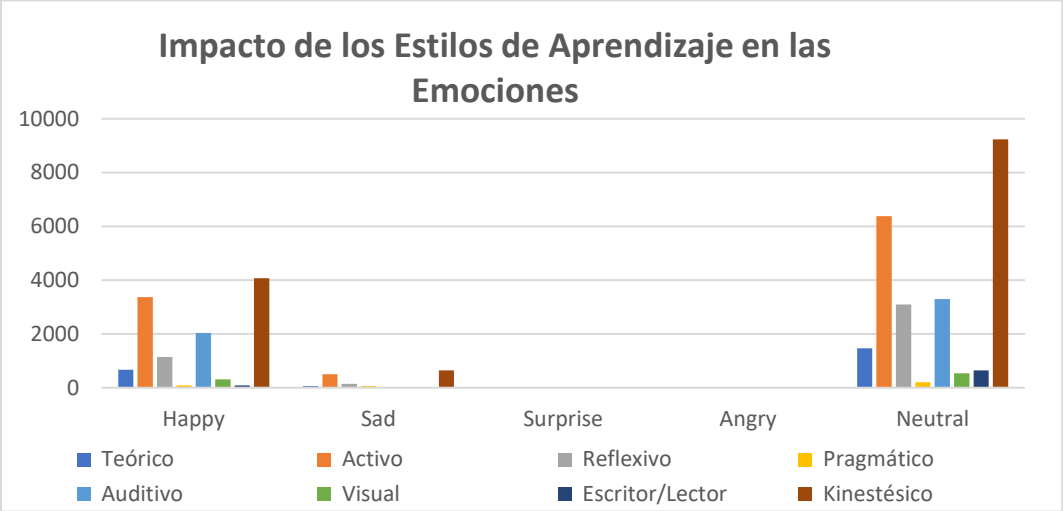

Ilustración 35: Emociones grupales según los estilos de aprendizaje

9 Análisis De Los Resultados

9.1 Análisis de resultados: Estilos de aprendizaje

En esta sección, se analiza la distribución de los estilos de aprendizaje de los estudiantes evaluados, considerando los resultados obtenidos en el apartado 8.1: Estilos de aprendizaje de cada estudiante. Este análisis se basa en la identificación de estilos a través de dos instrumentos: el Test CHAEA, que clasifica a los estudiantes en categorías Teórico, Activo, Reflexivo y Pragmático; y el Test VARK, que distingue entre estilos Auditivo, Visual, Escritor/Lector y Kinestésico. El propósito de este apartado es comprender las preferencias de aprendizaje predominantes entre los estudiantes y determinar tendencias significativas en los estilos identificados. Este conocimiento resulta esencial para diseñar estrategias pedagógicas que se adapten a las características individuales y grupales del aula, promoviendo un aprendizaje efectivo y significativo.

9.1.1 Distribución de Estilos CHAEA

El análisis revela que el estilo de aprendizaje predominante entre los estudiantes evaluados (ver tabla 4) es el Activo, con 14 estudiantes identificados bajo esta categoría. Este resultado sugiere una preferencia significativa por actividades dinámicas y experimentales, que involucran acción y participación.

Le sigue el estilo Reflexivo, con 6 estudiantes, indicando que un grupo menor prefiere analizar y observar antes de tomar decisiones o participar en actividades.

El estilo Teórico cuenta con 4 estudiantes, mostrando que hay quienes prefieren un enfoque lógico y estructurado.

Finalmente, el estilo Pragmático es el menos común, con solo 1 estudiante, lo que podría indicar una baja preferencia por enfoques enfocados en la aplicación inmediata y práctica de lo aprendido.

9.1.2 Distribución de Estilos VARK

En cuanto a los estilos del Test VARK, se observa que el Kinestésico es el más reconocido, con 16 estudiantes. Este resultado subraya la tendencia hacia un aprendizaje físico y experiencial, donde el movimiento y la manipulación son esenciales para la comprensión.

El Auditivo es el segundo estilo más frecuente, con 7 estudiantes, lo que indica una inclinación hacia el aprendizaje a través de la escucha activa.

