



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Doctorado

Modelo de comportamiento del movimiento ocular para la
identificación de la sintomatología depresiva

presentada por

M.C. Derick Axel Lagunes Ramírez

como requisito para la obtención del grado de
Doctor en Ciencias la Computación

Director de tesis

Dr. Juan Gabriel González Serna

Codirector de tesis

Dra. Leonor Rivera Rivera

Cuernavaca, Morelos, México. Abril de 2025.

	ACEPTACIÓN DE IMPRESIÓN DEL DOCUMENTO DE TESIS DOCTORAL	Código: CENIDET-AC-006-D20
		Revisión: 0
	Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4	Página 1 de 1

Cuernavaca, Mor., a 10 de junio de 2025


DR. CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO
P R E S E N T E

AT'n: DR. JUAN GABRIEL GONZÁLEZ SERNA
PRESIDENTE DEL CLAUSTRO DOCTORAL DEL
DEPARTAMENTO DE CIENCIAS COMPUTACIONALES

Los abajo firmantes, miembros del Comité Tutorial del estudiante **M.C. Derick Axel Lagunes Ramírez** manifiestan que después de haber revisado el documento de tesis titulado **"Modelo de Comportamiento del Movimiento Ocular para la Identificación de la Sintomatología Depresiva"**, realizado bajo la dirección del **Dr. Juan Gabriel González Serna** y la codirección de la **Dra. Leonor Rivera Rivera**, el trabajo se ACEPTA para proceder a su impresión.

A T E N T A M E N T E

Excelencia en Educación Tecnológica®
"Conocimiento y Tecnología al Servicio de México"



DR. JUAN GABRIEL GONZÁLEZ SERNA
TECNM/CENIDET


DRA. LEONOR RIVERA RIVERA
INSTITUTO NACIONAL DE SALUD PÚBLICA


DR. NIMROD GONZÁLEZ FRANCO
TECNM/CENIDET


DR. DANTE MÚJICA VARGAS
TECNM/CENIDET


DRA. MARÍA YASMÍN HERNÁNDEZ PÉREZ
TECNM/CENIDET


DR. JOSÉ ALEJANDRO REYES ORTIZ
UNIVERSIDAD AUTÓNOMA METROPOLITANA

c.c.p: C Verónica Sotelo Boyas/ Jefa del Departamento de Servicios Escolares
c.c.p: C Née Alejandro Castro Sánchez / Jefe del Departamento de Ciencias Computacionales
c.c.p: Expediente



Centro Nacional de Investigación y Desarrollo tecnológico
Subdirección Académica

Cuernavaca Mor, 11/junio/2025

Oficio No. SAC/135/2025

Asunto: Autorización de impresión de tesis

**DERICK AXEL LAGUNES RAMIREZ
CANDIDATO AL GRADO DE DOCTOR
EN CIENCIAS DE LA COMPUTACIÓN
P R E S E N T E**

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **"Modelo de Comportamiento del Movimiento Ocular para la Identificación de la Sintomatología Depresiva"**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.


Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica®

"Conocimiento y Tecnología al Servicio de México"

**CARLOS MANUEL ASTORGA ZÁRAGOZA
SUBDIRECTOR ACADÉMICO**



c.c.p. Departamento de Ciencias Computacionales
Departamento de Servicios Escolares

CMAZ/lmz



2025
Año de
La Mujer
Indígena

Interior Internado Palmira S/N, Col. Palmira,
C. P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 4104,
e-mail: acad_cenidet@tecnm.mx tecnm.mx | cenidet.tecnm.mx

cenidet
Centro Nacional de Investigación y Desarrollo Tecnológico



DEDICATORIAS

A mis padres, Sonia y Derick, cuyo apoyo incondicional y amor han sido el motor que me ha impulsado a lo largo de mi vida. A mi hermano Alexis, un pilar fundamental en muchos aspectos de mi camino, cuya fortaleza y compañía siempre han sido invaluableles. A mi esposa Nancy, quien con su amor, apoyo incansable y palabras de aliento, me ha acompañado con dedicación durante cada etapa de mis estudios de posgrado, animándome siempre a seguir adelante.

A mis amigos y compañeros, quienes con su compañía, opiniones y conocimientos han enriquecido mi vida, aportando perspectivas valiosas y motivación en este recorrido. A todos mis profesores, desde la educación básica hasta el centro de investigación, quienes han dejado una huella imborrable en mí al transmitir no solo conocimientos, sino también valores que han moldeado mi desarrollo académico y personal.

Y a la generación 2020-2024 del Departamento de Ciencias de la Computación, integrada por valiosos colegas de diversas líneas de investigación, con quienes compartí retos, aprendizajes y experiencias.

AGRADECIMIENTOS

Expreso mi más profundo agradecimiento a todas las personas que, de una u otra forma, me brindaron su apoyo y confianza durante el desarrollo de esta tesis.

Agradezco sinceramente al Consejo Nacional de Humanidades, Ciencias y Tecnologías (Conahcyt) por el respaldo económico proporcionado, sin el cual no habría sido posible llevar a cabo este trabajo.

Extiendo mi gratitud al Tecnológico Nacional de México, campus Centro Nacional de Investigación y Desarrollo Tecnológico (TecNM/CENIDET), y a todo su personal por ofrecerme la oportunidad de realizar mis estudios de doctorado en Ciencias de la Computación en un entorno de excelencia académica y profesional.

De manera especial, quiero expresar mi agradecimiento a mi Director de Tesis, el Dr. Juan Gabriel González Serna, por su invaluable dedicación, guía y apoyo durante cada etapa de mi estancia en el TecNM/CENIDET. También deseo agradecer profundamente a mi Codirectora, la Dra. Leonor Rivera Rivera, cuya experiencia y orientación fueron esenciales en el desarrollo de esta investigación.

Asimismo, reconozco con gratitud a los miembros de mi comité de tesis: el Dr. Nimrod González Franco, el Dr. Dante Mújica Vargas, la Dra. María Yazmín Hernández Pérez y el Dr. José Alejandro Reyes Ortiz, quienes aportaron su tiempo, conocimientos y experiencia para realizar revisiones, ofrecer sugerencias y brindar consejos que enriquecieron este trabajo.

Finalmente, quiero agradecer a mis compañeros del seminario de la línea de Tecnologías Inteligentes de Software del TecNM/CENIDET. Sus ideas, conocimientos y aportaciones, tanto directas como indirectas, contribuyeron significativamente al desarrollo de este proyecto, haciendo de este proceso una experiencia de aprendizaje colectivo invaluable.

RESUMEN

El presente estudio explora el uso de métricas de seguimiento ocular combinadas con algoritmos de aprendizaje automático supervisado para identificar síntomas depresivos en población joven. A través de la exposición a estímulos visuales emocionales y la recolección de datos oculares, se analizaron diversas características visuales como la duración de fijaciones y la velocidad de sacadas. Aunque no todas las métricas resultaron estadísticamente significativas, algunas mostraron diferencias claras entre participantes con y sin síntomas depresivos, especialmente en función del tipo y contexto cultural de los estímulos presentados.

Se evaluaron múltiples clasificadores, incluyendo Random Forest (RF), Support Vector Machine (SVM), Gradient Boosting (GB) y redes neuronales multicapa (MLP), destacando RF con una precisión promedio del 84%. Asimismo, se desarrolló un modelo por ensamble ponderado para mejorar el desempeño general, aunque su efectividad fue limitada al enfrentarse a nuevos subconjuntos de datos. El estudio también señala el potencial de transformar datos de seguimiento ocular en representaciones visuales, como mapas de calor o espectrogramas, para ser utilizados por modelos de aprendizaje profundo.

Como resultado práctico, se concretó el desarrollo una herramienta de apoyo al diagnóstico basada en una plataforma web, que actualmente opera con un sensor de eye-tracking GP3 HD. Se proyecta la integración de visión por computadora mediante cámaras web convencionales, lo que facilitaría una implementación más económica y accesible. Este enfoque ofrece una alternativa no invasiva para la detección temprana de síntomas depresivos en jóvenes, con aplicaciones en contextos clínicos y educativos.

Finalmente, se discuten las implicaciones éticas del uso de datos biométricos en salud mental, haciendo hincapié en la necesidad de garantizar el consentimiento informado, la privacidad y la protección contra el uso indebido de esta tecnología.

.

ABSTRACT

This study explores the use of eye-tracking metrics combined with supervised machine learning algorithms to identify depressive symptoms in young populations. By exposing participants to emotional visual stimuli and capturing ocular data, various visual features, such as fixation duration and saccade velocity, were analyzed. While not all metrics showed statistically significant differences, certain features, depending on the stimulus type and cultural context, effectively differentiated between individuals with and without depressive symptoms.

Several classifiers were evaluated, including Random Forest (RF), Support Vector Machine (SVM), Gradient Boosting (GB), and multilayer perceptrons (MLP), with RF achieving the highest average accuracy (84%). Additionally, a weighted ensemble model was implemented to improve performance, though its generalization capacity was limited on unseen datasets. The study also highlights the potential of transforming eye-tracking data into behavioral visual representations, such as heatmaps or spectrograms, to train deep learning models like convolutional neural networks.

As a practical outcome, a diagnostic support tool was developed using a web-based platform, currently relying on a GP3 HD eye-tracking sensor. Future development envisions the integration of computer vision with standard webcams, enabling a more accessible and cost-effective implementation. This non-invasive approach offers a promising solution for the early detection of depressive symptoms in youth, with potential applications in both clinical and educational settings.

Finally, the ethical implications of using biometric data in mental health assessment are discussed, emphasizing the importance of informed consent, data privacy, and protection against misuse of the technology.

Contenido

1. CAPÍTULO 1. INTRODUCCIÓN.....	1
1.1 ANTECEDENTES	4
1.2 TRABAJOS RELACIONADOS	7
1.2.1 Trabajos relacionados en el centro de investigación	7
1.2.2 Trabajos relacionados en el estado del arte	7
1.3 PLANTEAMIENTO DEL PROBLEMA	9
1.3.1 Análisis del Problema y Pregunta de Investigación	11
1.3.2 Complejidad del Problema.....	11
1.3 OBJETIVO GENERAL	12
1.3.1 Objetivos particulares.....	12
1.4 JUSTIFICACIÓN	13
1.4.1 APLICACIONES PRÁCTICAS DE LA HERRAMIENTA A DESARROLLAR.....	15
1.4.2 BENEFICIOS	17
1.4.3 VINCULACIÓN CON EL SECTOR PRODUCTIVO	17
1.5 ALCANCES	18
1.5.2 LIMITACIONES.....	19
1.6 ESTRUCTURA DEL DOCUMENTO	19
2. CAPÍTULO 2. MARCO TEÓRICO	21
2.1 SALUD MENTAL Y DEPRESIÓN	21
2.1.1 Tipos de depresión	21
2.1.2 Síntomas y criterios de diagnóstico	23
2.1.3 Causas de la depresión y Factores de riesgo	24
Relación del estado cognitivo con la regulación de emociones	25
2.1.4 Métodos de diagnóstico convencionales.....	26
Inventario de depresión de Beck	27
Escala de valoración de Hamilton para la evaluación de la depresión.....	27
Depression, Anxiety, Stress Scale (DASS-21)	28
Electroencefalograma	28
2.2 ESTADO MENTAL, COGNITIVO Y AFECTIVO	29
2.2.1 Estado mental.....	29
2.2.2 Estado cognitivo	29
2.2.3 ESTADO AFECTIVO	30
2.2.4 Estado cognitivo y su relación con la depresión	30

2.2.5 Estado afectivo y su impacto en la salud mental.....	31
2.3 SEGUIMIENTO OCULAR Y SU APLICACIÓN EN LA EVALUACIÓN DE LA DEPRESIÓN	32
2.3.1 Principios del seguimiento ocular	32
2.3.2 Relación entre seguimiento ocular y procesos cognitivos/emocionales.....	33
2.4 MÉTRICAS Y ANÁLISIS DE SEGUIMIENTO OCULAR	33
2.4.1 Puntos de fijación y visión.....	34
2.4.2 Métricas de fijación y visión	35
Mapas de calor	35
Mapas de rutas	37
Áreas de interés	38
Parpadeos	39
Tiempo hacia la primera fijación	40
Recuento de visión.....	40
Tiempo gastado	41
Distancia a la pantalla	41
2.4.3 Pupila y pupilometría.....	42
2.5 APRENDIZAJE SUPERVISADO	43
3. CAPÍTULO 3. METODOLOGÍA	45
3.1 ENFOQUE DE INVESTIGACIÓN	45
3.1.1 Diseño del estudio.....	45
3.2 ESTADO DEL ARTE	46
3.2.1 Fuentes de información	46
Criterios de inclusión	46
Criterios de exclusión	46
Palabras clave y cadenas de búsqueda	46
Recopilación de estudios	47
Selección de los estudios	47
3.2.1 Análisis del estado del arte.....	49
Comportamiento ocular y diferencias por edad	49
Estudios de correlación entre el comportamiento ocular y la depresión	50
Modelos para la detección de la depresión a través de características oculares	52
3.2.3 Discusión del estado del arte	58
Limitaciones	59
Alcance de la aplicación	59
3.3 DEFINICIÓN DE LA POBLACIÓN Y MUESTRA	60
3.3.1 Colaboración con el Instituto Nacional de Salud Pública y Comité de Ética	61

3.3.2 Protocolo de acción en casos de depresión	61
3.4 MATERIAL E INSTRUMENTOS DE RECOLECCIÓN DE DATOS.....	62
3.4.1 Estímulos emocionales	62
3.4.2 Cuestionarios	64
3.4.3 Proceso de inducción emocional	65
3.4.4 Hardware	66
Factores ambientales para toma de muestras.....	67
3.4.5 Software	68
Gazepoint GazeControl	68
Python 3.....	70
UXLab.....	71
Generador de métricas visuales PIE.....	73
UXLite.....	75
3.5 PROCEDIMIENTO DE LA RECOLECCIÓN DE DATOS	77
3.5.1 Cuestionario de inicio	79
3.5.2 Explicación de la prueba e indicaciones.....	79
3.5.3 Actividad de visualización libre.....	81
3.5.4 Cuestionario de finalización.....	82
3.5.5 Actualización del repositorio de datos.....	83
3.6 INGENIERÍA DE CARACTERÍSTICAS	84
3.6.1 Extracción de características	84
3.6.2 Análisis y preprocesamiento de los datos.....	93
Manejo de valores atípicos	93
Limpieza de los datos.....	94
Normalización de los datos	95
Aumento de datos	95
Estructura del vector de datos	95
3.6.3 Selección de características	97
3.7 ALGORITMOS DE APRENDIZAJE AUTOMÁTICO	97
Optimización de Hiperparámetros.....	98
Evaluación de rendimiento de los algoritmos.....	99
Seleccionar el mejor algoritmo	99
3.7 HERRAMIENTA DE APOYO AL DIAGNOSTICO	100
Desarrollo del Software	100
3.8 RESUMEN DE LA METODOLOGÍA DE SOLUCIÓN	101
4. CAPÍTULO 4. RESULTADOS.....	102

4.1 RESULTADOS DE RECOLECCIÓN DE DATOS	102
4.1.1 <i>Resumen de la muestra</i>	103
4.2 ANÁLISIS Y PROCESAMIENTO DE DATOS POSITIVOS Y NEGATIVOS.....	105
4.2.1 <i>Limpieza de los datos de datos positivos y negativos</i>	106
4.2.2 <i>Análisis y manejo de valores atípicos de datos positivos y negativos</i>	107
4.2.3 <i>Análisis de normalidad de datos positivos y negativos</i>	110
4.2.4 <i>Análisis de características de datos positivos y negativos</i>	112
4.3 ANÁLISIS Y PROCESAMIENTO DE CONJUNTO DE DATOS ALTERNATIVO	120
4.3.1 <i>Limpieza de datos</i>	121
4.3.2 <i>Manejo de valores atípicos</i>	121
4.3.3 <i>Preparación de datos</i>	121
4.3.4 <i>Balance de las clases</i>	122
4.3.5 <i>Selección de características</i>	123
4.4 RESULTADOS DE SELECCIÓN DE CARACTERÍSTICAS	125
4.4.1 <i>Comparativa de características seleccionadas con el estado del arte</i>	127
4.5 ENTRENAMIENTO DE ALGORITMOS DE APRENDIZAJE AUTOMÁTICO Y RESULTADOS.....	128
4.5.1 <i>Conjuntos de datos para pruebas</i>	128
4.5.2 <i>Selección de algoritmos para pruebas de predicción</i>	128
4.5.3 <i>Selección de y ajuste de hiperparámetros para los algoritmos</i>	129
Hiperparámetros de SVM	131
Hiperparámetros de Random Forest	132
Hiperparámetros de Gradient Boosting	132
Hiperparámetros de MLP	133
Mejores hiperparámetros	134
4.7 RESULTADOS DE APRENDIZAJE AUTOMÁTICO	134
4.7.1 <i>Presentación del script para pruebas de predicción</i>	135
<i>Librerías utilizadas</i>	135
<i>Definición de la clase principal y constructor</i>	136
<i>Main</i>	140
4.7.2 <i>EVALUACIÓN DEL RENDIMIENTO DE LOS ALGORITMOS DE APRENDIZAJE AUTOMÁTICO</i>	141
4.7.3 <i>RESULTADOS DEL ENTRENAMIENTO Y VALIDACIÓN CRUZADA DE LOS ALGORITMOS</i>	141
4.7.4 <i>Otros resultados</i>	143
El problema de clasificación y propuesta de modelo de ensamble	145
CAPÍTULO 5. DISCUSIÓN	149
6. CAPÍTULO 6. CONCLUSIONES Y TRABAJOS FUTUROS	152