Los estilos Visual y Escritor/Lector son los menos comunes, con 1 estudiante cada uno, lo que refleja una preferencia menor por el aprendizaje basado en imágenes o la lectura/escritura en este grupo.

9.2 Análisis de Resultados: Estilos de Aprendizaje y Emociones

En este apartado, se presenta un análisis detallado que combina los estilos de aprendizaje predominantes con las emociones manifestadas durante actividades específicas, como se describe en el apartado 8.2: Estilos de Aprendizaje y Emociones.

9.2.1 Emociones Predominantes

La emoción Neutral es la más recurrente en todas las actividades, indicando que los estudiantes, en su mayoría, mantuvieron una actitud de equilibrio o sin cambios emocionales significativos.

Las emociones positivas, como Happy, están presentes con mayor frecuencia en actividades Kinestésicas y Activas, lo que sugiere que los estudiantes disfrutan más de tareas dinámicas y prácticas.

Las emociones Sad y Angry tienen menor representación, lo que indica que las actividades propuestas no generan niveles altos de frustración o tristeza.

9.2.2 Patrones por Actividad y Estilo de Aprendizaje

Actividades Kinestésicas: Generaron el mayor número de emociones Happy, lo que confirma que los estudiantes se sienten más comprometidos en actividades físicas o manipulativas.

Actividades Auditivas: Muestran una tendencia hacia emociones más equilibradas, con altos valores en Neutral y moderados en Happy.

Actividades Reflexivas y Teóricas: Aunque generan emociones Neutral, las emociones Happy también están presentes, aunque en menor medida.

El análisis muestra que las emociones positivas están asociadas principalmente a actividades prácticas y dinámicas, como las Kinestésicas y Activas. Por otro lado, actividades más pasivas, como las Auditivas y Reflexivas, generan emociones más equilibradas. Estos resultados son útiles para ajustar las estrategias pedagógicas, potenciando aquellas actividades que generan más emociones positivas y explorando formas de hacer más atractivas las actividades que no logran el mismo impacto emocional.

9.2.3 Resultados por actividad

9.2.3.1 Emociones en Actividad Uno (CHAEA)

Emociones más frecuentes:

Neutral (10,856): Predominó significativamente, mostrando una respuesta emocional equilibrada durante actividades relacionadas con la teoría CHAEA.

Happy (5,302): Fue la emoción positiva más recurrente, evidenciando satisfacción o motivación en estas actividades.

Emociones menos frecuentes:

Surprise (47): Indica un bajo nivel de novedad o sorpresa en estas tareas.

Angry (275): Aunque baja en comparación, su presencia puede señalar momentos puntuales de frustración.

9.2.3.2 Emociones en Actividad Dos (VARK)

Emociones más frecuentes:

Neutral (13,915): Se mantuvo como la emoción predominante, lo que podría reflejar un estado de concentración o rutina en estas actividades.

Happy (6,498): Destaca como la emoción positiva principal, indicando un buen grado de aceptación hacia las actividades relacionadas con VARK.

Emociones menos frecuentes:

Sad (709): Una leve alza en comparación con la Actividad Uno, lo que puede señalar diferencias en la percepción de las tareas según estilos VARK.

Surprise (2): Nula relevancia, lo que refuerza que estas actividades tienen un enfoque menos inesperado o innovador.

9.2.3.3 Emociones en Actividad Tres

Emociones más frecuentes:

Neutral (12,182): Siguió siendo la emoción predominante.

Happy (2,285): Aunque menor que en las actividades anteriores, sigue reflejando momentos positivos para los estudiantes.

Emociones menos frecuentes:

Angry (25): Muestra que esta emoción negativa tiene una incidencia mínima en esta actividad.

Surprise (4): Su baja frecuencia indica que estas actividades tampoco generan niveles altos de asombro.

El análisis muestra que las emociones Neutral y Happy dominan en todas las actividades, mientras que las emociones negativas, como Sad y Angry, son escasas. Esto sugiere que las actividades propuestas están alineadas con las preferencias y necesidades de aprendizaje de los estudiantes, minimizando las respuestas emocionales negativas y promoviendo estados de satisfacción o equilibrio.

Los estilos de aprendizaje teóricos (CHAEA) y prácticos (VARK) tienen un impacto diferenciado en la expresión emocional de los estudiantes. Actividades relacionadas con estilos más dinámicos y personalizados (como en VARK) parecen fomentar más emociones positivas que las relacionadas con teorías generales (como CHAEA).

9.2.4 Emociones grupales según su estilo de aprendizaje

Al analizar la tabla y la ilustración de Emociones grupales según los estilos de aprendizaje, se observa que los estilos que generaron más emociones felices fueron Visual , Kinestésico y Auditivo , con 312 , 4065 y 2038 muestras respectivamente. Esto sugiere que los estudiantes que prefieren estos estilos de aprendizaje experimentarán una mayor satisfacción emocional durante las actividades. Los estilos Visual y Auditivo se caracterizan por una alta estimulación sensorial, donde las experiencias visuales y auditivas son clave para el aprendizaje, lo que puede generar emociones positivas como felicidad. El estilo Kinestésico, al involucrar movimiento y acción, también facilita la participación lo que puede contribuir a una mayor felicidad al ver resultados tangibles de su esfuerzo.

En cuanto a las emociones neutrales, los estilos Teórico, Reflexivo y Auditivo mostraron un mayor número de respuestas neutrales, con 1466 , 3092 y 3297 muestras respectivamente. Esto podría deberse a que los estudiantes en estos estilos se concentren más en el análisis y la reflexión durante las actividades. En el caso del estilo Teórico, los participantes pueden estar completamente enfocados en la resolución de problemas abstractos o teóricos, lo que puede generar una respuesta emocional moderada. Los estudiantes con el estilo Reflexivo probablemente están más involucrados en pensar profundamente sobre la actividad, lo cual puede generar una emoción neutral debido a la falta de estímulos emocionales fuertes. Por otro lado, aunque el estilo Auditivo también muestra emociones neutrales, esto podría ser debido a la naturaleza más centrada en la escucha, donde

los participantes se concentran en procesar información sin involucrarse de manera emocional tan intensa.

Finalmente, el Pragmático fue el que generó un mayor número de respuestas tristes, con 82 muestras, lo que podría reflejar la frustración de los participantes cuando no logran aplicar conceptos prácticos de manera inmediata o efectiva. Los estudiantes de este estilo suelen buscar soluciones concretas a los problemas, y cuando no alcanzan los resultados esperados, la frustración puede generar emociones negativas, como tristeza.

10 Conclusiones

Se lograron identificar las características más relevantes de las actividades escolares en función de los estilos de aprendizaje predominantes (CHAEA y VARK). Este análisis permitió determinar que los estilos Activo y Kinestésico son los más comunes en el grupo de estudiantes, lo que subraya la efectividad de actividades dinámicas e interactivas. Asimismo, se evidenció la necesidad de diversificar las estrategias pedagógicas para integrar mejores estilos menos representados, como Visual y Escritor/Lector. Esto demuestra un entendimiento profundo de cómo adaptar las actividades escolares para maximizar su impacto en diferentes perfiles de aprendizaje.

El asistente virtual AVREA fue diseñado con éxito, integrando tecnologías avanzadas de reconocimiento facial y análisis emocional, junto con las teorías pedagógicas CHAEA y VARK. Este sistema no solo identifica los estilos de aprendizaje de los estudiantes, sino que también adapta actividades educativas que optimizan su experiencia y motivación. La inclusión de un componente emocional en la personalización de actividades marcó un avance significativo en la interacción entre tecnología y pedagogía.

A través de pruebas realizadas con 25 estudiantes, AVREA demostró su efectividad al relacionar estilos de aprendizaje con emociones durante actividades educativas. Los resultados destacaron cómo los estilos Activo y Kinestésico fomentan emociones positivas como la felicidad, mientras que otros estilos, como Pragmático, requieren ajustes para reducir emociones negativas. Estas evaluaciones no solo validaron la funcionalidad del sistema, sino que también permitieron identificar áreas de mejora, como la incorporación de nuevas emociones y la optimización del análisis de datos, proyectando su utilidad en diversas asignaturas y contextos educativos.