6.1 APORTACIONES	153
6.1.1 SOFTWARE	153
6.1.2 MÉTODOS.....	153
6.1.3 PUBLICACIONES.....	154
6.2 TRABAJOS FUTUROS	156
7. CAPÍTULO 7. REFERENCIAS	157
8. CAPÍTULO 8. ANEXOS.....	174

Lista de figuras

FIGURA 1.1: ARQUITECTURA DE UXLAB, DE FOUILLOUX QUIROZ, 2018, TODOS LOS DERECHOS RESERVADOS 2018. TOMADO CON PERMISO DEL AUTOR.....	5
FIGURA 2.1: MODELO DE INTERACCIÓN INTEGRADOR ENTRE EL CONTROL COGNITIVO, LOS SESGOS COGNITIVOS Y LA REGULACIÓN EMOCIONAL EN LA DEPRESIÓN. ADAPTADO DE (VILLALOBOS ET AL., 2021)	26
FIGURA 2.2: CLASIFICACIÓN DE ESTADOS MENTALES, DE (SORIANO, 2018), TODOS LOS DERECHOS RESERVADOS 2018. TOMADO CON PERMISO DEL AUTOR.	30
FIGURA 2.3: ESQUEMA DEL FUNCIONAMIENTO DEL SEGUIMIENTO OCULAR CON UN SENSOR INFRARROJO (D. FOUILLOUX, 2018). TOMADO CON PERMISO DEL AUTOR.....	32
FIGURA 2.4: ESQUEMA DE COORDENADAS DE VISIÓN EN UNA PANTALLA	34
FIGURA 2.5: EJEMPLO DE MAPA DE CALOR: REALIZADO CON LOS DATOS DE ET DE UNA PRUEBA DE EVALUACIÓN UX	36
FIGURA 2.6: EJEMPLO DE MAPA DE RUTAS: REALIZADO CON LOS DATOS DE ET DE UNA PRUEBA DE EVALUACIÓN UX	37
FIGURA 2.7: EJEMPLO DE ÁREAS DE INTERÉS: REALIZADO CON LOS DATOS DE ET DE UNA PRUEBA DE EVALUACIÓN UX.....	39
FIGURA 2.8: REPRESENTACIÓN GRÁFICA DE UN PARPADEO	39
FIGURA 2.9: ESQUEMA DE TIEMPO HACIA LA PRIMERA FIJACIÓN	40
FIGURA 2.10: ESQUEMA DE RECUENTO DE VISIÓN	41
FIGURA 2.11: ESQUEMA DE TIEMPO GASTADO.....	41
FIGURA 2.12: ESQUEMA DE LA DISTANCIA ENTRE EL USUARIO Y LA PANTALLA.....	42
FIGURA 2.13: REPRESENTACIÓN DE LA MEDICIÓN DEL TAMAÑO DE LA PUPILA, ADAPTADO DE (CASIA 2005)	42
FIGURA 2.14: ESQUEMA DEL PROCESO DE APRENDIZAJE SUPERVISADO, ADAPTADO DE (NGUYEN ET AL., 2017)	44
FIGURA 3.1: DIAGRAMA DE FLUJO DE LOS ELEMENTOS DE INFORMACIÓN PRISMA VER. 2020.....	48
FIGURA 3.2: ALGUNOS ESTÍMULOS DE LA BASE DE DATOS IAPS. FUENTE: INTERNATIONAL AFFECTIVE PICTURE SYSTEM (IAPS): AFFECTIVE RATINGS OF PICTURES AND INSTRUCTION MANUAL, (LANG ET AL., 2008).....	63
FIGURA 3.3: ESQUEMA DEL PIE. (SORIANO TERRAZAS, 2018) . TOMADO CON PERMISO DEL AUTOR.....	66
FIGURA 3.4: ESQUEMA DEL PROCESO DE INDUCCIÓN EMOCIONAL PIE ADAPTADO AL CONTEXTO DE ESTA INVESTIGACIÓN	66
FIGURA 3.5: INTERFAZ GRÁFICA DE GAZEPOINT CONTROL.....	69
FIGURA 3.6: ARQUITECTURA DE UXLAB	71
FIGURA 3.7: FUNCIONALES DE UXLAB	72
FIGURA 3.8: INTERFAZ DEL SOFTWARE PIE PARA LA GENERACIÓN DE MÉTRICAS OCULARES	73
FIGURA 3.9: INTERFAZ DEL SOFTWARE UXLITE PARA LA GRABACIÓN DE DATOS DE SEGUIMIENTO OCULAR EN FUNCIÓN DE UNA INDUCCIÓN EMOCIONAL	75
FIGURA 3.10: FLUJO DEL PROCESO DE UXLITE	76
FIGURA 3.11: ESQUEMA DEL PROCESO DE RECOLECCIÓN DE DATOS.....	77
FIGURA 3.12: DIAGRAMA DE FLUJO DEL PROCESO DE PRUEBAS DE SEGUIMIENTO OCULAR	78
FIGURA 3.13: PANTALLA DE CALIBRACIÓN CON 5 PUNTOS.....	80

FIGURA 3.14: PANTALLA DE PRUEBA DE CALIBRACIÓN	80
FIGURA 3.15: ESQUEMA DEL PROCESO DE LA PRUEBA DE INDUCCIÓN EMOCIONAL	82
FIGURA 3.16: ESQUEMA DEL PROCESO DE LA PRUEBA DE INDUCCIÓN EMOCIONAL	84
FIGURA 3.17: ESQUEMA DEL PROCESO DE DEFINICIÓN Y OBTENCIÓN DE DATOS DE LOS EVENTOS DE UNA PRUEBA DE INDUCCIÓN EMOCIONAL	85
FIGURA 3.18: ESQUEMA DEL PROCESO DE PROCESAMIENTO DE CARACTERÍSTICAS ADICIONALES EN FUNCIÓN DE DATOS CRUDOS DEL SEGUIMIENTO OCULAR	86
FIGURA 3.19: METODOLOGÍA DE SOLUCIÓN PROPUESTA.....	101
FIGURA 4.1: EVIDENCIAS DE TOMA DE MUESTRAS.....	102
FIGURA 4.2: ESQUEMA DE GENERACIÓN DE ARCHIVOS DF_POSITIVO Y DF_NEGATIVO	106
FIGURA 4.3: BOXPLOT PARA EL CONJUNTO DE DATOS	107
FIGURA 4.4: DISTRIBUCIÓN DE PRESENTACIÓN DE LOS VALORES P DE LAS CARACTERÍSTICAS EN LA MATRIZ.....	113
FIGURA 4.5: MATRIZ DE VALORES P RESULTADO DE LA PRUEBA U EN LAS CARACTERÍSTICAS DE TODAS LAS CLASES	114
FIGURA 4.6: VISUALIZACIÓN DE LAS DOS PRIMERAS COMPONENTES PRINCIPALES CLASIFICADAS EN 2 CLASES	115
FIGURA 4.7: VISUALIZACIÓN DE LAS DOS PRIMERAS COMPONENTES PRINCIPALES CLASIFICADAS EN 5 CLASES (0 = SD, 1 = DL, 2 = DM, 3 = DS Y 4 = DES)	116
FIGURA 4.8: GRÁFICO DE LA PROPORCIÓN DE LA VARIANZA EXPLICADA POR EL PCA EN EL CONJUNTO DE DATOS DF_NEGATIVO.	116
FIGURA 4.9: GRÁFICO DE LA PROPORCIÓN DE LA VARIANZA EXPLICADA POR EL PCA EN EL CONJUNTO DE DATOS DF_POSITIVO..	117
FIGURA 4.10 GRÁFICO DE CARGAS DE LAS CARACTERÍSTICAS EN LOS DOS PRIMEROS PC PARA EL CONJUNTO DE DATOS DF_NEGATIVO.	118
FIGURA 4.11 GRÁFICO DE CARGAS DE LAS CARACTERÍSTICAS EN LOS DOS PRIMEROS PC PARA EL CONJUNTO DE DATOS DF_POSITIVO.	119
FIGURA 4.12 DIAGRAMA DE CLASE PARA CLASIFICADORDEPRESION	136

Lista de tablas

TABLA 2.1: CLASIFICACIÓN DE PUNTAJE DE INSTRUMENTOS BDI-II, HDRS Y DASS.....	28
TABLA 2.2: CLASIFICACIÓN DE LOS ESTADOS AFECTIVOS, DE (SORIANO, 2018), TODOS LOS DERECHOS RESERVADOS 2018. TOMADO CON PERMISO DEL AUTOR	30
TABLA 3.1: RESULTADOS OBTENIDOS DE BUSCAR LAS CADENAS 1 Y 2 EN DISTINTOS BUSCADORES ACADÉMICOS	47
TABLA 3.2: ÍNDICES DE LAS FUENTES DE INFORMACIÓN RECOPIADAS	48
TABLA 3.3: ESTUDIOS REVISADOS SOBRE LA CORRELACIÓN DE LA DEPRESIÓN CON LOS MOVIMIENTOS OCULARES.....	50
TABLA 3.4: ESTUDIOS REVISADOS SOBRE LA DETECCIÓN DE LA DEPRESIÓN CON LOS MOVIMIENTOS OCULARES	53
TABLA 3.5: CRITERIOS DE SELECCIÓN CONSIDERADOS	60
TABLA 3.6: EVALUACIÓN Y COMPARACIÓN DE IAPS.....	64
TABLA 4.1: RESULTADOS DEL INSTRUMENTO DASS-21 SOBRE LA POBLACIÓN DE ESTUDIO	104
TABLA 4.2: RESULTADOS DEL INSTRUMENTO DASS-21 SOBRE LA POBLACIÓN DE ESTUDIO FILTRANDO POR SEXO	104
TABLA 4.3: OBSERVACIONES DE DATOS ATÍPICOS EN AMBOS CONJUNTOS DE DATOS	108
TABLA 4.4: UMBRALES DE DATOS ATÍPICOS EN AMBOS CONJUNTOS DE DATOS.....	109
TABLA 4.5: DISTRIBUCIÓN DE LAS CLASES EN LOS DATOS	109
TABLA 4.6: RESULTADOS DE PRUEBAS DE NORMALIDAD UNIVARIANTE	110
TABLA 4.7: ESTADÍSTICOS DESCRIPTIVOS DE LOS DATOS	111
TABLA 4.8: RESULTADOS DE LA PRUEBA U PARA LAS CARACTERÍSTICAS DE LOS CONJUNTOS DE DATOS PARA 2 CLASES.....	112
TABLA 4.9: RESULTADOS DEL ANÁLISIS PCA EN CIFRAS PARA AMBOS CONJUNTOS DE DATOS	117
TABLA 4.10: CARACTERÍSTICAS QUE SI SON SIGNIFICATIVAMENTE DIFERENTES ENTRE LAS DOS CLASES	123
TABLA 4.11: DIFERENCIAS ENTRE GRUPOS (DEPRESIÓN Y SIN DEPRESIÓN) EN EL CONJUNTO DE DATOS COMPUESTO.CSV	126
TABLA 4.12: CARACTERÍSTICAS QUE SE OBSERVARON EN EL ESTADO DEL ARTE	127
TABLA 4.13: RESUMEN DE LOS CONJUNTOS DE DATOS UTILIZADOS PARA LAS PRUEBAS DE CLASIFICACIÓN	128
TABLA 4.14: CONFIGURACIÓN DE HIPERPARÁMETROS PARA CADA ALGORITMO DE ML UTILIZADO.....	131
TABLA 4.15: RESULTADOS DE ALGORITMOS DE ML.....	141
TABLA 4.16: RESUMEN DE LOS MEJORES DESEMPEÑOS PARA LA CLASIFICACIÓN DE DF_NEGATIVOS Y DF_POSITIVOS	144
TABLA 4.17: RESUMEN DE LOS CONJUNTOS DE DATOS UTILIZADOS PARA LAS PRUEBAS DE CLASIFICACIÓN CON EL CLASIFICADOR ENSAMBLE	147

Capítulo 1. Introducción

Es evidente que muchas disciplinas han adoptado la inteligencia Artificial (IA) y el Aprendizaje Automático (ML, por sus siglas en inglés) para implementar soluciones a diversas problemáticas en cada dominio. El uso de tecnologías con IA y ML ha traído cambios revolucionarios que redefinen la forma que se aborda un problema específico, la toma de decisiones y la automatización.

En el ámbito de la salud, la inteligencia artificial (IA) y el aprendizaje automático (ML, por sus siglas en inglés) se emplean para analizar grandes conjuntos de datos, lo que facilita el diagnóstico de enfermedades, la creación de planes de tratamiento personalizados y el descubrimiento de nuevos medicamentos. Los avances recientes en estas tecnologías han generado investigaciones prometedoras con un impacto positivo en la salud global, lo que sugiere que la implementación del ML en diversos sectores continuará expandiéndose de manera exponencial.

Sin embargo, el uso de ML requiere entrenamiento riguroso y datos precisos para las computadoras. Puede entenderse al comparar cómo los seres humanos razonamos sobre las diferencias entre objetos cotidianos. Por ejemplo, sabemos que perros y gatos comparten ciertas características, como altura y peso, y que existen rangos típicos para estos valores según el animal. Nuestra experiencia nos permite inferir que un animal de 15 kilogramos y 65 cm de altura probablemente sea un perro, mientras que uno de 5 kilogramos y 30 cm de altura podría ser un gato o incluso un perro pequeño. Sin embargo, incluso los humanos podemos equivocarnos al identificar objetos según ciertas condiciones y, en ocasiones, necesitamos más información para tener un contexto más completo. Lo mismo ocurre con las máquinas: Requieren datos para aprender, pero también pueden cometer errores dependiendo de la calidad y cantidad de la información.

El éxito de un modelo predictivo depende en gran medida de la calidad de los datos de entrenamiento, ya que estos permiten que el algoritmo de ML identifique patrones y haga predicciones precisas adaptadas a las particularidades del problema. Y es importante tener en cuenta que, en el ámbito del uso de la tecnología en la salud, los modelos de ML deben de ser lo más confiables posibles para evitar problemas. Un ejemplo de esto es la detección de depresión en jóvenes, donde la calidad de los datos es fundamental para garantizar resultados confiables y útiles.

La salud mental es crucial y se reconoce como un objetivo global por la organización mundial de la salud (OMS) para muchos países. Una de las principales preocupaciones en este ámbito es la depresión ya que ha ido en aumento especialmente después de los años de la pandemia mundial por Covid-19 en el contexto global como se demuestra en los estudios de Khubchandani et al., en el 2021 y Ludwig-Walz et al., en el 2022 donde se muestra el aumento en los casos de depresión en la población de Estados Unidos y en la población joven de Europa durante el encierro en la pandemia. En el contexto Mexicano el estudio de Galindo-Vázquez et al., en el 2020 demuestra situaciones similares en el territorio nacional.

La depresión es una enfermedad mental, muy común que afecta a 3.8% de la población mundial (OMS 2021). También es prevalente en la que la persona afectada presenta emociones y sentimientos negativos junto con síntomas físicos. Es muy importante aclarar que, aunque la depresión puede ser una enfermedad diagnosticada (Desorden Depresivo Mayor o MDD por sus siglas en inglés) también puede ser reconocida como un estado emocional propio del ser humano. Es por este motivo que uno puede sentirse deprimido, pero puede no tener un trastorno mental.

La depresión como enfermedad, está asociada con alteraciones del lóbulo temporal, el hipocampo, los neurotransmisores (serotonina, norepinefrina y dopamina), algunos desordenes hormonales (cortisol, tiroides) y cambios en las etapas REM del sueño y los ritmos circadianos. La enfermedad debe ser diagnosticada por un experto a través de diversas pruebas, entrevistas e instrumentos diseñados para ese propósito. Generalmente cuando una persona es diagnosticada es debido al tiempo y severidad de síntomas como:

- | | |
|---|---|
| <ul style="list-style-type: none"> • Estado de desánimo • Pérdida de interés • Cambios de apetito • Sentimientos de culpa • Trastornos del sueño | <ul style="list-style-type: none"> • Poca concentración • Inquietud • Lentitud • Pérdida de energía • Pensamientos recurrentes de suicidio |
|---|---|

Puede volverse un problema crónico si se supera y afecta el rendimiento de quien la padece, afecta no solo al paciente, sino también a sus familias, amigos y a la economía en general. Dado que los jóvenes generalmente disfrutan de buena salud física, la depresión se destaca como una de las principales causas de enfermedad y discapacidad en este grupo (OMS 2020). Los trastornos emocionales pueden afectar profundamente actividades cotidianas como el trabajo escolar, la asistencia y la interacción social, lo que puede aumentar el aislamiento y la soledad, lo cual puede conducir incluso a las autolesiones y a intentos de suicidio.