El desarrollo del asistente virtual AVREA ha permitido demostrar que es posible personalizar la orientación de actividades educativas según los estilos de aprendizaje de los estudiantes, integrando teorías pedagógicas como CHAEA y VARK con tecnologías avanzadas de reconocimiento facial y análisis emocional. Este sistema representa una herramienta innovadora para los docentes, facilitando la implementación de estrategias educativas adaptadas a las necesidades individuales y emocionales de los estudiantes.

Los resultados obtenidos evidencian que los estilos de aprendizaje activos y kinestésicos predominan en el grupo de estudiantes analizados, lo cual subraya la efectividad de actividades prácticas, interactivas y dinámicas para este perfil. Sin embargo, la presencia significativa de estilos reflexivos y auditivos también recalca la necesidad de diversificar las estrategias pedagógicas, garantizando que todos los estudiantes se beneficien de una educación inclusiva. La baja representación de los estilos visual y escritor/lector plantea un desafío importante, ya que sugiere la necesidad de diseñar metodologías innovadoras que estimulen y desarrollen estas preferencias, o bien reconocer que estos estilos podrían ser menos comunes en el grupo estudiado.

El análisis de las emociones durante las actividades permitió identificar que las emociones positivas, como la felicidad, están más asociadas a actividades kinestésicas y activas, mientras que las actividades pragmáticas y escritor/lector generan menores niveles de compromiso emocional. Este hallazgo refuerza la importancia de diseñar actividades que no solo respondan a los estilos de aprendizaje predominantes, sino que también promuevan emociones positivas que fortalezcan el bienestar de los estudiantes y su motivación hacia el aprendizaje.

La medición de emociones también destacó que los estudiantes tienden a mostrar expresiones faciales neutrales durante momentos de concentración, lo que sugiere que el sistema debe incorporar herramientas complementarias para capturar de manera más precisa las emociones y sentimientos subyacentes. Además, se identificó la necesidad de incluir emociones como el aburrimiento, que puede ser un indicador crítico de desconexión o falta de interés en las actividades. Incorporar esta emoción al sistema no solo enriquecerá el análisis emocional, sino que permitirá realizar ajustes en tiempo real para mantener la atención y el compromiso de los estudiantes.

La integración de los test CHAEA y VARK fue fundamental para identificar los estilos de aprendizaje predominantes y su relación con las emociones. Estos instrumentos proporcionaron una base teórica sólida que permitió personalizar las actividades escolares y ajustar las metodologías de enseñanza según las necesidades de los estudiantes. Al combinar esta información con el análisis de emociones, se ofrece una perspectiva más integral del proceso de aprendizaje, lo cual tiene un impacto significativo en la pedagogía moderna. Este enfoque fomenta la interacción entre estudiantes y docentes, promoviendo un ambiente educativo más inclusivo, dinámico y emocionalmente positivo.

En términos pedagógicos, AVREA no solo mejora la experiencia de aprendizaje al personalizar las actividades, sino que también optimiza la experiencia emocional de los estudiantes. Esto representa un avance significativo en la integración de tecnología en la educación, al proporcionar herramientas que permitan un enfoque holístico del aprendizaje. Además, este sistema ofrece la posibilidad de proyectar su uso a nivel institucional, beneficiando tanto a docentes como a estudiantes al promover una enseñanza adaptativa y basada en evidencia.

10.1 Conclusión General

AVREA constituye un aporte relevante en el ámbito educativo, demostrando que la tecnología puede ser una aliada en la personalización del aprendizaje. Este asistente virtual, al combinar estilos de aprendizaje y emociones, ofrece a los docentes un recurso valioso para adaptar las actividades escolares y mejorar el compromiso emocional de los estudiantes. Aunque los resultados son prometedores, futuras implementaciones deben incluir nuevas emociones y herramientas para comprender mejor los sentimientos de los estudiantes, garantizando una experiencia de aprendizaje más enriquecedora, inclusiva y efectiva.