Tradicionalmente, para evaluar a un paciente sospechoso de tener depresión, se consideran sus circunstancias, historial biográfico, síntomas, historial familiar y antecedentes de consumo de alcohol y drogas. También se realiza un examen del estado mental para buscar la presencia de pensamientos negativos, desesperanza, pesimismo, autolesiones, suicidio, e incluso pruebas de electroencefalografía (EEG). El uso de escalas de valoración de la depresión es otra práctica común. Sin embargo, no se utilizan por si solas para diagnosticar la depresión, sino para evaluar la intensidad de los síntomas y apoyar un diagnóstico posterior. Ejemplos de estas escalas incluyen la Escala de Hamilton para la Depresión (Hamilton 1960) o el Inventario de Depresión de Beck (BDI-II) (Beck, Steer, and Brown 1996).

Sin embargo, gracias a los avances tecnológicos podríamos estar cada vez más cerca de evaluar a los pacientes al utilizar sus patrones de comportamiento, por ejemplo: Con el uso de EEG se han demostrado las características de actividad cerebral que son propias de esta enfermedad mental (Olbrich and Arns 2013) y además se ha demostrado la efectividad de entrenar algoritmos de ML con estos datos para la predicción de depresión en personas que no han sido diagnosticadas (Wu et al., 2021). Sin embargo, las aplicaciones cotidianas de esta tecnología se ven reducidas debido al factor invasivo de los sensores de EEG.

Por lo que otros indicadores del comportamiento humano como lo es el movimiento ocular podrían ser útiles para reconocer patrones depresivos en las personas sin depender de sensores invasivos como lo son los cascos o gorros de electroencefalografía, ya que el seguimiento ocular solo requiere como mínimo un dispositivo con cámara de video hacia los ojos de la persona.

La accesibilidad de la tecnología de seguimiento ocular ha aumentado significativamente, gracias a la comercialización y simplificación de los sensores de seguimiento ocular, junto con los avances en la tecnología de cámaras digitales (Ho 2014).

Ultimadamente el eye-tracking (ET) permite analizar el movimiento de los ojos mientras los usuarios observan estímulos visuales. Examinar características oculares, como la dilatación de las pupilas, las fijaciones, las sacadas y los parpadeos, proporciona información valiosa sobre los estados afectivos, el comportamiento y la atención de los usuarios (Lu et al., 2015).

Gracias a que los trastornos mentales se caracterizan por el comportamiento anormal de las personas, es posible utilizar estos patrones de movimientos oculares para distinguir entre una persona que sufre un episodio depresivo a diferencia de otra que no lo tiene. En este documento, buscamos demostrar los resultados obtenidos al utilizar algoritmos de ML para predecir la depresión a través de datos de seguimiento ocular recopilados de una población joven. El objetivo final es contribuir a la identificación de comportamientos oculares asociados con la depresión en jóvenes y establecer una base para futuros estudios sobre este tema.

1.1 Antecedentes

Dentro del grupo de investigación de Tecnologías Inteligentes de Software (TIS) del TecNM/CENIDET se investigan los temas de la usabilidad y la experiencia de usuario ya que están directamente relacionados con el área de Interacción Humano Computadora. En el centro de investigación se han trabajado métodos e investigaciones relacionadas a la medición de la calidad de la experiencia de usuario y el comportamiento humano. Los siguientes trabajos antecedentes se identifican y se describen con el propósito de ampliar el panorama del uso de las tecnologías en investigaciones de la salud.

En el trabajo para grado doctoral de Alejandro Sanchez (2016) “Evaluación centrada en el usuario de sistemas de recomendación sensibles al contexto: efecto de interfaces multimodales interactivas y esquemas de explicación en la experiencia del usuario”, se describen experimentos que utilizaron sistemas de recomendación sensibles al contexto, que utilizan interfaces de realidad aumentada, el trabajo buscaba obtener una valoración

cuantitativa de aspectos subjetivos de la experiencia del usuario (efectividad, confianza y satisfacción) al emplear cuestionarios como instrumentos de evaluación.

La tesis doctoral “Metodología UXEeg para la evaluación de la Experiencia del Usuario en personas con discapacidad a partir de Interfaces Cerebro Computadora” de González Franco (2017) desarrolla la metodología UXEeg para evaluar la experiencia del usuario en personas con discapacidad mediante Interfaces Cerebro-Computadora. Su estudio demuestra que los datos EEG pueden estimar la cognición del usuario al identificar patrones cerebrales asociados a concentración y distracción.

Además, en el trabajo de Arana Llanes (2020) titulado “Explotación de Estados Cognitivos en Entornos E-Learning a Partir de BCI No Invasivas” se desarrollaron métodos para la evaluación de estados mentales cognitivos de estudiantes que usaban plataformas de e-learning en función de sensores Brain-Computer Interface (BCI).

Los antecedentes previamente mencionados representan aproximaciones al análisis del comportamiento humano con un propósito específico y constituyeron bases sólidas para el desarrollo de la metodología propuesta en este trabajo.

Los siguientes antecedentes están relacionados con el software UXLab el cual comenzó con la tesis “Método para integrar y sincronización de datos EEG y multimedia para su aplicación en un ambiente de evaluación para la experiencia del usuario” por Fouilloux Quiroz (2018). En esta tesis se desarrolló un método y sistema para sincronizar y grabar flujos multimedia y datos de diferentes sensores fisiológicos y biométricos resultado del proceso de evaluación de la experiencia del usuario (ver Figura 1.1).




Figura 1.1: Arquitectura de UXLab, de Fouilloux Quiroz, 2018, Todos los derechos reservados 2018. Tomado con permiso del autor

UXLab incluye un módulo de seguimiento ocular donde se utiliza el sensor “the eye tribe” modelo ET1000 y por medio de una secuencia de imágenes tomadas por éste, se obtiene la trayectoria de la mirada en forma de puntos. También se generan mapas de calor a partir de los puntos de visión y la utilización de una fórmula de distribución gaussiana multivariable.

Posteriormente varios trabajos actualizaron o agregaron funcionalidades a UXLab:

- En el trabajo de Maestría de Garcia Pinzon (2020) “Procesamiento de datos fisiológicos para detectar estados afectivos en el proceso de evaluación de la experiencia de usuario” Se incluyeron nuevos módulos de sensores fisiológicos y depuración del código de UXLab.
- Lagunes Ramirez (2020) en su tesis de Maestría “Método para analizar el movimiento ocular de usuarios para generar métricas y correlación con estados emocionales y cognitivos”, integro módulos de captura y procesamiento de datos de ET, lo cual relaciona las métricas oculares con los elementos que observan los usuarios durante una evaluación de UX.
- Morales Morante (2021) agrego módulos de procesamiento de señales EEG para identificar emociones durante las grabaciones de datos con UXLab con su tesis de Maestría “Metodología para el preprocesamiento y clasificación de datos fisiológicos multimodales basado en el modelo Valencia-Excitación”.
- En la tesis de Maestría de Hernandez Perez (2022) “Método para la detección de emociones mediante el análisis de expresión facial en videos de evaluación de la experiencia de usuario”, se describe como se adiciona en UXLab el módulo de reconocimiento de emociones con modelos de detección emocional en función de patrones del rostro del usuario.
- En la tesis de Maestría titulada “Método para cartografiar mapas de calor emocionales mediante la fusión de datos de seguimiento ocular y datos de valencia/activación” de Andrade Perez (2023), se reacondicionaron algunos de los algoritmos de métricas oculares para incorporar la visualización de emociones calculados con EEG.
- Jaime Diaz (2023), se encargó de actualizar los métodos de reconocimiento de emociones con un enfoque multimodal en la tesis de Doctorado titulada “Metodología

para el reconocimiento de emociones basado en datos fisiológicos multimodales mediante la selección de características relevantes”.

El software UXLab fue la base de la obtención de datos para este proyecto de investigación y fue modificado con el fin de agregar nuevas funcionalidades relacionadas a la recolección de datos de ET.

1.2 Trabajos relacionados

A continuación, se describen varios trabajos relacionados con el tema de investigación, estos se dividen en: 1) Trabajos relacionados en el centro de investigación (TecNM/Cenidet) y 2) Trabajos relacionados en el estado del arte.

1.2.1 Trabajos relacionados en el centro de investigación

En el trabajo de maestría de Cuevas Chavez (2020), se enfocó en la detección automática del trastorno de ansiedad generalizada mediante el monitoreo de datos fisiológicos a través de dispositivos vestibles. Se desarrolló un modelo de comportamiento para adultos jóvenes en conjunto con un dispositivo Fitbit para registrar variables como la frecuencia cardíaca, la actividad física y la calidad del sueño.

Otros trabajos han estudiado los estados mentales cognitivos de una población como la identificación y clasificación de estados cognitivos en estudiantes que utilizan plataformas de aprendizaje virtual, con el objetivo de optimizar su atención y concentración para un aprendizaje efectivo (Arana Llanes 2020) y una metodología para complementar la evaluación de la experiencia de usuario mediante el reconocimiento del estado cognitivo de carga de trabajo a partir de datos fisiológicos (Banuelos Lozoya 2023).

1.2.2 Trabajos relacionados en el estado del arte

En el estado del arte, estudios similares han utilizado características de seguimiento ocular, a menudo combinadas con otros tipos de datos, para predecir la depresión en diversas

poblaciones y contextos. Emplearon varios algoritmos, incluidos: Maquinas de Vector Soporte (SVM), diferentes implementaciones de redes neuronales (NN), métodos de ensamblado, regresión logística (LR) y k-vecinos más cercanos (KNN).

En el trabajo de Alghowinem et al., (2013) se utilizaron datos de video para clasificar sujetos como deprimidos o no deprimidos mediante SVM y un modelo híbrido, donde se logró una precisión del 75.00%. Su estudio destacó que las personas deprimidas tenían aperturas palpebrales más pequeñas y duraciones de parpadeo más largas. De manera similar, Stolicyn, Steele, y Seriès (2020) alcanzaron una precisión del 79.00% al emplear un algoritmo SVM con un núcleo gaussiano, donde se clasificó la depresión según datos de movimiento ocular y comportamiento.

En contraste, los trabajos de Zhu et al., (2019, 2020) emplearon un método de ensamblado basado en contexto (CBEM) que combina datos de EEG y seguimiento ocular, donde se alcanzó una precisión del 82.50% solo con seguimiento ocular y del 92.65% en combinación con EEG. Encontraron que RF funcionaba mejor con datos no integrados, mientras que SVM con un núcleo de función de base radial sobresalía con datos integrados. En otro trabajo de Alghowinem et al., (2018), los autores lograron una precisión del 86.00% al fusionar características de ojos, habla y movimiento de cabeza con SVM y fusión de decisiones.

En enfoques similares, Shen et al., (2021) lograron una precisión del 77.00 % al clasificar la depresión con datos de rastreo ocular obtenidos de tareas con estímulos emocionales y SVM. por otro lado, Pan et al., (2019) combinaron tiempos de reacción y datos de movimientos oculares para entrenar un algoritmo de SVM, lo cual alcanza el 86.00 % de precisión en la detección de la depresión. Mientras que Wang et al., (2019) fusionaron datos de cuestionarios de autoinforme con rastreo ocular y otras características, esto logró hasta un 93.02 % de precisión con LR.

Otras investigaciones se basaron en enfoques de detección con datos multimodales por ejemplo en los trabajos de: Al-gawwam y Benaissa (2018) donde se centraron en características de parpadeo extraídas de datos de video en el conjunto de datos Audio/Visual Emotion Challenge (AVEC) diseñado para el análisis y reconocimiento de emociones a partir de señales de audio y video (Valstar et al., 2013; Valstar, B. Schuller, et al., 2014), donde se alcanzó un 92.95 % de precisión en tareas de lectura y un 88.00 % en entrevistas con

AdaBoost. Zhu, Y. Wang, et al., (2019) integraron datos de EEG y movimientos oculares con redes neuronales y lograron un 83.42 % de precisión con un algoritmo SVM lineal. Ding et al., (2019) combinaron datos de EEG, rastreo ocular y respuesta galvánica de la piel (GSR) para detectar depresión, con una precisión del 79.63 % con LR.

Otros algoritmos supervisados de Machine Learning fueron utilizados en trabajos como el de Li et al., (2016) donde se emplearon datos de movimientos oculares y KNN, donde se logró un 81.00 % de precisión en la detección de la depresión. Shafiei et al., (2020) usaron una red neuronal recurrente con memoria a corto y largo plazo (RNN-LSTM) con métricas visuales para clasificar la salud mental, dando un 95.00 % de precisión en la predicción del bienestar. Gavrilescu and Vizireanu (2019) utilizaron características oculares y un sistema de red neuronal feedforward (FFNN) para predecir depresión, ansiedad y estrés, con un 87.20 % de precisión en la predicción de la depresión.

Finalmente algunos otros trabajos utilizaron enfoques diferentes al resto como Li et al., (2020) ya que combinaron características de comportamiento ocular con una característica de ancho de banda afectivo mediante un algoritmo de Máquina Extrema de Aprendizaje con Núcleo (KELM), la cual logró un 91.00 % de precisión. De forma similar, en el trabajo de Lu et al., (2020) se alcanzó un 88.55 % de precisión al usar únicamente datos de imágenes oculares. Mientras que en el trabajo de Yuan and Wang (2019) se aplicó una red neuronal a trayectorias de movimientos oculares, y se obtuvo una precisión del 83.17 %.

A pesar de los hallazgos prometedores en la detección de depresión mediante rastreo ocular, existe una notable brecha en la literatura respecto a poblaciones más jóvenes. La mayoría de los estudios se enfocan en adultos, lo cual deja poca investigación sobre cómo estos comportamientos se manifiestan en adolescentes y adultos jóvenes.

1.3 Planteamiento del problema

Hablar de la depresión como un concepto puede referirse a una emoción pasajera, por ejemplo, cuando uno se siente deprimido usualmente se refiere al sentimiento que viene después de experimentar una situación o evento negativo como: Tener un mal día, pelearse con un buen amigo o enfrentar una pérdida. En esos momentos el sentimiento se presenta en la persona, pero usualmente pueden sobrellevarse y regresar a un estado de ánimo neutro.

Sin embargo, la depresión como una enfermedad es un trastorno mental común que se presenta con un estado de ánimo deprimido, pérdida de interés o placer, disminución de la energía, sentimientos de culpa o baja autoestima, trastornos del sueño o del apetito y falta de concentración (Marcus et al., 2012) por más tiempo sin poder superarlo. Este problema puede volverse crónico o recurrente y dar lugar a deterioros sustanciales en la capacidad de una persona para hacerse cargo de sus responsabilidades diarias. Afecta no solo a quien la padece, sino también a sus familias, amigos y la economía en general (Alghowinem et al., 2013).

Tradicionalmente, un experto en salud utilizará el diagnóstico rutinario que compromete la exactitud ya que emplea instrumentos subjetivos como la Escala de Valoración de Hamilton (Hamilton 1960) o el Inventario de Depresión de Beck (Beck et al., 1996), que dependen de las respuestas del paciente y la interpretación del especialista.

A nivel mundial, en el 2015 se estima que la prevalencia de depresión fue del 4,4% y entre 2005 y 2015 se incrementó en un 18,4% (OMS 2017). La depresión es el factor que más contribuye a la discapacidad mundial al aportar el 7,5% de todos los años vividos con discapacidad (YLLDs) y es la principal causa de muertes por suicidio según los reportes del año 2017 de la Organización Mundial de la Salud.

En México, la información estadística sobre salud mental es limitada. En 2022, el 2º Diagnóstico Operativo de Salud Mental y Adicciones (Secretaría de Salud 2022) reportó que alrededor de una quinta parte de la población (24.8 millones) experimenta trastornos mentales y se registró una prevalencia anual de 5.3% (3.6 millones) de casos de depresión y 3.3% (2.2 millones) de ansiedad.

Además, se reportaron 434 establecimientos de atención para salud mental, con 668 psiquiatras y 2172 psicólogos. En paralelo, se registraron aproximadamente 898,000 consultas, lo cual representa solo el 15.48% de la demanda para quienes padecen depresión y ansiedad. Para abordar la demanda del año 2022, cada consultorio debería haber atendido a aproximadamente 13,364 pacientes debido a que por cada 100,000 habitantes existen 0.959 psiquiatras y 3.119 psicólogos.

Estos datos reflejan una brecha significativa entre la demanda de atención en salud mental y la capacidad de respuesta del sistema sanitario, lo que limita el acceso a un diagnóstico y

tratamiento oportuno para muchas personas con depresión. Ante esta problemática, es fundamental explorar alternativas que complementen los métodos tradicionales de diagnóstico y permitan una detección más accesible, objetiva y eficiente.