11 Trabajos futuros

En el desarrollo de AVREA se vislumbran diversas oportunidades de mejora y ampliación que podrían enriquecer significativamente su funcionalidad y utilidad en entornos educativos. Una de las primeras propuestas es la inclusión de una sexta emoción, el aburrimiento, para complementar las cinco emociones actualmente reconocidas. Esta adición

permitiría un análisis más profundo del estado emocional de los estudiantes durante las actividades, identificando posibles áreas de mejora en el diseño de estas.

Asimismo, se propone explorar nuevos métodos de reconocimiento de emociones, como los sistemas auditivos, que podrían analizar tonos de voz, inflexiones y patrones de habla para identificar emociones en tiempo real. Tecnologías como el análisis de audio mediante redes neuronales y la integración de micrófonos adaptados serían clave en este enfoque, ampliando las capacidades de AVREA hacia un sistema multimodal de reconocimiento emocional.

Otra área crítica de mejora es la optimización del proceso de recolección y análisis de datos. Actualmente, AVREA genera un archivo Excel con el registro de emociones, pero este formato limita el análisis eficiente. En futuros desarrollos, sería ideal implementar un sistema integrado que no solo almacene los datos, sino que también los procese y presente estadísticas claras, como porcentajes de tiempo en cada emoción y patrones emocionales a lo largo de las actividades. Esto permitiría al docente obtener una perspectiva inmediata y valiosa sobre el desempeño y las emociones de los estudiantes.

Además, se propone un sistema que facilite el cargue y configuración de nuevas actividades, expandiendo el alcance de AVREA más allá de la asignatura de tecnología hacia otras áreas del conocimiento, como ciencias, matemáticas o literatura. Este enfoque multidisciplinario no solo diversificaría el uso del asistente, sino que también aumentaría su impacto en la formación integral de los estudiantes.

También se sugiere ampliar el rango de investigación sobre el comportamiento del sistema y las necesidades educativas, lo que permitiría identificar mejoras continuas. Es crucial que AVREA siga evolucionando y adaptándose, convirtiéndose en una herramienta cada vez más útil para los docentes y enriquecedora para los estudiantes.

Por último, el futuro de AVREA también debe enfocarse en aprovechar el potencial del machine learning para mejorar tanto el reconocimiento de emociones como la personalización de las actividades. Investigar cómo la integración de la inteligencia artificial con la educación puede revolucionar el aprendizaje es un campo vasto y prometedor. AVREA es solo una aproximación inicial, pero representa un ejemplo claro de cómo estas tecnologías pueden contribuir al progreso educativo.

12 REFERENCIAS

.

1. Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Zheng, X. (2016). TensorFlow: A system for large-scale machine learning. *12th {USENIX} Symposium on Operating Systems Design and Implementation (OSDI} 16)*, 265-283.
2. Accom, (2024) ¿Qué es un asistente virtual? Accom Agencia digital de ventas. https://www.we-accom.com/tendencias/que-es-un-asistente-virtual/#:~:text=Un%20asistente%20virtual%20puede%20ser,y%20están%20en%20continua%20evolución.
3. Aguilar Mejía, J. R. (2022) Uso de asistente virtual para el aprendizaje de temas selectos de la física (Tesis de maestría). Tecnológico de Monterrey, México. https://repositorio.tec.mx/handle/11285/636395
4. Arturo Castro, V. (2013). Enseñanza de tecnologías de la información y comunicación mediante el uso de herramientas virtuales en una institución de nivel superior no universitario. [PDF]
5. Bashyal, S., & Venayagamoorthy, G. K. (2008). Recognition of facial expressions using Gabor wavelets and learning vector quantization. *Engineering Applications of Artificial Intelligence*, 21(7), 1056-1064.
6. Bethel University Online. (s. f.). The Importance of Small Class Sizes in Education. Recuperado de https://online.betheluniversity.edu/articles/small-class-sizes-in-education
7. Blanco (2023). Chat Bot: Asistentes Virtuales en la Educación. Up Informa diario digital. https://upinforma.com/nuevo/info.php?cat=opinion&id=1307
8. Bradski, G., & Kaehler, A. (2008). *Learning OpenCV: Computer vision with the OpenCV library*. O'Reilly Media, Inc.
9. Brownlee, J. (2019). *Deep learning for computer vision: Image classification, object detection, and face recognition in Python with Keras, PyTorch, and TensorFlow*. Machine Learning Mastery.
10. Cabero, J., & Marín, V. (2019). Las TIC en la educación y su impacto en los estilos de aprendizaje. *Revista de Educación y Tecnología*, 23(1), 45-62.