El uso de herramientas tecnológicas basadas en datos fisiológicos, inteligencia artificial y análisis automatizado de patrones podría representar un avance significativo en la identificación temprana de la depresión. En este contexto, la presente investigación busca desarrollar un enfoque innovador que contribuya a mejorar la detección y el seguimiento de esta enfermedad, lo cual facilitaría intervenciones oportunas y reduce el impacto que tiene en la calidad de vida de los pacientes y en el sistema de salud en general.

1.3.1 Análisis del Problema y Pregunta de Investigación

La pregunta central de esta investigación es: ¿Es posible detectar la depresión en función de los datos de comportamiento ocular de jóvenes mexicanos con sintomatología depresiva? El análisis del estado del arte revela que diversos estudios han abordado la detección de la depresión a través de características del comportamiento de las personas afectadas, al utilizar algoritmos de clasificación combinados con datos del movimiento ocular. En algunas investigaciones, también se integran otras características relacionadas con la depresión, tales como los datos fisiológicos obtenidos del electroencefalograma (EEG), la respuesta galvánica de la piel (GSR), el análisis de expresiones faciales y la postura del sujeto.

A pesar de que algunos estudios reportan una precisión superior al 80%, no se han encontrado trabajos que implementen una herramienta de software centrada en el apoyo a expertos en salud mental para la detección y el seguimiento de la depresión en jóvenes de entre 18 y 29 años. Esta herramienta permitiría observar patrones de comportamiento humano durante la depresión, contribuyendo al diagnóstico y seguimiento de este trastorno mental, lo cual facilitaría la labor de los profesionales de la salud mental.

1.3.2 Complejidad del Problema

Uno de los principales obstáculos en los proyectos de investigación sobre depresión es la escasez de repositorios de datos públicos, principalmente debido a las restricciones impuestas

por la sensibilidad de la información personal y clínica de los participantes. Además, en el estado del arte se identificaron pocos estudios que incluyeran datos de comportamiento ocular; la mayoría de los repositorios de datos disponibles están compuestos por archivos de audio y video de entrevistas o interacciones con pacientes.

Para entrenar un clasificador supervisado, es necesario diseñar, desarrollar y ejecutar una metodología para la obtención de datos de comportamiento ocular de pacientes mexicanos, al seguir estrictamente los protocolos éticos y de salud necesarios para el manejo adecuado de la información y los participantes.

El experimento que se diseñará incluirá técnicas que estimulen características comunes del comportamiento en pacientes con depresión, como se señala en el estado del arte. Una de estas características es el sesgo de atención hacia estímulos negativos, que afecta a las personas con este trastorno. Por ello, se utilizará un paradigma similar al de estudios previos, con estímulos emocionales positivos, neutros y negativos.

Finalmente, para cumplir con los objetivos de este proyecto, será necesario realizar diversos procesos, que incluyen el análisis de las características del comportamiento ocular, la implementación de algoritmos computacionales para la selección de las variables más significativas, y la prueba de diferentes combinaciones de características y algoritmos de clasificación para obtener los mejores resultados en la detección de la depresión.

1.3 Objetivo general

Proponer un modelo computacional de patrones de comportamiento ocular en la depresión clínica para realizar la detección del trastorno y apoyar a expertos psiquiatras en la evaluación y el seguimiento de los pacientes con depresión.

1.3.1 Objetivos particulares

- Diseñar y desarrollar un conjunto de datos de seguimiento ocular a partir de la interacción de un grupo de control y un grupo con depresión clínica (en distintos niveles) con estímulos emocionales, de repositorios validados como IAPS.

- Identificar y caracterizar patrones de comportamiento ocular asociados a distintos niveles de depresión, en función de métricas extraídas del seguimiento ocular y su correlación con escalas clínicas de evaluación como las de Hamilton y Beck.
- Evaluar y seleccionar los algoritmos de ML supervisados más eficaces para la clasificación de niveles de depresión a partir de datos de seguimiento ocular, considerando la evaluación de métricas de los mismos.
- Desarrollar e implementar un modelo computacional basado en patrones de comportamiento ocular que permita la detección de depresión clínica y el seguimiento de pacientes, integrando el modelo en un sistema computacional adaptable a los servicios de salud.
- Validar el modelo propuesto mediante pruebas experimentales con datos reales, evaluando su precisión, sensibilidad y especificidad en la detección de depresión.

1.4 Justificación

En México, datos recientes de la Encuesta Nacional de Salud (ENSANUT) (Shamah-Levy et al., 2020) indican que el 17.9% de las mujeres y el 8.8% de los hombres adultos de 20 años o más presentan sintomatología depresiva. Entre los adolescentes mexicanos, la prevalencia es del 10.8% (Rivera-Rivera et al., 2020). El estudio de Cerecero-García et al., (2020), basado en la ENSANUT desde 2006, evidencia las brechas existentes en el acceso a servicios de salud mental entre distintas regiones y niveles de marginación.

La depresión es una de las principales causas de discapacidad a nivel mundial (National Institute of Mental Health (NIMH) 2021). Puede volverse crónica o recurrente, genera un deterioro significativo en la capacidad de una persona para cumplir con sus responsabilidades diarias (Marcus et al., 2012). En adultos, afecta el desempeño laboral, la capacidad de generar ingresos y su rol dentro del núcleo familiar.

En los jóvenes, la depresión es una de las principales causas de enfermedad y discapacidad. Los trastornos emocionales pueden afectar profundamente actividades cotidianas como el desempeño escolar, la asistencia a clases y la interacción social, lo que puede aumentar el aislamiento y la sensación de soledad (OMS 2020). Esto impacta el desarrollo cognitivo y social. Además, la pandemia de COVID-19 ha incrementado los síntomas de ansiedad y

depresión en la población debido al aislamiento, la incertidumbre económica, los efectos de la enfermedad en la vida diaria y el retraso académico (Galindo-Vázquez et al., 2020).

Uno de los problemas más graves asociados a la depresión es su relación con tendencias suicidas. Se estima que el 60% de las personas que cometen suicidio padecían depresión mayor (Ng, How, and Ng 2017). Cada año, cerca de 800,000 personas se quitan la vida, lo que representa una tragedia que afecta a familias, comunidades y países enteros, con efectos duraderos en quienes quedan atrás. En 2016, el suicidio fue la segunda causa principal de muerte entre personas de 15 a 29 años a nivel mundial (OMS 2019).

El diagnóstico y evaluación de la depresión suelen realizarse mediante instrumentos de autoinforme con escalas de medición clínica. Sin embargo, estudios recientes sobre el comportamiento humano han identificado correlaciones entre los trastornos mentales y patrones de conducta fisiológica. Investigaciones con tecnología de seguimiento ocular han demostrado una relación entre el comportamiento ocular y los estados mentales, cognitivos y emocionales. Se ha observado que ciertos patrones oculares están vinculados con la carga cognitiva (Joseph y Murugesh 2020; Lagunes-Ramírez et al., 2020; Mitre-Hernandez, Covarrubias-Carrillo, and Lara-Alvarez 2020; Zagermann, Pfeil, and Reiterer 2018) y con la respuesta a estímulos emocionales (Gerdes et al., 2020; Lim, Mountstephens, y Teo 2020; Skinner et al., 2018).

Por ejemplo, Arai (2015) encontró una relación entre el número de cambios rápidos en la visión y las lecturas de actividad cerebral (EEG) cuando los usuarios experimentaban dificultad para leer palabras, lo que sugiere un aumento en el esfuerzo cognitivo. Estudios previos han demostrado que las personas con depresión clínica tienden a prestar mayor atención a estímulos negativos y menor atención a estímulos positivos en comparación con individuos sanos (Armstrong y Olatunji 2012; Suslow et al., 2020; Zhao et al., 2019). Estos sesgos atencionales, que dificultan desviar la atención de la información negativa hacia la positiva, juegan un papel clave en la aparición y mantenimiento del trastorno (Vazquez et al., 2016).

Dado que los sesgos de atención están estrechamente relacionados con los patrones de movimiento ocular, este proyecto propone el uso de sensores de seguimiento ocular (ET) para capturar información sobre dichos sesgos atencionales.

El análisis de seguimiento ocular permite medir variables como:

- Fijaciones en un área (mediante mapas de calor)
- Áreas de interés y secuencias de fijaciones
- Tiempo hasta la primera fijación
- Duración de la fijación
- Número de respuestas oculares
- Tamaño de la pupila y frecuencia de parpadeo.

La tecnología de captura de movimientos oculares ofrece un método no invasivo y accesible para registrar el comportamiento visual, lo que permite estudiar patrones de visión en diversas tareas e interacciones con el entorno.

Una vez capturados los datos del comportamiento ocular, pueden utilizarse para entrenar algoritmos de ML, con el objetivo de desarrollar una herramienta computacional capaz de detectar indicios de comportamiento depresivo, especialmente en jóvenes, quienes representan un grupo altamente vulnerable a los trastornos mentales.

1.4.1 Aplicaciones prácticas de la herramienta a desarrollar

En México, la depresión ha ido en aumento desde el inicio de la pandemia por Covid-19. Sin embargo, muchas personas que la padecen, independientemente de la causa, no se consideran enfermas y suelen ocultar su malestar debido al estigma que aún rodea la salud mental en muchas partes del país. Existe la creencia generalizada de que los servicios de salud mental están destinados únicamente a personas con trastornos severos que afectan notablemente su comportamiento, como la esquizofrenia. No obstante, incluso la depresión en niveles leves requiere atención, ya que puede volverse crónica y agravarse con el tiempo, esto afecta el rendimiento laboral, la integración social, la salud física e incluso aumenta el riesgo de suicidio.

Cuando las personas buscan ayuda, ya sea por iniciativa propia o a sugerencia de su entorno, rara vez acuden directamente a especialistas en salud mental. En su lugar, suelen recibir diagnósticos subjetivos por parte de médicos generales, lo que representa un problema, ya que los síntomas de la depresión pueden confundirse con otros trastornos o no ser tomados con la debida seriedad. Como consecuencia, muchos pacientes solo acceden a atención especializada cuando la depresión ha avanzado significativamente y afecta su vida diaria. En los centros de salud mental, los pacientes son evaluados mediante diversas pruebas para determinar la causa de su depresión y definir un tratamiento adecuado, que puede incluir terapia o el uso de antidepresivos. Es fundamental realizar un diagnóstico preciso, ya que los distintos tipos de antidepresivos tienen efectos variables en cada paciente.

En este contexto, se han identificado tres aplicaciones clave para la herramienta propuesta:

1. **Apoyo a médicos generales:** Mejorar la precisión y objetividad en la identificación de posibles casos de depresión.
2. **Monitoreo en entornos escolares y laborales:** Evaluar la salud mental de estudiantes y empleados, permitiendo tomar medidas preventivas que favorezcan el rendimiento y el bienestar emocional. La detección temprana es crucial, especialmente en jóvenes, para reducir el riesgo de suicidio.
3. **Uso en centros de salud mental:** Determinar el nivel de depresión en nuevos pacientes y dar seguimiento a su evolución a lo largo del tratamiento.

El principal valor de esta herramienta radica en su capacidad para aumentar la objetividad y resaltar la importancia de atender la sintomatología depresiva en jóvenes antes de que derive en depresión mayor. En comparación con métodos como la evaluación mediante electroencefalografía (EEG), el uso de seguimiento ocular (SO) es una alternativa menos invasiva, más accesible y fácil de interpretar.

Desde una perspectiva computacional, la propuesta incluye el desarrollo de un algoritmo de clasificación y la experimentación con técnicas de entrenamiento basadas en datos de seguimiento ocular, representados en forma de espectrogramas y mapas de calor. Estos datos

permitirán la creación de un repositorio novedoso de patrones visuales asociados a la depresión, lo que contribuirá al avance en la detección temprana de este trastorno.

1.4.2 Beneficios

El desarrollo de este modelo computacional para analizar el movimiento ocular en personas afectadas por depresión permitirá su detección, evaluación, seguimiento y apoyo en terapias. Su principal beneficio radica en agregar objetividad a los diagnósticos de los especialistas, quienes actualmente se basan en auto informes y técnicas subjetivas, como entrevistas, para diagnosticar a los pacientes. Esto no solo mejorará la precisión en la identificación de la depresión, sino que también beneficiará tanto a médicos como a pacientes al ofrecer una herramienta complementaria para la toma de decisiones clínicas.

Además, la investigación contribuirá al conocimiento en diversas áreas multidisciplinarias, incluyendo psicología, comportamiento humano e interacción humano-computadora (IHC), esto abre nuevas líneas de estudio y aplicaciones en el campo de la salud mental.

1.4.3 Vinculación con el Sector Productivo

Para el desarrollo de este proyecto, se cuenta con la colaboración de la Dra. Leonor Rivera Rivera, investigadora SNI nivel II adscrita al Instituto Nacional de Salud Pública (INSP) ubicada en Cuernavaca, Morelos. La Dra. Rivera es experta en el área de salud mental y depresión. La colaboración con el INSP se formalizó mediante un convenio de colaboración con el TecNM/CENIDET.

Adicionalmente, el Dr. Gabriel González Serna, responsable técnico del proyecto, participa con el grupo de Salud Mental y Adicciones, en el que se encuentran expertos en salud mental del Instituto de Psiquiatría de la CDMX y la Universidad Autónoma del Estado de Morelos (UAEM). Esta vinculación permitirá el acceso a sujetos humanos diagnosticados con depresión clínica, lo que fortalece la validez del estudio.

El Comité de Ética en Investigación (CEI) del INSP certifica los protocolos de intervención y recolección de datos de comportamiento, lo cual garantiza el bienestar y los derechos de

los participantes. Para más información sobre el CEI, se puede consultar el siguiente enlace: <https://www.insp.mx/insp-cei.html>.

El producto de esta investigación tiene aplicaciones tanto en el sector privado como educativo, ya que, al implementarse en una plataforma de software, proporcionará un importante aporte a los expertos en salud mental quienes gracias a la tecnología podría atender a más jóvenes de manera más fácil y rápida y observar características depresivas antes de que se vuelva un problema crónico. Además, aunque el objetivo principal del proyecto es la detección y seguimiento de la depresión, la tecnología desarrollada podría también utilizarse para identificar emociones y estados cognitivos en pacientes diagnosticados, lo cual abre nuevas oportunidades de aplicación en otros sectores productivos y de investigación.

1.5 Alcances

- Obtención de datos a través de la API del sensor de seguimiento ocular “GazePoint GP3 HD Eye Tracker” para obtener datos.
- Desarrollo de un modelo computacional para la detección de depresión clínica basado en patrones de comportamiento ocular.
- Clasificación de los participantes de pruebas por medio de instrumentos de autoinforme validados por el Instituto Nacional de Salud Pública (INSP)
- Generación de un conjunto de datos de seguimiento ocular con participantes catalogados con depresión y un grupo de control, con imágenes emocionales validadas como IAPS.
- Caracterización de patrones de comportamiento ocular asociados a la depresión mediante métricas extraídas del seguimiento ocular.
- Evaluación y selección de algoritmos de ML para la clasificación de depresión en función de los datos recolectados.
- Implementación de un sistema computacional que integre el modelo de detección y pueda ser utilizado en entornos clínicos para evaluación y monitoreo de pacientes.
- Validación experimental del modelo con datos reales, solo considerar métricas de precisión, sensibilidad y especificidad.

1.5.2 Limitaciones

- Los participantes y sus tutores tienen el derecho de retirarse del proceso de recolección de datos en cualquier momento, lo que podría afectar la cantidad de datos disponibles para el análisis.
- Toda la información recolectada es completamente anónima y no permite la identificación de los participantes, lo que garantiza la confidencialidad, pero limita la posibilidad de realizar seguimientos individuales a largo plazo.
- La cantidad de participantes disponibles para el estudio puede limitar la generalización del modelo a poblaciones más amplias o de otro grupo de edad.
- La validación del modelo se basa en instrumentos tradicionales como las escalas de Hamilton y Beck, que dependen de la subjetividad del paciente y del especialista.
- Factores como fatiga, estado emocional momentáneo, consumo de sustancias o condiciones externas pueden influir en los patrones de seguimiento ocular y afectar la consistencia de los resultados.
- La precisión del modelo está condicionada por la calidad del hardware y ambiente controlado utilizado para el seguimiento ocular y el procesamiento de señales.
- Aunque el modelo será diseñado para ser integrado en sistemas de salud, su adopción dependerá de la aceptación por parte de profesionales de la salud y de restricciones regulatorias.
- El sistema no sustituye la evaluación médica, sino que se plantea como una herramienta complementaria para apoyar el diagnóstico y seguimiento de la depresión.

1.6 Estructura del documento

Este documento se organiza en varios capítulos para guiar al lector a través del desarrollo de la investigación. El Capítulo 1 introduce el contexto y la problemática del estudio. En el Capítulo 2, se presenta el marco teórico, que proporciona los fundamentos conceptuales y antecedentes relevantes. El Capítulo 3 recopila el estado del arte, se analizan investigaciones previas y enfoques relacionados con el tema.

El Capítulo 4 describe la metodología propuesta para abordar el problema, mientras que el Capítulo 5 detalla el proceso de recopilación, limpieza y procesamiento de datos, así como el entrenamiento de algoritmos de Machine Learning. En el Capítulo 6, se exponen los resultados obtenidos junto con un análisis detallado de los mismos.

Finalmente, el Capítulo 7 presenta las conclusiones de la investigación, y el Capítulo 8 incluye las referencias bibliográficas utilizadas a lo largo del estudio.

Capítulo 2. Marco teórico

2.1 Salud Mental y Depresión

Según la OMS (2025), la salud mental es un estado de bienestar emocional, psicológico y social en el que una persona puede enfrentar los retos normales de la vida, trabajar de manera productiva y fructífera, y contribuir a su comunidad. Incluye la capacidad de manejar las emociones, relaciones interpersonales y las demandas cotidianas, lo cual mantiene un equilibrio que permita un funcionamiento óptimo en diversas áreas de la vida.

La salud mental no solo se refiere a la ausencia de trastornos mentales, sino también a la presencia de factores protectores como el manejo adecuado del estrés, la resiliencia frente a adversidades y el sentido de propósito y satisfacción en la vida. Cuando la salud mental se ve afectada, puede manifestarse a través de trastornos como la depresión, ansiedad, trastornos del comportamiento, entre otros.

Por otro lado, la depresión es un trastorno mental común que afecta a más de 264 millones de personas en todo el mundo. Se caracteriza por una tristeza persistente y una falta de interés o placer en actividades que antes eran gratificantes o agradables. Afecta todos los aspectos de la vida: las actividades diarias como la escuela, el trabajo, las relaciones con la familia, los amigos y la capacidad para participar en sociedad. Los efectos de la depresión pueden ser duraderos o recurrentes y pueden afectar drásticamente la capacidad de una persona para funcionar y vivir una vida gratificante (National Institute of Mental Health (NIMH) 2021).

2.1.1 Tipos de depresión

La depresión es un trastorno heterogéneo con múltiples manifestaciones clínicas. En cualquier tipo de depresión, mientras esta haya sido diagnosticada por un profesional en la salud, se le llama Depresión Clínica. A continuación, se presentan algunos de los tipos de depresión más comúnmente reconocidos, de acuerdo con el DSM-5 (APA 2013) y la CIE-11 (OMS 2022):

1. **Trastorno Depresivo Mayor (TDM):** Caracterizado por la presencia de uno o más episodios depresivos mayores, definidos por al menos cinco síntomas durante un período mínimo de dos semanas. Puede incluir síntomas como tristeza

persistente, fatiga, alteraciones del sueño, pérdida de interés y pensamientos suicidas (APA 2013).

2. **Trastorno Depresivo Persistente (Distimia):** Es una forma crónica de depresión en la que los síntomas duran al menos dos años en adultos (uno en niños y adolescentes). Aunque los síntomas pueden ser menos intensos que en el TDM, su persistencia puede afectar significativamente la vida diaria (Tolentino y Schmidt 2018).
3. **Depresión con Características Psicóticas:** En algunos casos, la depresión puede ir acompañada de síntomas psicóticos, como delirios o alucinaciones. Estos pueden ser congruentes o incongruentes con el estado de ánimo, lo que influye en el pronóstico y tratamiento (Otte et al., 2016).
4. **Depresión con Características Atípicas:** Este subtipo se caracteriza por reactividad del estado de ánimo (mejora temporal ante eventos positivos), aumento del sueño y apetito, sensación de pesadez en las extremidades y alta sensibilidad al rechazo interpersonal (Singh y Gotlib 2014).
5. **Trastorno Afectivo Estacional (TAE):** Se manifiesta principalmente en los meses de otoño e invierno y está asociado con la reducción de la exposición a la luz solar. Se cree que la disrupción de los ritmos circadianos y la melatonina juegan un papel importante en su etiología (Melrose 2015).
6. **Depresión Postparto:** Aparece en mujeres después del parto y se diferencia del "baby blues" por su gravedad y duración. Se asocia con cambios hormonales, estrés y antecedentes de trastornos del estado de ánimo en la familia (Sloman et al., 2019).
7. **Trastorno Disfórico Premenstrual (TDPM):** Afecta a mujeres en la fase lútea del ciclo menstrual y se caracteriza por síntomas emocionales severos, como irritabilidad, tristeza y ansiedad, además de síntomas físicos. Se considera una forma grave del síndrome premenstrual (Eisenlohr-Moul et al., 2017).
8. **Depresión Secundaria a Enfermedades Médicas o Sustancias:** Algunas condiciones médicas, como hipotiroidismo, enfermedades neurológicas o el uso de ciertas sustancias (alcohol, drogas o medicamentos), pueden inducir síntomas depresivos (Fava y Kendler 2000).

2.1.2 Síntomas y criterios de diagnóstico

Para el diagnóstico del trastorno depresivo mayor, además de las herramientas de autoinforme y entrevistas, los profesionales de la salud mental utilizan principalmente dos sistemas de clasificación: el Manual Diagnóstico y Estadístico de los Trastornos Mentales en su quinta edición (DSM-5) y la Clasificación Internacional de Enfermedades en su undécima edición (CIE-11). Ambos proporcionan criterios clínicos estandarizados para la identificación de los episodios depresivos y su diferenciación de otros trastornos del estado de ánimo (APA 2013; OMS 2022).

Según el DSM-5, un episodio depresivo mayor se caracteriza por la presencia de al menos cinco de los siguientes síntomas durante un periodo mínimo de dos semanas, donde al menos uno de ellos debe ser estado de ánimo deprimido o pérdida de interés o placer en actividades:

- Estado de ánimo deprimido la mayor parte del día, casi todos los días.
- Pérdida de interés o placer en casi todas las actividades.
- Cambios significativos en el peso o apetito.
- Insomnio o hipersomnia.
- Agitación o enlentecimiento psicomotor.
- Fatiga o pérdida de energía.
- Sentimientos de inutilidad o culpa excesiva.
- Dificultades para concentrarse o tomar decisiones.
- Pensamientos recurrentes de muerte o ideación suicida.

Estos síntomas deben causar un deterioro significativo en la vida del individuo y no ser atribuibles a efectos de sustancias o condiciones médicas subyacentes. Además, el DSM-5 diferencia entre distintos subtipos de depresión, como la depresiva persistente o la depresiva con características psicóticas (APA 2013). La CIE-11, desarrollada por la OMS, también proporciona criterios diagnósticos para el trastorno depresivo, diferenciándolo en función de su gravedad (leve, moderada o grave). Según este sistema, el diagnóstico de depresión requiere la presencia de al menos dos de los siguientes tres síntomas principales durante un período de al menos dos semanas:

- Estado de ánimo persistentemente deprimido.
- Pérdida de placer o interés en actividades usuales.
- Reducción de energía o fatiga.
- Además, pueden presentarse otros síntomas adicionales, tales como:
- Dificultades para concentrarse.
- Sentimientos de culpa o inutilidad.
- Pensamientos suicidas.
- Alteraciones del sueño y del apetito.

A diferencia del DSM-5, la CIE-11 enfatiza la clasificación de la depresión según su severidad, lo que facilita la toma de decisiones clínicas en cuanto a tratamiento.

Ambos sistemas presentan similitudes y diferencias clave en la conceptualización del trastorno depresivo mayor. El DSM-5 establece un umbral específico de cinco síntomas para el diagnóstico, mientras que la CIE-11 se centra en tres síntomas principales y permite una clasificación más flexible de la gravedad del trastorno. Además, el DSM-5 es más utilizado en Norteamérica, mientras que la CIE-11 es el estándar de referencia de la OMS a nivel global (Kendler 2016; OMS 2022).

El conocimiento de los criterios diagnósticos de la depresión es fundamental para el desarrollo de herramientas tecnológicas que contribuyan a su detección temprana ya que estudios recientes han demostrado que los individuos con depresión presentan patrones de fijación ocular y tiempos de respuesta alterados ante estímulos emocionales, lo que podría servir como biomarcador objetivo para el diagnóstico del trastorno (Holzman y Mehrotra 2019; Isaac, Buchanan, y Gollan 2020).

2.1.3 Causas de la depresión y Factores de riesgo

Los orígenes de la depresión incluyen interacciones complejas entre factores sociales, psicológicos y biológicos. Los acontecimientos de la vida como la adversidad, la pérdida y traumas de la niñez contribuyen y pueden catalizar el desarrollo de la depresión. Las investigaciones actuales también muestran fuertes relaciones entre la depresión y la salud física.

A continuación, se listan algunos de los factores relacionados con la aparición y mantenimiento del trastorno:

- **Factores hormonales:** Los niveles anormales de cortisol, conocido como la "hormona del estrés", juegan un papel clave en la fisiopatología de la depresión. Se ha observado que pacientes con depresión mayor presentan una hiperactividad del eje hipotalámico-hipofisario-adrenal (HHA), lo que conduce a una secreción excesiva de cortisol y, en consecuencia, a efectos negativos sobre la neuroplasticidad y el funcionamiento cerebral (Pariente y Lightman 2008).
- **Alteraciones cerebrales :** Estudios de neuroimagen han identificado disfunciones en regiones como la corteza prefrontal, la amígdala y el hipocampo en personas con depresión. La reducción del volumen hipocampal se ha asociado con un procesamiento emocional alterado y dificultades en la regulación del estrés (Sheline, Gado, y Kraemer 2003). Además, hay evidencia de deficiencias en neurotransmisores como la serotonina, la dopamina y la noradrenalina, lo que impacta el estado de ánimo y la motivación (Nestler, Barrot, y DiLeone 2002).
- **Alteraciones del sueño:** Los trastornos del sueño son característicos en la depresión y pueden incluir insomnio o hipersomnia. Se ha documentado una reducción en la latencia del sueño REM y un incremento en su densidad, lo que se relaciona con una regulación emocional deficiente (Armitage 2007). Además, los ritmos circadianos pueden verse alterados, contribuyendo a la sintomatología depresiva.

Relación del estado cognitivo con la regulación de emociones

Los efectos de la depresión pueden afectar a todo tipo de personas (National Institute of Mental Health (NIMH) 2021). La Figura 2.1 muestra una propuesta de un modelo de interacción entre la regulación de las emociones y estados mentales cognitivos adaptado del trabajo de (Villalobos, Pacios, and Vázquez 2021).




Figura 2.1: Modelo de interacción integrador entre el control cognitivo, los sesgos cognitivos y la regulación emocional en la depresión. Adaptado de (Villalobos et al., 2021)

En el modelo se observa que una alteración en los procesos cognitivos, ya sea causada por factores físicos (anormalidades hormonales o de la estructura cerebral) o mentales (traumas), afecta directamente el estado emocional de una persona.

En el peor de los casos, la depresión puede llevar al suicidio. Cerca de 800,000 personas mueren por suicidio cada año; esto se traduce a una persona cada 40 segundos. Es la segunda causa principal de muerte entre los jóvenes de 15 a 29 años en todo el mundo (OMS and Motturi 2021).

Si bien existe el vínculo entre el suicidio y los trastornos mentales (en particular, la depresión), muchos suicidios ocurren impulsivamente en momentos de crisis con un colapso en la capacidad para lidiar con las tensiones de la vida. Además, experimentar conflictos, desastres, violencia, abuso o pérdida y una sensación de aislamiento están fuertemente asociados con el comportamiento suicida. Las tasas de suicidio también son altas entre los grupos vulnerables que sufren discriminación (OMS 2019).

2.1.4 Métodos de diagnóstico convencionales

La evaluación de la depresión depende en primera instancia de la disposición del paciente para aceptar que tiene un problema y acercarse a un médico o psiquiatra. Usualmente se

utilizarán distintos métodos para obtener información del paciente que incluyen entrevistas, instrumentos de autoinforme y análisis clínicos para, de manera subjetiva, obtener un diagnóstico sobre la salud mental del paciente. A continuación, se presentan algunos métodos usuales para la evaluación de la depresión.

Inventario de depresión de Beck

El Inventario de Depresión de Beck (BDI) es uno de los instrumentos más utilizados para la evaluación de la sintomatología depresiva tanto en contextos clínicos como de investigación. Su diseño se basa en criterios cognitivos, afectivos y somáticos de la depresión. Ha demostrado una alta confiabilidad y validez, con coeficientes de consistencia interna superiores a 0.85 en diversas poblaciones.

Este cuestionario ha sido ampliamente validado en diferentes grupos poblacionales y ha sido traducido a múltiples idiomas, lo que permite su aplicación en diversos contextos culturales, por ejemplo en el trabajo de González, Reséndiz, y Reyes (2015) que se adaptó en el contexto Mexicano. Sin embargo, una de sus limitaciones es que se basa en la autopercepción del individuo, lo que puede llevar a sesgos en la respuesta debido a factores como deseabilidad social o dificultades para reconocer síntomas depresivos.

Además del BDI en su versión original, existen adaptaciones más recientes como el BDI-II, que incorpora criterios diagnósticos actualizados según el DSM-IV y se considera una versión más precisa para evaluar la depresión en la actualidad. Este instrumento mide la depresión con 21 preguntas (Ver **Anexo 1**). Los individuos pueden clasificar su nivel de depresión según las puntuaciones totales que pueden oscilar entre: 0-13, mínimamente deprimido; 14-19, levemente deprimido; 20-28, moderadamente deprimido; y 29-63, severamente deprimido (Beck et al., 1996).

Escala de valoración de Hamilton para la evaluación de la depresión

El Hamilton Depression Rating Scale (HDRS) es un instrumento tipo entrevista que maneja una escala, diseñada para ser utilizada en pacientes diagnosticados previamente de depresión,

con el objetivo de evaluar cuantitativamente la gravedad de los síntomas y valorar los cambios del paciente. Su versión original consta de 21 preguntas (Ver

Anexo 2) pero existe una versión reducida de 17 reactivos. Esta escala puede ir de 0 a 54 puntos los cuales indican los siguientes niveles de depresión: 0-6, no hay depresión; 7-17, depresión ligera; 18-24 depresión moderada; 25-52 depresión grave (Hamilton 1960).

Depression, Anxiety, Stress Scale (DASS-21)

El DASS-21 (ver

Anexo 3) es un instrumento de autoinforme diseñado para evaluar los niveles de depresión, ansiedad y estrés en individuos a través de 21 ítems, distribuidos en tres subescalas de siete ítems cada una (Lovibond y Lovibond 1995). Este cuestionario es una versión abreviada del DASS-42 y ha demostrado ser una herramienta psicométricamente válida y confiable en diversas poblaciones y contextos clínicos (Henry y Crawford 2005). Su estructura factorial ha sido confirmada en estudios transculturales, lo que sugiere su aplicabilidad en diferentes entornos lingüísticos y culturales (Oei et al., 2013). El DASS-21 permite obtener medidas diferenciadas de los tres estados emocionales, lo que facilita la identificación de patrones específicos de malestar psicológico y proporciona una base para intervenciones dirigidas a mejorar la salud mental.

La Tabla 2.1, muestra una comparativa entre los tres instrumentos, cabe destacar que el instrumento HDRS es una entrevista mientras que el BDI-II y DASS-21 son de autoinforme.

Tabla 2.1: Clasificación de puntaje de instrumentos BDI-II, HDRS y DASS

Beck		Hamilton		DASS	
Puntaje	Resultado	Puntaje	Resultado	Puntaje	Resultado
0-13	Mínimamente deprimido	0-6	No hay depresión	5-6	Depresión leve
14-19	Levemente deprimido	9-17	Depresión ligera	7-10	Depresión moderada
20-28	Moderadamente deprimido	18-24	Depresión moderada	11-13	Depresión severa
29-63	Severamente deprimido	25-52	Depresión grave	14+	Extremadamente severa

Electroencefalograma

Otra de las formas para determinar la presencia de depresión en un paciente es al analizar su actividad eléctrica en el cerebro con ayuda del electroencefalograma (EEG), esto es una exploración neurofisiológica que se basa en el registro de la actividad bioeléctrica cerebral en condiciones de reposo, en vigilia o sueño. Los patrones anormales en el cerebro son indicadores de trastornos como la depresión.

En un estudio de (Begić et al., 2011) se reporta que los pacientes deprimidos presentan una disminución de la concordancia prefrontal y existe una combinación de asimetría izquierda-derecha de theta-alfa. También se han reportan valores altos de poder absoluto en las frecuencias alfa y theta de pacientes con depresión en comparación con pacientes sanos y un aumento de la actividad alfa en reposo, localizada en las regiones parietal y frontal predominantemente izquierdas en (Olbrich and Arns 2013).

2.2 Estado mental, cognitivo y afectivo

Es importante definir que es un estado mental en general y a partir de ese concepto definir el estado mental cognitivo, emocional y afectivo de un ser humano.

2.2.1 Estado mental

Estado o proceso que corresponde con el pensar y sentir de un sujeto, y que además posee propiedades espaciotemporales, causas y efectos distinguibles (Goldstein, 2000). Los estados mentales se clasifican en dos tipos: estados cognitivos y estados afectivos.