11. Calderón Angulo, JA, & Rosales Chalen, AD (2024). estilo de aprendizaje VARK y su influencia en el rendimiento académico de los estudiantes de la carrera de pedagogía de la actividad física y deporte de la universidad técnica de Babahoyo, periodo académico octubre 2023 - marzo 2024 http://dspace.utb.edu.ec/handle/49000/16262
12. Campaña, L., Castro, M., Guerrero, L., & Hernández, A. (2018). Utilización de software libre. Atlante Cuadernos de Educación y Desarrollo. Revista: Atlante (marzo). https://www.eumed.net/rev/atlante/2018/03/software-libre-geometria.html
13. Casos-Gerónimo, E. R., Romero-Rodríguez, F. R., & Cieza-Mostacero, S. E. (2022). Asistente Virtual para Mejorar el Aprendizaje en Anatomía en los grados 5to y 6to de primaria en una Institución Educativa de Trujillo. En Memorias de la Vigésima Primera Conferencia Iberoamericana en Sistemas, Cibernética e Informática (CISCI 2022) (pp. 146-151). https://doi.org/10.54808/CISCI2022.01.146
14. Chollet, F. (2015). Keras. GitHub. *https://github.com/fchollet/keras*.
15. Cira Thania, P. M., Quispe-Paiva , M., Carhuas-Arzapalo, I. A., & Ríos-Cataño , C. (2021). Estilos de aprendizaje en estudiantes universitarios: una revisión descriptiva de la literatura. Desafíos, 12(2), 144–151. https://doi.org/10.37711/desafios.2021.12.2.345
16. Corvalán Cantero, J. A., Gómez Giménez, R. E., & Arrua Ginés, J. L. (2022). Automatización del hogar mediante asistente virtual en placa computadora simple. FPUNE Scientific, (16). http://servicios.fpune.edu.py:83/fpunescientific/index.php/fpunescientific/article/view/231
17. Pérez, M., Villalonga, P., Guillén, J., & Baños, J. (2020). La integración de las TIC en el aula: Un derecho para el alumnado y una necesidad para el profesorado. *Revista Iberoamericana de Tecnología Educativa*, 15(3), 27-38.
18. Déniz, O., Bueno, G., Salido, J., & De la Torre, M. (2011). Face recognition using Histograms of Oriented Gradients. *Pattern Recognition Letters*, 32(12), 1598-1603.
19. Django Software Foundation. (s.f). Meet Django. Recuperado el 12 de Julio de 2024, de https ://www .djangoproject .com/