2.2.2 Estado cognitivo

Un estado cognitivo es una condición neuropsicológica que presenta un sujeto durante la realización de una o más tareas cognitivas, las cuales contemplan los procesos necesarios para el cálculo, la concentración y la memoria, además de las funciones ejecutivas, de las cuales se consideran las siguientes:

- Concentración.

- Planificación de tareas.
- Resolución de problemas.
- Formular conceptos abstractos.
- Autoconciencia.

2.2.3 Estado afectivo

Se entiende por estados afectivos a la condición neuropsicológica que presenta un sujeto. Los estados afectivos se clasifican en emociones y sentimientos. Los estados afectivos se diferencian principalmente por el tiempo de duración, los sentimientos tienen una duración mayor que las emociones. En la Tabla 2.2 se presenta la clasificación de los estados afectivos y algunos ejemplos que permiten diferenciarlos.

Tabla 2.2: Clasificación de los estados afectivos, de (Soriano, 2018), Todos los derechos reservados 2018.
Tomado con permiso del autor

Clasificación de los estados afectivos			
Emociones		Sentimientos	
Miedo	Alegría	Vergüenza	Simpatía
Ira	Sorpresa	Resentimiento	Orgullo
Tristeza	Asco	Amor	Celos

Los estados emocionales se clasifican en dos tipologías: estados emocionales positivos y estados emocionales negativos. En la Figura 2.2 se muestra una categorización de estados mentales que según la neurociencia.




Figura 2.2: Clasificación de estados mentales, de (Soriano, 2018), Todos los derechos reservados 2018.
Tomado con permiso del autor.

2.2.4 Estado cognitivo y su relación con la depresión

El estado cognitivo de un individuo puede verse afectado significativamente por la depresión, una condición que impacta las funciones ejecutivas y la capacidad de procesamiento de información. La depresión mayor se asocia con déficits en atención, memoria de trabajo, toma de decisiones y velocidad de procesamiento cognitivo (Gotlib y Joormann 2010). Estos déficits pueden influir en la calidad de vida del individuo y dificultar la realización de actividades diarias, lo que a su vez refuerza los síntomas depresivos en un ciclo negativo.

Estudios neurocientíficos han demostrado que la disfunción en la corteza prefrontal dorsolateral y el hipocampo está correlacionada con la disminución de la memoria de trabajo y la planificación de tareas en individuos con depresión (Disner et al., 2011). Además, la hiperactividad en la amígdala y la reducción en la conectividad funcional con la corteza prefrontal pueden contribuir a una mayor dificultad en la regulación emocional y en el control cognitivo sobre pensamientos negativos recurrentes (Hamilton et al., 2012).

2.2.5 Estado afectivo y su impacto en la salud mental

El estado afectivo de un individuo tiene una influencia directa sobre su salud mental, ya que las emociones y sentimientos regulan la respuesta psicológica ante los estímulos del entorno. Los estados afectivos negativos, como la tristeza prolongada, el miedo o la ira, pueden incrementar el riesgo de desarrollar trastornos psicológicos, como la ansiedad y la depresión (Watson y Clark 1984). Por el contrario, los estados afectivos positivos, como la alegría y la simpatía, están asociados con una mayor resiliencia psicológica y bienestar subjetivo (Fredrickson 2001).

La regulación emocional es un proceso clave en la modulación de los estados afectivos y en la prevención de trastornos mentales. Modelos como la Teoría Ampliada y Construida de las Emociones Positivas sugieren que experimentar emociones positivas no solo mejora el bienestar inmediato, sino que también contribuye al desarrollo de recursos psicológicos y sociales que protegen contra el estrés y las enfermedades mentales (Fredrickson and Joiner 2002).

Los estudios en neurociencia han evidenciado que la actividad en la amígdala y en la corteza prefrontal ventromedial está relacionada con la respuesta emocional y la regulación afectiva (Ochsner y Gross 2005). La disfunción en estas regiones ha sido vinculada con alteraciones en la percepción de recompensas y la regulación de emociones negativas en personas con trastornos afectivos (Davidson 2004).

2.3 Seguimiento Ocular y su Aplicación en la Evaluación de la Depresión

El seguimiento ocular (ET) es una técnica que permite registrar y analizar los movimientos de los ojos para comprender cómo las personas procesan la información visual. A través del uso de dispositivos especializados, conocidos como eye trackers (sensores de seguimiento ocular), se pueden obtener datos sobre la dirección y duración de la mirada, los puntos de fijación y los movimientos sacádicos, entre otros parámetros. Esta tecnología ha sido ampliamente utilizada en diversas áreas como la neurociencia, la psicología cognitiva, el marketing y la interacción humano-computadora (IHC).

2.3.1 Principios del seguimiento ocular

El ET es una tecnología que ayuda a entender la atención visual. Existen dos tipos de sensores que pueden extraer la información del movimiento ocular de un usuario, el primero utiliza cámaras de video en conjunto con visión por computadora para analizar y registrar el movimiento de los ojos. El segundo utiliza tecnología infrarroja de emisión y recepción para procesar la reflexión de la luz en la pupila del usuario (ver Figura 2.3).




Figura 2.3: Esquema del funcionamiento del seguimiento ocular con un sensor infrarrojo (D. Fouilloux, 2018). Tomado con permiso del autor

La reflexión de la luz sobre la pupila es registrada por un sensor que calcula la posición en coordenadas (x, y) del punto que representan la mirada del usuario en el plano espacial de la pantalla.

El seguimiento ocular detecta en dónde está la posición de la mirada el usuario en un punto del tiempo, cuánto tiempo mira algo y la ruta que sus ojos siguen. Por ejemplo, en el campo de la experiencia de usuario, el seguimiento ocular ayuda a entender de manera más completa la percepción del usuario (Bergstrom and Schall 2014).

2.3.2 Relación entre seguimiento ocular y procesos cognitivos/emocionales

El seguimiento ocular es una técnica ampliamente utilizada para evaluar los procesos cognitivos y emocionales en distintos contextos clínicos y experimentales. Diversos estudios han demostrado que las personas con depresión presentan sesgos atencionales caracterizados por una mayor fijación en estímulos negativos y una menor atención a estímulos positivos en comparación con individuos sanos (Armstrong y Olatunji 2012). Estos patrones de fijación pueden ser detectados mediante el análisis de movimientos oculares, lo que permite inferir estados cognitivos y emocionales subyacentes.

Además, investigaciones en neurociencia han evidenciado que la actividad ocular está estrechamente relacionada con el procesamiento emocional y la regulación atencional. Por ejemplo, los movimientos sacádicos y la duración de las fijaciones están modulados por la carga cognitiva y la valencia emocional del estímulo visual (Isaacowitz et al., 2006). También existen estudios que utilizan características oculares para evaluar la función ejecutiva (procesamiento cognitivo) en pacientes con enfermedades mentales (Kim et al., 2024).

En este sentido, el uso de inteligencia artificial para analizar estos patrones ha permitido mejorar la identificación de condiciones afectivas y ha facilitado el desarrollo de herramientas para la evaluación de la salud mental.

2.4 Métricas y Análisis de Seguimiento Ocular

El seguimiento ocular es una herramienta precisa y no invasiva para registrar el comportamiento visual de un individuo, lo que permite analizar la relación entre la atención visual y los procesos cognitivos y emocionales. Por lo cual, las métricas de ET sirven como

indicadores clave del patrón de movimiento ocular ante estímulos visuales, lo cual proporciona información detallada sobre la forma en que el cerebro procesa la información.

Estas métricas incluyen variables como los puntos de fijación, las trayectorias de la mirada, la duración de las fijaciones y la frecuencia de parpadeo, entre otras. El análisis de estos parámetros ofrece valiosos conocimientos sobre la distribución de la atención, la carga cognitiva y las respuestas emocionales de los individuos, lo que resulta fundamental para comprender su estado mental y cognitivo.

2.4.1 Puntos de fijación y visión

Los puntos de visión son la unidad básica de medición del seguimiento ocular, se obtienen directamente de los sensores de seguimiento ocular y representan puntos, en forma de coordenadas (x, y). Como se representa en la Figura 2.4, las coordenadas del punto de visión representan un punto en el plano de visión del usuario, comúnmente este plano es la pantalla o monitor donde está colocado un sensor de seguimiento ocular, pero también puede representar el plano de visión en lentes con tecnología de seguimiento ocular.



Figura 2.4: Esquema de coordenadas de visión en una pantalla

Un punto de visión (1) es un conjunto que contiene tres elementos: un par de coordenadas (x, y) y una estampa de tiempo t.

$$puntodevisión = \{x, y, t\} \quad (1)$$

Donde:

- x es un punto en el eje x del plano espacial de la pantalla.
- y es un punto en el eje y del plano espacial de la pantalla.

- t es la estampa de tiempo que define el momento en que ocurrió el punto de visión.

Al utilizar los puntos de visión del usuario se obtienen las coordenadas de fijación visual, las fijaciones se representan como muestras discretas de puntos estables donde mira el ojo (Borys y Małgorzata 2017). Los puntos de observación se agregan según un área y un intervalo de tiempo específicos. El área de agregación suele ser de unos 20 a 50 píxeles, en un intervalo de tiempo entre 200 y 300 ms (Holmqvist et al., 2011).

Un punto de fijación se obtiene al calcular la diferencia entre la velocidad de un primer punto de visión al siguiente o como grupos de puntos consecutivos dentro de una dispersión específica, o separación máxima (Salvucci y Goldberg 2000). Y se representan como un conjunto de cinco elementos (2): coordenada x , coordenada y , tiempo de inicio t_i , tiempo de fin t_f y duración de la fijación d .

$$punto de fijación = \{x, y, t_i, t_f, d\} \quad (2)$$

Donde:

- x es un punto en el eje x del plano espacial de la pantalla.
- y es un punto en el eje y del plano espacial de la pantalla.
- t_i es la estampa de tiempo que define el momento en que ocurrió la fijación.
- t_f es la estampa de tiempo que define el momento en que termino la fijación.
- d es la diferencia de t_i y t_f , representa el tiempo que duro la fijación.

2.4.2 Métricas de fijación y visión

Actualmente la mayoría de los sensores de seguimiento ocular calcula directamente los puntos de fijación y pueden ser distinguidos de puntos de visión simples. Ambos, los puntos de visión y los puntos de fijación son la base para obtener características de observación como los clásicos mapas de atención que son formas de representar la atención visual de un usuario.

Dos de los mapas de atención más utilizados, ya que son fáciles de interpretar, son los mapas de calor y los mapas de rutas sacádicas.

Mapas de calor

Representan las agregaciones de los puntos de fijación y/o de visión de uno o varios usuarios, revelan la distribución de la atención visual al utilizar una serie de colores (azul = frío, verde = tibio y rojo = caliente) para representar temperatura, las temperaturas altas, de color rojo, indican mayor tiempo de atención en el área (ver Figura 2.5).



Figura 2.5: Ejemplo de mapa de calor: Realizado con los datos de ET de una prueba de evaluación UX

Para realizar un mapa de calor se debe tratar cada pixel disponible en la imagen de la captura como un espacio en un arreglo de dos dimensiones, donde en función del conjunto de puntos de fijaciones se aumentará la intensidad de un pixel (i, j) relacionado con la coordenada (x, y) de cada uno de los puntos de fijación (en varias iteraciones) y además, se aumenta el valor de los pixeles alrededor de éste en una menor medida con un vlaor $\propto (3)$, normalmente, utilizando un kernel gaussiano (Duchowski et al., 2012), esto para asignarle un peso de manera más uniforme a los pixeles vecinos. Mientras más alto sea el valor del píxel se le asignará un color más caliente.

$$intensidad\ pixel(i, j) = exp - \frac{(x-i)^2 + (y-j)^2}{2\alpha^2} \quad (3)$$

Donde:

- x es un punto capturado en el eje x del plano espacial de la pantalla.
- y es un punto capturado en el eje y del plano espacial de la pantalla.
- i es un punto de un píxel en el eje x del plano espacial de la pantalla.
- j es un punto de un píxel en el eje y del plano espacial de la pantalla.
- α es la desviación estándar del conjunto de datos capturados, se puede modificar el valor para variar la intensidad.
- La función es iterativa se calcula para cada píxel (i, j) disponible en la pantalla.

Al final se procesa el arreglo como una imagen con los colores de temperatura y se coloca sobre la imagen o video capturado durante la prueba.

Mapas de rutas

Los mapas de rutas (ver Figura 2.6), al igual que los de calor, sirven para representar la atención visual de un usuario o de un conjunto de ellos, se definen como una secuencia de fijaciones alternas y sácadas (Holmqvist et al., 2011). Los elementos visuales de los mapas de rutas son tres: círculos para representar una fijación y el diámetro del círculo que representa la duración de la fijación. Cada círculo está numerado, para representar la secuencia en el que ocurrieron las fijaciones. Finalmente, el último elemento es un conjunto de vectores que unen los círculos, esto representa la ruta que siguieron los ojos para llegar a cada una de las fijaciones.



Figura 2.6: Ejemplo de mapa de rutas: Realizado con los datos de ET de una prueba de evaluación UX

Para generar el mapa de rutas se debe utilizar el conjunto de puntos de fijación para obtener el conjunto de sácadas. Éstas describen un movimiento ocular rápido de una fijación a otra. Suelen durar entre 30 y 80 ms y son el movimiento más rápido que puede realizar el cuerpo humano (Holmqvist et al., 2011). Representan el movimiento de transición entre dos fijaciones y se describen con cinco elementos (4).

$$sacada = \{x_1, y_1, x_2, y_2, d\} \quad (4)$$

Donde:

- x_1 es un punto de la primera fijación en el eje x del plano espacial de la pantalla.
- y_1 es un punto de la primera fijación en el eje y del plano espacial de la pantalla.
- x_2 es un punto de la segunda fijación en el eje x del plano espacial de la pantalla.
- y_2 es un punto de la segunda fijación en el eje y del plano espacial de la pantalla.
- d es la diferencia de t_i de la primera fijación y t_f de la segunda fijación, representa el tiempo que duro la sácada.

Una vez obtenido el conjunto de sácadas se procesa la imagen de la prueba para sobreponer los puntos de fijación en orden con las sácadas que los unen de forma que el par de

coordenadas de la primera fijación forma el origen de la flecha y el par de coordenadas de la segunda fijación forma el final del trazo de la flecha.

Áreas de interés

Otra de las métricas del seguimiento ocular son las áreas de interés también conocidas como AOI's o ROI's (Areas Of Interest, y Regions Of Interest, por sus siglas en inglés). En la práctica se pueden definir manualmente áreas de interés donde los investigadores observan el comportamiento ocular dentro de las zonas establecidas manualmente. También es posible obtener áreas de interés automáticamente mediante algoritmos de agrupamiento, el principio es obtener n número de clústeres de forma automática al utilizar todo el conjunto de puntos de visión que fueron capturados durante una prueba de seguimiento ocular. Al agrupar los puntos se obtiene de forma dinámica un conjunto de clústeres a los cuales pertenecen n puntos de visión, el centro de cada clúster representa también el centro del área de interés mientras que los demás puntos se utilizan para determinar el área que abarca la región de interés (ver Figura 2.7).



Figura 2.7: Ejemplo de áreas de interés: Realizado con los datos de ET de una prueba de evaluación UX

Uno de los algoritmos de agrupamiento que obtiene un número dinámico de clústeres de manera automática y que ha sido utilizado para obtener las áreas de interés con datos de seguimiento ocular es el algoritmo Meanshift (Fuhl et al., 2018; Santella and DeCarlo 2004).

Parpadeos

Los parpadeos (Figura 2.8) son una fuente de información sobre la carga cognitiva, se consideran como el cierre total de los párpados en los dos ojos y duran aproximadamente de 100 a 150 ms bajo condiciones normales (Chen et al., 2011), cualquier tiempo mayor se conoce como un “microsueño”.



Figura 2.8: Representación gráfica de un parpadeo

En varios trabajos encontrados en la literatura, (Chen et al., 2011; Mallick et al., 2016; McIntire et al., 2014; Sakai et al., 2017; Smilek, Carriere, and Cheyne 2010; Zagermann, Pfeil, and Reiterer 2016; Zagermann et al., 2018), el número de parpadeos se correlaciona con la carga cognitiva del usuario que realiza una tarea visual. Esto demuestra que la frecuencia de los parpadeos se puede utilizar para obtener información acerca de la carga cognitiva que le genera un estímulo y para obtener una idea general de su nivel de atención.

Los estudios demuestran que, si la frecuencia de parpadeos es baja, el usuario se enfrenta a una carga cognitiva alta y prestan más atención a las tareas, por ejemplo, al ver una película o jugar un videojuego. Por otro lado, una frecuencia de parpadeo alta denota lo contrario, una carga cognitiva baja y falta de atención o aburrimiento.

Tiempo hacia la primera fijación

Cuando un usuario busca un objeto o área específica en una pantalla, el tiempo transcurrido desde el inicio de la prueba hasta la primera vez que fija su mirada en dicho elemento (ver Figura 2.9), ofrece una medida de su accesibilidad y visibilidad. Esta métrica es especialmente útil para evaluar qué tan llamativo es un segmento de información en una página web, lo que permite identificar los elementos que captan la atención del usuario con mayor rapidez. La métrica mide la diferencia de tiempo entre el inicio de la prueba y el tiempo en el que se registra la primera fijación (Guo et al., 2016).



Figura 2.9: Esquema de tiempo hacia la primera fijación

Recuento de visión

Esta métrica se basa en el conteo de puntos de fijación dentro de un área de interés definida y proporciona información sobre la concentración visual y la cantidad de usuarios que dirigieron su mirada hacia esa región específica (Figura 2.10). Un mayor número de fijaciones en comparación con otras áreas sugiere que ciertos elementos dentro del área de interés captan más la atención de los usuarios. De este modo, es posible identificar las zonas de mayor impacto visual y determinar qué contenidos generan mayor interés (Guo et al., 2016; Shojaeizadeh et al., 2019).



Figura 2.10: Esquema de recuento de visión

Tiempo gastado

El tiempo gastado cuantifica la cantidad de tiempo que los usuarios pasan en un área de interés, se calcula con la sumatoria de la duración de las fijaciones que se encuentren dentro del rango de coordenadas que definen el perímetro del área de interés. Mientras más tiempo se mire un área se puede inferir un mayor nivel de interés, mientras que un menor tiempo puede indicar que otras áreas en la pantalla son más llamativas (Figura 2.11) (Shojaeizadeh et al., 2019).



Figura 2.11: Esquema de tiempo gastado

Distancia a la pantalla

Los sensores de ET permiten medir con precisión la distancia entre el usuario y la pantalla (Figura 2.12), esto proporciona información clave sobre el comportamiento de acercamiento o rechazo ante distintos estímulos visuales (Farnsworth 2016). Esta distancia, expresada en centímetros, se calcula a partir de la detección de la posición de los ojos del usuario en relación con el sensor, lo que facilita el análisis de reacciones cognitivas y emocionales en diversos contextos.




Figura 2.12: Esquema de la distancia entre el usuario y la pantalla

2.4.3 Pupila y pupilometría

La pupila es una estructura del ojo que consiste en un orificio situado en la parte central del iris por el cual penetra la luz al interior del globo ocular y permite realizar el proceso del sentido de la visión en los seres humanos. La pupila es una abertura dilatable y contráctil, aparentemente de color negro, que tiene la función de regular la cantidad de luz que llega a la retina, en la parte posterior del ojo (Derrickson and Tortora 2006).

El tamaño de la pupila responde a factores como la iluminación, heridas, enfermedades, medicamentos, o a estímulos visuales. Si se controlan los factores ambientales externos, el

diámetro de la pupila (ver Figura 2.13) puede otorgar información sobre el estado emocional y cognitivo de la persona.




Figura 2.13: Representación de la medición del tamaño de la pupila, adaptado de (CASIA 2005)

El procesamiento cognitivo de las señales emocionales por lo general provoca un aumento en el tamaño de la pupila, y este efecto se ha atribuido en gran medida a la activación provocada por los estímulos (Oliva and Anikin 2018).

Diversos estudios correlacionan esta característica ocular a cambios en los estados mentales de las personas ya que además de reaccionar a estímulos emocionales, se observan cambios en la pupila durante la toma de decisiones (procesos cognitivos).

Por ejemplo, el trabajo de (Johansson and Balkenius 2018) propone un modelo computacional que utiliza la dilatación de la pupila de los usuarios como un indicador para el esfuerzo cognitivo y la activación emocional. Aunque la correlación de la pupila está presente, trabajos como los de Shafiei et al., (2020) y Zhu, Wang, La, et al., (2019), insisten en considerar la afectación de la pupila por estímulos emocionales externos e internos, cada persona reacciona diferente y la pupila se ve afectada por la luz, la carga mental, entre otros (Li et al., 2020).

2.5 Aprendizaje supervisado

Se tienen dos tipos de aprendizaje supervisado: 1) Clasificación y 2) Regresión. Para esta investigación nos enfocaremos en la clasificación, donde se entrena el algoritmo para etiquetar o clasificar los datos de entrada en variables discretas (variable que no tiene un valor numerable si no que únicamente pertenece a un conjunto específico).

Además de los tipos de aprendizaje antes mencionados, existen dos tipos de clasificación: 1) Binaria y 2) Multiclase. En la primera se busca filtrar en solo dos clases, esto es útil cuando se busca detectar estados binarios de tipo Encendido/Apagado. En la clasificación multiclase se pueden etiquetar los datos en n número de clases como por ejemplo la clasificación de música en distintos géneros musicales.

Para el proceso de clasificación multiclase se infiere una función a partir de datos de entrenamiento etiquetados (variables discretas), estos consisten en un conjunto de ejemplos de entrenamiento (Mohri, Rostamizadeh, y Talwalkar 2012). Cada dato del conjunto de entrenamiento es un par que consta de un objeto de entrada y un valor de salida deseado (clasificación o etiqueta). Es importante que estos pares se encuentren etiquetados correctamente, esto implica realizar un análisis y clasificación de los datos de entrada ya sea de forma manual o mediante otro tipo de algoritmos de clasificación como, por ejemplo, algoritmos de aprendizaje no supervisado.

Finalmente, el aprendizaje supervisado, sea de clasificación binaria o multiclase, resultará en una función que fue inferida durante el proceso de entrenamiento y que puede usarse para mapear nuevos datos de ejemplo.

En un escenario óptimo el entrenamiento adecuado permitirá que el algoritmo determine correctamente las etiquetas de clase para nuevas instancias. Para lograr esto el algoritmo de aprendizaje generaliza la nueva instancia no vista previamente, a alguna clase o etiqueta que ya se conocía previamente. La Figura 2.14 ilustra el proceso del aprendizaje supervisado.




Figura 2.14: Esquema del proceso de aprendizaje supervisado, adaptado de (Nguyen et al., 2017)

Se encuentra disponible una amplia gama de algoritmos de aprendizaje supervisado, cada uno con sus fortalezas y debilidades. No existe un algoritmo de aprendizaje único que funcione mejor en todos los problemas de aprendizaje supervisado.

Los algoritmos de aprendizaje más utilizados, en el contexto de la detección de depresión con datos de seguimiento ocular, son:

- | | |
|--|---|
| <ul style="list-style-type: none"> • Máquinas de Vector-Soporte • Regresión lineal • Regresión logística • Naive Bayes | <ul style="list-style-type: none"> • Árboles de decisión • K-nearest neighbor • Redes neuronales |
|--|---|

Capítulo 3. Metodología

3.1 Enfoque de investigación

A pesar de los prometedores hallazgos en la detección de depresión con seguimiento ocular, existe una brecha notable en la literatura en cuanto a las poblaciones más jóvenes. La mayoría de los estudios se centran en adultos, lo que deja una escasez de investigación sobre cómo se manifiestan estos comportamientos en adolescentes y jóvenes adultos. Para abordar esta brecha, nos centramos exclusivamente en una población joven (de 15 a 21 años) y utilizamos únicamente los datos de los sensores de seguimiento ocular para la extracción de características, a diferencia de los enfoques multimodales que integran datos adicionales como EEG.

Este estudio tiene como objetivo explorar el potencial de los datos de un solo sensor para detectar la depresión en los jóvenes, al proporcionar información sobre si los patrones similares observados en adultos son aplicables también a individuos más jóvenes. Además, se busca aplicar varios algoritmos de ML optimizados a través de la afinación de hiperparámetros, para realizar un análisis comparativo del rendimiento de los algoritmos e identificar las técnicas más efectivas para el conjunto de datos específico. Finalmente se pretende desarrollar una herramienta que utilice los modelos de ML entrenados para apoyar al diagnóstico de la depresión.

3.1.1 Diseño del estudio

En este estudio, se empleó un diseño experimental controlado aleatorizado para garantizar la validez y confiabilidad de los datos obtenidos. Este tipo de enfoque permite recopilar datos de seguimiento ocular de una muestra de estudiantes jóvenes, al asegurar que la asignación de los participantes a las condiciones del experimento se realice de manera equitativa y sin sesgos. A través de este diseño, se logra controlar variables externas que pudieran influir en los resultados, lo cual permite una mejor interpretación de la relación entre los estímulos visuales y las respuestas observadas.

A continuación, se describen en detalle todas las partes que componen la metodología del estudio comenzando por la búsqueda de información en el estado del arte.

3.2 Estado del arte

A continuación, se describe el proceso de selección de fuentes de información en conjunto con su análisis y discusión del panorama del estado del arte al inicio de esta investigación.

3.2.1 Fuentes de información

Esta revisión sigue las recomendaciones del Informe de Declaración de los Elementos Preferidos para Revisiones Sistemáticas y Metaanálisis (PRISMA) (Moher et al., 2009), donde el objeto del estudio se da en la pregunta: ¿Es posible detectar la depresión en jóvenes mexicanos utilizando características del movimiento ocular? Y se definen las siguientes preguntas de investigación: ¿Cuáles son las características del comportamiento ocular de personas jóvenes con depresión? Y ¿Cómo afectan los estímulos visuales con carga emocional a los patrones de movimientos oculares de las personas jóvenes diagnosticadas con depresión en comparación a las personas sin depresión?

El estudio del estado del arte se realizó con los siguientes criterios:

Criterios de inclusión

- Índice JCR
- SCOPUS
- Conocimiento tipo “base” para la investigación

Criterios de exclusión

- Fuentes de información de no más de 5 años de antigüedad (con excepciones)
- Contenido no relevante para la investigación

Palabras clave y cadenas de búsqueda

Se utilizaron las siguientes palabras clave derivadas de las preguntas de investigación para realizar la revisión sistemática de la literatura: 1) Seguimiento ocular, 2) Depresión, Estímulo, 3) Emoción, 4) Detección, 5) Clasificación, 6) Predicción, 7) Modelo, 8) Comportamiento ocular, 9) Jóvenes.

Donde se obtuvieron las siguientes cadenas de búsqueda:

1. (Eye AND (Behavior OR Tracking OR Movement)) AND (Depression) AND (Young OR Youth)
2. (Eye AND (behavior OR tracking OR Movement)) AND (Depression) AND (Detection OR Prediction OR Classification OR Model)

Recopilación de estudios

Luego de utilizar las cadenas de búsqueda con los filtros de inclusión en buscadores académicos, se obtuvieron los siguientes resultados (ver Tabla 3.1).

Tabla 3.1: Resultados obtenidos de buscar las cadenas 1 y 2 en distintos buscadores académicos

Cadena	1	2
Google Scholar	52400	54400
Semantic Scholar	61800	292000
Pubmed	240	361
SpringerLink	5502	8785
MDPI	81	34
EBSCO	29	63
IEEE Xplore	1	15

Selección de los estudios

Los criterios de elegibilidad para la revisión siguieron la estructura PICOS (Methley et al., 2014), donde se definió la Población como "personas con síntomas de depresión"; Intervención/Exposición como "enfrentar estímulos emocionales"; Comparación como "comportamiento ocular entre la inducción de emociones negativas, positivas y neutrales"; Resultado como "patrones depresivos en los movimientos oculares"; Diseño del estudio como "comparación estadística entre dos grupos o detección de la depresión con características del ojo/seguimiento ocular".

Además, como criterios generales de inclusión, establecimos los tipos de fuentes de información como artículos de revistas indexados en JCR o Scopus, esto con el objetivo de obtener estudios de mejor calidad. Se observa un resumen de las fuentes de información en la Tabla 3.2.

Tabla 3.2: Índices de las fuentes de información recopiladas

Índice	Cantidad
Conferencia	8
JCR	60
SCOPUS	10
N/A	1

Luego se seleccionaron estudios relevantes para las palabras clave de búsqueda y con no más de cinco años desde su publicación (de 2016 hasta 2021). Sin embargo, se incluyeron investigaciones de años anteriores si se consideraban relevantes para la investigación. Finalmente, la selección de estudios no estuvo limitada a algún idioma en particular.

Se obtuvo una muestra de los primeros 100 artículos de cada uno de los motores de búsqueda, lo que dio como resultado un total de 1,023 títulos de artículos identificados. La Figura 3.1 presenta el diagrama de flujo PRISMA del proceso de selección.




Figura 3.1: Diagrama de flujo de los Elementos de Información PRISMA ver. 2020

Muchos de los artículos encontrados no tenían relevancia para la investigación y se descartaron porque, aunque los estudios de seguimiento ocular medían el nivel de depresión de los participantes, el objetivo de esas investigaciones no estaba relacionado con la investigación sobre la depresión, sino más bien con otros problemas de seguimiento ocular donde la depresión se examinaba de manera incidental. Finalmente, después de descartar duplicados, se seleccionaron 79 artículos de 46 revistas y 8 conferencias.

Se clasifico los artículos en dos tipos de investigaciones: 1) Correlación de movimientos oculares en pacientes con depresión en comparación con un grupo de control y 2) Detección de la depresión a través de características oculares.

Se analizaron en profundidad un total de 36 estudios de vanguardia para obtener una imagen más amplia del alcance de la tecnología de seguimiento ocular y la depresión.

3.2.1 Análisis del estado del arte

Comportamiento ocular y diferencias por edad

Aunque las cadenas de búsqueda se centraron en estudios con grupos más jóvenes, las fuentes de información recopiladas incluyeron estudios con rangos de edad variados. Sin embargo, al observar y comparar los resultados publicados con población joven (8 trabajos) y población adulta (11 trabajos), observamos que el comportamiento ocular y los síntomas de la depresión comparten características clave en cualquier rango de edad. Por ejemplo, se observó un sesgo de atención negativo y un comportamiento ocular irregular (fijaciones, sacadas, parpadeos y dilatación de la pupila) en comparación con los grupos de control sin depresión. Esto coincide con los hallazgos de Lu et al., (2017), quienes realizaron un estudio controlado de seguimiento ocular para observar el sesgo de atención entre personas jóvenes y de mediana edad con depresión y un grupo de control. Sus resultados mostraron que aquellos con depresión tenían un sesgo de atención positiva significativamente reducido y un sesgo de atención negativa aumentado, independientemente de la edad. Sin embargo, es necesario investigar los cambios en el comportamiento desde la infancia hasta la depresión en adultos, ya que los niños tienden a evitar estímulos negativos como una táctica de protección emocional. Esto se discute más adelante en este estudio.

Estudios de correlación entre el comportamiento ocular y la depresión

La Tabla 3.3 muestra una comparación entre estudios relacionados con la correlación entre el comportamiento ocular y la depresión.

Tabla 3.3: Estudios revisados sobre la correlación de la depresión con los movimientos oculares.

Trabajo	Correlación				Análisis			Paradigma		Muestra		
	Enfoque negativo	Desapego emocional	Dilatación de la pupila	Correlación no significativa	ANOVA	T-test	Otros	Tipo	Estímulo	Tipo	Control	Depresión
(Lu et al., 2017)	✓				✓	✓		Visualización libre	Rostros emocionales	Jóvenes y Adultos	75	90
(Burkhouse et al., 2015)			✓				✓	Visualización libre	Rostros emocionales	Niños	--	43
(Owens et al., 2016)	✓	✓					✓	Visualización pasiva	Rostros emocionales	Niños	81	81
(Gibb et al., 2016)		✓			✓			Spatial cueing task (Posner 1980)	Rostros emocionales	Niños	64	69
(Platt et al., 2022)				✓	✓	✓	✓	DPT, VST & PVT	Rostros emocionales	Niños y Adultos	36	44
(Greimel et al., 2020)	✓					✓		Visualización libre	IAPS	Adolescentes	37	36
(Sanchez, Romero, and De Raedt 2017)	✓						✓	Visualización condicionada	Rostros emocionales	Adultos	25	14
(Garcia et al., 2019)	✓				✓	✓		DPT	Rostros emocionales	Adultos jóvenes	120	31
(Jin, Steding, and Webb 2015)			✓		✓		✓	Visualización libre	Multimedia emocional	Adultos	25	25
(Burkhouse et al., 2017)			✓		✓			Visualización libre	Rostros emocionales	Adolescentes	26	18
(Klawohn et al., 2020)	✓				✓	✓		Visualización libre	Rostros emocionales	Adultos	31	50
(Krejtz et al., 2018)						✓	✓	ABMT	Rostros emocionales	Adultos	27	33
(Bodenschatz et al., 2019)		✓			✓		✓	Visualización libre	Rostros emocionales	Adultos	31	31
(Figueiredo et al., 2019)	✓					✓		Visualización libre	Rostros emocionales	--	44	25
(Tang et al., 2019)	✓				✓		✓	Visualización libre	IAPS	Adultos	43	22
(Yaroslavsky, Allard, and Sanchez-Lopez 2019)	✓						✓	Visualización libre	Rostros emocionales	Adultos jóvenes	23	23
(Bodenschatz et al., 2020)					✓		✓	Visualización condicionada	Rostros emocionales	Adultos	29	29
(Unruh, Bodfish, and Gotham 2020)	✓				✓	✓		Visualización libre	Rostros emocionales	Adultos	24	24
(Godara, Sanchez-Lopez, and De Raedt 2019)	✓			✓	✓			Visualización condicionada	Rostros emocionales	Adultos	24	29

Nota: DPT = Dot-Probe Task (MacLeod, Mathews, and Tata 1986), VST = Visual-Search Task, PVT = Passive-Viewing Task, ABMT = Attentional bias modification training, IAPS = International Affective Picture System. (Lang, Bradley, and Uthbert 2008).