20. Django Software Foundation. (s.f.). *Models | Django documentation*. Recuperado el 12 de Julio de 2024, de https://docs.djangoproject.com/en/stable/topics/db/models/
21. Django Software Foundation. (s.f.). *Templates | Django documentation*. Recuperado el 12 de Julio de 2024, de https://docs.djangoproject.com/en/stable/topics/templates/
22. Django Software Foundation. (s.f.). *The Django admin site | Django documentation*. Recuperado el 12 de Julio de 2024, de https://docs.djangoproject.com/en/stable/ref/contrib/admin/
23. Django Software Foundation. (s.f.). *Views | Django documentation*. Recuperado el 12 de Julio de 2024, de https://docs.djangoproject.com/en/stable/topics/http/views/
24. Entrena, S., & Javier, R. (2012). Face detection in C.
25. Figueroa, M. Á. H., Báez, R. G. V., & Rangel, J. O. C. (2020). Propuesta de asistente virtual basado en inteligencia artificial en la integración de un brazo robótico para aplicaciones en la industria 4.0. Research in Computing Science, 149(8), 353-364. https://rcs.cic.ipn.mx/rcs/2020_149_8/Propuesta%20de%20asistente%20virtual%20basado%20en%20inteligencia%20artificial%20en%20la%20integracion.pdf
26. Finn, J. D., & Achilles, C. M. (1999). Tennessee's Class Size Study: Findings, Implications, Misconceptions. Educational Evaluation and Policy Analysis, 21(2), 97-109.
27. Fleming, N., & Mills, C. (1992). Not Another Inventory, Rather a Catalyst for Reflection. *To Improve the Academy*, 11, 137-155.
28. Fleming, Neil D. (2001). Teaching and Learning Styles: VARK Strategies, Editorial Christchurch, Nueva Zelanda
29. GeeksforGeeks. (2023,). Python Web Development - Django. GeeksforGeeks. Recuperado el 17 de noviembre de 2024, de https://www.geeksforgeeks.org/python-web-development-django/
30. Gil Vera, V. D. (2021) Metodología para predecir el desempeño estudiantil en cursos universitarios virtuales a distancia (Tesis de doctorado). Universidad Nacional de Colombia, Medellín, Colombia. http://repositorio.unal.edu.co/handle/unal/81113
31. Herrera Torres, L. & E. Buitrago Bonilla, R. (2019). Emociones en la educación en Colombia, algunas reflexiones. http://surl.li/cztyff

32. Honey, P. y Mumford, A. (1994). Los Estilos de Aprendizaje: Procedimientos de diagnóstico y mejora. Bilbao: Editions Mensajero https://www.researchgate.net/publication/311452891_Los_Estilos_de_Aprendizaje_Procedimientos_de_diagnostico_y_mejora
33. Iglesias Torres, M. (2018). Presencia de las emociones a lo largo de la jornada escolar. Una propuesta educativa para cuatro años. http://surl.li/xzqnfy
34. Izquierdo-Valladarez, J.I., & Cuenca-Tapia, J.P. (2020). Reconocimiento de objetos del hogar, usando redes neuronales convolucionales para personas con discapacidad visual.
35. Jiang, S., & Zavala, V.M. (2021). Convolutional Neural Nets: Foundations, Computations, and New Applications. *ArXiv, abs/2101.04869*.
36. Kolb, D. A. (1984). Experiential learning: Experience as the source of learning and development. Prentice-Hall.
37. Kumar, M.S., M.Chitra, Sharma, A., Ragavendiran, S.D., Banappagoudar, S.B., & Kumar, A.N. (2023). RECOGNITION OF EMOTIONS THROUGH SPEECH USING MACHINE LEARNING TECHNIQUES.
38. Li, S., & Deng, W. (2020). Deep facial expression recognition: A survey. *IEEE Transactions on Affective Computing*, 13(3), 1195-1215.
39. Manjarrés-Betancur, R., & Echeverri-Torres, M. M. (2020). Asistente virtual académico utilizando tecnologías cognitivas de procesamiento de lenguaje natural. *Revista Politécnica*, 16(31), 85-96. https://doi.org/10.33571/rpolitec.v16n31a7
40. McKinney, W. (2010). Data Structures for Statistical Computing in Python. *Proceedings of the 9th Python in Science Conference* (pp. 56-61).
41. McKinney, W. (2017). *Python for Data Analysis: Data wrangling with Pandas, NumPy, and IPython*. O'Reilly Media.
42. Microsoft (2022). Asistente Virtual https://www.microsoft.com/es-co/Asistente_virtual - Cortana
43. Ministerio De Educación Nacional. (2022). *Orientaciones curriculares para el área de tecnología e informática en educación básica y media*. https://www.mineducacion.gov.co/1780/articles-411706_recurso_5.pdf

44. Murrieta Ortega, R. (2021). Identificación de los estilos de aprendizaje, estrategia para mejorar la formación de docentes en la escuela normal. *Revista De Estilos De Aprendizaje*, *14*(27), 112–123. https://doi.org/10.55777/rea.v14i27.2611
45. Navas Ten, R. (2020). Metodologías de Reconocimiento facial en modelos bidimensionales (Tesis de pregrado). Universidad Autónoma de Madrid, España. https://repositorio.uam.es/bitstream/handle/10486/693421/navas_ten_raul_tfg.pdf?sequence=1
46. Parra Robledo, R. (2017). Ambientes virtuales de aprendizaje colaborativo desde la web social 2.0. [PDF]
47. Peralta Caballero, A. & Díaz Barriga, F. (2010). Diseño instruccional de ambientes virtuales de aprendizaje desde una perspectiva constructivista. [PDF]
48. PERLADO LAMO DE ESPINOSA, I., Barroso Tristán, J. M., & Trujillo Vargas, J. J. (2023). Evaluación por competencias y estilos de aprendizaje: español. *Revista De Estilos De Aprendizaje*, *16*(32), 104–114. https://doi.org/10.55777/rea.v16i32.4603
49. Pulli, K. (2012). Mobile visual computing. *IEEE Computer Graphics and Applications*, 32(2), 86-90.
50. Quiroga, F. (2020). Medidas de invarianza y equivarianza a transformaciones en redes neuronales convolucionales.
51. Saipullah, K.M. (2012). OpenCV Based Real-Time Video Processing Using Android Smartphone.
52. Sanz, C., Gibelli, T., Lovos, E., Suárez, P., Saldivia, Álvaro, Condó, S., Cariaga, R., Luján Colueque, M., & Cuevas, V. (2017). Tecnologías innovadoras como mediadoras de procesos de enseñanza y aprendizaje. [PDF]
53. Sariyanidi, E., Gunes, H., & Cavallaro, A. (2015). Automatic analysis of facial affect: A survey of registration, representation, and recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(6), 1113-1133.
54. Saz-Pérez, F. & Pizà-Mir, B. (2024). Estudio exploratorio sobre usos y adaptaciones de las tareas escolares ante la irrupción de software de inteligencia artificial generativa. osf.io
55. Sethi, Karan. (2020). Emotion Detection Using OpenCV and Keras. Medium. Emotion Detection Using OpenCV and Keras | by Karan Sethi | The Startup | Medium

56. Sobrevilla Reséndiz, E. (2021). Asistente virtual para la selección de objetos de aprendizaje bajo la influencia del estilo de enseñanza-aprendizaje y perfil de personalidad del estudiante en un ambiente LMS (Tesis de maestría). Tecnológico Nacional de México, Madero – Tamaulipas, México. https://rinacional.tecnm.mx/handle/TecNM/2892
57. T2ó. (2021). Chatbots y Asistentes de voz en el sector Educación. T2ó. https://www.t2o.com/t2o-industry/chatbots-asistentes-de-voz-sector-educacion/
58. Torres-Carrión, P., Soledad González, C., Rodrigo Barba-Guamán, L., & Cecilia Torres-Torres, A. (2017). Experiencia Afectiva de Usuario (UAX): Modelo desde sensores biométricos en aula de clase con plataforma gamificada de Interacción Gestual. http://surl.li/ccjhwh
59. Vaishali, & Singh, S. (2019). Real-Time Object Detection System using Caffe Model.
60. Vera Briones, R. J. (2018). Los estilos de aprendizaje en el desempeño escolar en matemática de los estudiantes de décimo año de educación general básica (Tesis de pregrado). Universidad de Guayaquil, Guayaquil, Ecuador. http://repositorio.ug.edu.ec/handle/redug/54591
61. Villegas-Ch., W.E., Garcia-Ortiz, J.V., & Sánchez-Viteri, S. (2023). Identification of Emotions from Facial Gestures in a Teaching Environment With the Use of Machine Learning Techniques. *IEEE Access*, *11*, 38010-38022.
62. Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1, I-I.
63. Zheng Lim, J., Mountstephens, J., & Teo, J. (2020). Emotion Recognition Using Eye-Tracking: Taxonomy, Review and Current Challenges. ncbi.nlm.nih.gov

13 Anexos

13.1 Anexo 1

Datos AVREA (2024) https://pedagogicaedu-my.sharepoint.com/:x:/g/personal/cdcarrenog_upn_edu_co/EbqljFl2Zj1HilD3wxzby1MBPglBGinotqUJERkUqUcYGQ?e=ZpKGgS