Para cada publicación, se extrajeron las conclusiones e ideas de los autores sobre el comportamiento ocular en la depresión, centrándonos en el tipo de población. Además, se recopilaron los métodos estadísticos de comparación utilizados en los estudios, como la

prueba t de Student (Student 1908) y el análisis de varianza ANOVA (Girden 1992). También se observó el número de sujetos de prueba en las muestras de investigación y el tipo de muestra (niños, jóvenes o adultos).

Para comenzar con estudios en niños y adolescentes, el trabajo de Burkhouse et al., (2015) encontró diferencias en el comportamiento ocular entre niños con madres deprimidas y aquellos sin ellas. Los hijos de madres deprimidas mostraron más síntomas de depresión, evidenciados por una mayor dilatación pupilar durante interacciones con estímulos negativos. Además en Owens et al., (2016) también se identificaron diferencias en la atención visual en niños, con un mayor enfoque en estímulos negativos en aquellos con madres deprimidas.

Sin embargo, los estudios en niños con riesgo o diagnóstico de depresión han arrojado resultados mixtos. Por ejemplo en Gibb et al., (2016) se observó que los hijos de madres deprimidas tienden a evitar estímulos negativos, mientras que en Platt et al., (2022) no se encontraron una correlación significativa entre pruebas de atención y síntomas de depresión en niños en riesgo.

Los resultados son más consistentes en adultos, quienes tienden a tener dificultades para desviar la atención de estímulos negativos. Esto sugiere que, en algún punto durante el desarrollo o la progresión de la depresión, las personas deprimidas pierden la capacidad de desviar su atención de estímulos tristes. Sin embargo, algunos estudios han reportado sesgo negativo en niños con síntomas depresivos, lo que requiere más investigación. Por ejemplo, los autores de Owens et al., (2016) sugirieron que esto podría estar relacionado con la genética.

En adolescentes, el trabajo de Lu et al., (2017) menciona que los pacientes con depresión tenían un sesgo de atención positiva reducido y un sesgo de atención negativa aumentado, independientemente de la edad. Además, en Greimel et al., (2020) se descubrieron que los adolescentes con depresión tenían dificultades en la regulación emocional al observar estímulos emocionales. Mientras que en Garcia et al., (2019) se concluyó que los sesgos de atención negativos estaban fuertemente asociados con niveles más altos de depresión y ansiedad social en estudiantes universitarios.

En el trabajo de Burkhouse et al., (2017) se investigó la reactividad neural y pupilar a estímulos emocionales en adolescentes con depresión. Se encontró que los adolescentes con depresión tenían una mayor dilatación pupilar en respuesta a estímulos emocionales en comparación con el grupo de control. Esto sugiere que la dilatación pupilar puede ser útil como un marcador en jóvenes con depresión.

En adultos, se ha observado un sesgo de atención hacia estímulos emocionales visuales en aquellos con depresión. Además, cambios en características oculares, como el tamaño de la pupila y el tiempo de fijación, también se ha reportado. Por ejemplo, se observó que el tamaño de la pupila tiende a aumentar en personas con depresión al enfrentar estímulos emocionales.

Se han explorado intervenciones para abordar el sesgo de atención en personas con depresión. Algunos estudios han utilizado el entrenamiento de modificación del sesgo de atención (ABTM) para condicionar la atención hacia estímulos positivos, lo que ha demostrado éxito en la reducción de síntomas de ansiedad. Además, paradigmas de recompensa musical se han utilizado para reducir el sesgo de atención negativo en personas con depresión.

También se ha investigado la relación entre la depresión y otros factores de salud, como el embarazo y el maltrato infantil. En mujeres embarazadas, se ha observado que aquellas con síntomas de depresión responden más a imágenes negativas. En el caso del maltrato infantil, aquellos con depresión y antecedentes de maltrato tienden a evitar estímulos negativos.

Finalmente, la rumiación, que implica repetir pensamientos negativos, se ha relacionado con el sesgo de atención y los niveles de depresión. La relación entre estos factores se mantiene incluso independientemente de los niveles de depresión.

Modelos para la detección de la depresión a través de características oculares

La Tabla 3.4 muestra una comparación entre los estudios de detección de la depresión, que incluyen los algoritmos utilizados, los tipos de datos utilizados y los resultados de predicción informados como métricas de predicción: precisión, sensibilidad y especificidad (si el estudio las informó). Para las 17 publicaciones, se revisaron los métodos, paradigmas experimentales y datos de seguimiento ocular.

Tabla 3.4: Estudios revisados sobre la detección de la depresión con los movimientos oculares

Trabajo	Año de publicación	Algoritmo	Precisión	Sensibilidad	Especificidad	Tipos de datos			#Características
						Imagen	Seguimiento ocular	Otros	
(Alghowinem et al., 2013)	2013	SVM	75.00%	--	--	✓			126
(Li et al., 2020)	2020	KELM	91.00%	91.06%	92.31%	✓			28
(Stolicyn et al., 2020)	2020	SVM	79.17%	76.00%	82.61%	✓			132
(Shafiei et al., 2020)	2020	RNN-LSTM	94.52%	--	--	✓			20
(Zhu, Z. Wang, et al., 2019)	2019	CBEM	78.50%	--	--	✓		✓	87
(Alghowinem et al., 2018)	2018	SVM & Fusión	86.00%	--	--	✓		✓	128
(Al-gawwam and Benaissa 2018)	2018	Adaboost	92.00%	--	--	✓			3
(Shen et al., 2021)	2021	SVM	77.00%	--	--		✓		--
(Lu et al., 2020)	2020	KELM	88.55%	87.71%	89.42%	✓			--
(Zhu et al., 2020)	2020	CBEM	82.50 %	--	--	✓		✓	87
(Gavrilescu and Vizireanu 2019)	2019	FFNN	79.80%	77.20%	78.10%	✓			30
(Pan et al., 2019)	2019	SVM	86.00%	88.00%	84.00%		✓		82
(Wang et al., 2019)	2019	Regresión Logística	93.02%	88.02%	--		✓		20
(Yuan and Wang 2019)	2019	Red neuronal	83.17%	--	--		✓		30
(Zhu, Y. Wang, et al., 2019)	2019	SVM Lineal	83.42%	--	--		✓	✓	1846
(Ding et al., 2019)	2019	Regresión Logística	79.63%	76.67%	85.19%	✓		✓	--
(Li et al., 2016)	2016	KNN	81.00%	--	--		✓		6

Nota: SVM=Support Vector Machines, RNN-LSTM=Long Short-Term Memory Recurrent Neural Network, CBEM=Content Based Ensemble Method, KELM=Kernel Extreme Learning Machine, FFNN=Feed-Forward Neural Network, KNN=K Nearest Neighbor.

En el trabajo de Alghowinem et al., (2013) se utilizaron un conjunto de datos de video para extraer características del movimiento ocular y clasificaron a los sujetos en dos clases: 1) deprimidos y 2) no deprimidos. Entrenaron dos clasificadores: un clasificador SVM y un clasificador híbrido que utilizaba modelos de mezcla gaussiana y un SVM. Los resultados indicaron que el modelo SVM con datos estáticos obtuvo el mejor rendimiento con una precisión del 75.00%. También observaron que, entre los deprimidos y los controles sanos, la apertura de los párpados era significativamente menor y la duración promedio de los parpadeos era más larga en los sujetos deprimidos.

En Stolicyn et al., (2020) se registraron medidas de comportamiento, faciales y de movimiento ocular de 75 participantes (34 con síntomas de depresión) durante tareas de rendimiento cognitivo (emparejar con una muestra y tareas de detección rápida) mientras se presentaban palabras emocionales distractores a los participantes. Se utilizaron

características estadísticas para entrenar un algoritmo SVM con un kernel gaussiano. Los autores informaron una precisión del 79.00% en la clasificación de la depresión.

Mientras que en Zhu et al., (2020) y Zhu, Z. Wang, et al., (2019), se describe un método de conjunto basado en contenido (CBEM) para mejorar la precisión en la detección de la depresión. Para estos estudios, los autores utilizaron un conjunto de datos de EEG y seguimiento ocular para entrenar varios clasificadores, con lo cual se obtuvo la mejor precisión del 82.50% con solo datos oculares y el 92.65% al alimentar con solo datos de EEG. También compararon algoritmos de clasificación clásicos para ambos conjuntos de datos. Los resultados mostraron que Random Forest funcionó mejor para datos no integrados, mientras que el kernel de función de base radial SVM funcionó mejor para datos integrados.

En Alghowinem et al., (2018) se combinaron características estadísticas de comportamiento del habla, actividad ocular y movimiento de cabeza para detectar la depresión con una fusión multimodal de características. Para las características relacionadas con los ojos, los autores extrajeron características estadísticas de direcciones de mirada, duración de los parpadeos, ojos cerrados, frecuencia de parpadeo, aversión de la mirada, movimiento del iris y movimiento de párpados. Se utilizaron clasificadores SVM en este estudio y se entrenaron en detección binaria (deprimido y no deprimido). Se probaron varias modalidades de fusión; sin embargo, los mejores resultados se obtuvieron mediante fusión de decisiones, que logró una precisión de hasta el 86.00% para la detección multimodal de la depresión.

En el trabajo de Shen et al., (2021) se observó un paradigma experimental cognitivo basado en la teoría de la atención y tecnologías de seguimiento ocular. El experimento constó de dos tareas principales en las que los participantes tenían que observar estímulos emocionales (neutros, negativos y positivos) y luego una tarea de vista controlada en la que se instruía al participante a observar una imagen específica. Después del experimento, los datos grabados se procesaron para extraer características y se utilizaron finalmente para entrenar un SVM para predecir a los sujetos de manera binaria (deprimidos y no deprimidos). El modelo logró una precisión del 77.00%.

En Pan et al., (2019), los autores detectaron la depresión al entrenar un algoritmo SVM con tiempos de reacción y movimientos oculares capturados de pacientes con depresión y controles sanos. Este paradigma de seguimiento ocular utilizó rostros emocionales como

estímulos visuales para registrar los datos de la mirada. Los autores fusionaron los datos de tiempo de reacción (características de 16 dimensiones) y movimiento ocular (características de 66 dimensiones) de 630 participantes (172 pacientes deprimidos y 458 sujetos de control) para entrenar su algoritmo. Esto logró una precisión del 86.00%.

Un enfoque multimodal para detectar tendencias depresivas fue discutido por Wang et al., (2019). Donde los autores fusionaron datos autoreportados con datos de seguimiento ocular. Los datos fusionados incluyeron movimiento ocular (observación de rostros emocionales), características de memoria (Wechsler Memory Scale), características de estilo cognitivo (Embedded Figure Test) y comportamiento en línea (2 semanas de uso de redes sociales). Estos datos se utilizaron como entrada para un metamodelo llamado modelo de ataque de exploración (SSM). Gracias a SSM, se entrenaron varios algoritmos de clasificación clásicos con características multimodales. El mejor rendimiento se logró con la regresión logística y KNN, con precisiones del 93.02% y 90.53%, respectivamente.

En el trabajo de Al-gawwam y Benaissa (2018) se utilizaron características de parpadeo extraídas de cuadros de video en los conjuntos de datos AVEC 2013 y AVEC 2014. Los conjuntos de datos AVEC contienen medios de video de entrevistas y tareas de lectura realizadas por participantes deprimidos. Para cada tarea AVEC, se entrenó un algoritmo AdaBoost parametrizado solo con las características de parpadeo extraídas. Se informó una precisión de detección del 92.95% para la tarea de lectura y del 88.00% para la tarea de entrevista.

En el trabajo de Zhu, Y. Wang, et al., (2019) obtuvieron datos de 51 estudiantes universitarios (de 18 a 24 años) para procesarlos en fusiones multimodales de EEG y datos de movimiento ocular. La fusión de características se realizó con dos enfoques de redes neuronales con un autoencoder. Primero, las características se vincularon en función el enfoque BestFirst de WEKA, luego se realizó una fusión de capas ocultas, donde se utilizó el algoritmo BestFirst para generar una representación compartida de EEG y movimientos oculares. Todos los métodos de fusión y características unimodales se probaron con los seis métodos de clasificación. El método de capa oculta funcionó mejor con un algoritmo SVM lineal, con una precisión del 83.42%. Los autores afirmaron que la identificación en tiempo real de la depresión puede ser posible mediante enfoques de aprendizaje profundo multimodales.

Mientras que en Ding et al., (2019) se utilizaron datos de EEG, seguimiento ocular y respuesta galvánica de la piel (GSR) para diferenciar entre pacientes con depresión y sujetos sanos. Este enfoque de ML multimodal recopiló datos de 144 pacientes con TDM y 204 sujetos sanos durante una tarea de visualización de estímulos emocionales. Se entrenaron tres algoritmos de ML para construir el modelo de clasificación. Los autores informaron que el algoritmo de regresión logística tuvo el mejor rendimiento, con una precisión del 79.63%.

El enfoque final de algoritmos de clasificación clásica en la revisión fue informado en Li et al., (2016), donde los autores buscaron desarrollar un enfoque objetivo para la detección de la depresión con datos de movimiento ocular. En este experimento, 34 participantes (9 deprimidos y 25 controles) observaron 15 ensayos de estímulos emocionales mientras se registraban datos de seguimiento ocular. Se extrajeron características de fijación, sacada, pupila y preferencia negativa. A partir de este conjunto, se seleccionaron seis características en función de selección de características basadas en correlación (CFS) con un enfoque BestFirst. Los resultados mostraron que KNN logró el mejor rendimiento con una precisión del 81%.

A continuación, revisamos enfoques de clasificación de redes neuronales. Por ejemplo, en Shafiei et al., (2020) se utilizó una red neuronal profunda entrenada con métricas visuales para identificar el estado de salud mental de los pacientes con cáncer después de la cirugía. Los participantes fueron evaluados mediante escalas de autoinforme para esperanza, ansiedad y bienestar. Se registraron datos de 25 sujetos que observaron 18 obras de arte diferentes, y estos datos se utilizaron para modelar tres clases diferentes de pacientes y predecir características de las escalas de autoinforme. En este trabajo, los autores informaron un 95.00% de precisión en la predicción del estado de bienestar.

Mientras que en Gavrilescu y Vizireanu (2019) se informó sobre un sistema para predecir los niveles de depresión, ansiedad y estrés con características oculares. Los autores clasificaron los niveles de salud mental al utilizar la Escala de Depresión, Ansiedad y Estrés (DASS) (Parkitny y McAuley 2010). El sistema de detección combina tres capas: 1) primero, las unidades de acción (AU) se clasifican mediante SVM y modelos de apariencia activa; 2) se construye una matriz con los niveles de AU; y 3) finalmente, la matriz se introduce en una red neuronal de alimentación directa óptima (FFNN). La red neuronal realizó una tarea de

reconocimiento de patrones, logrando predecir los niveles de DASS. Este sistema logró una precisión del 87.20% para la detección de la depresión y pudo diferenciar entre MMD y pacientes sanos con una precisión del 93.00%.

En el trabajo de Li et al., (2020) se informó de un método para la clasificación de la depresión basado en patrones de movimiento ocular. Los autores utilizaron estímulos emocionales y tecnologías de seguimiento ocular para registrar datos de comportamiento ocular junto con señales fisiológicas de 48 sujetos de control y 48 pacientes con depresión. Los autores propusieron una característica de ancho de banda afectivo que se calculó al restar el diámetro promedio de la pupila en todos los puntos de fijación durante la tarea neutral del diámetro promedio en las tareas positivas o negativas. Luego, al utilizar métodos estadísticos como la prueba t corregida de FDR y el análisis de componentes principales (PCA), se redujo el ruido y la información redundante. Se entrenó un algoritmo KELM. Los resultados mostraron que la fusión de características del comportamiento ocular y el ancho de banda afectivo produce mejores resultados que el uso de una sola característica. Su método logró una precisión del 91.00%. Similarmente, en Lu et al., (2020) también se logró la detección de la depresión con características oculares como fijaciones y un clasificador KELM con precisión del 88.55%.

En el trabajo de Yuan y Wang (2019) se utilizó una red neuronal con trayectorias de movimiento ocular. Los datos de seguimiento ocular se obtuvieron de una tarea de distracción en la que se instruyó a los sujetos que enfocaran su mirada en un objetivo central e ignoraran los objetivos que aparecían. Se utilizaron técnicas de extracción y transformación de características en este estudio. El conjunto de datos resultante constó de 149 matrices con 10 secuencias y cinco características. Los autores definieron la depresión al clasificar las trayectorias oculares y las diferencias con las coordenadas de distracción. Se utilizó 111 muestras para entrenar la red y 37 muestras para la prueba. La red neuronal se diseñó con Keras de Python y se optimizó en tres submodelos: 1) un modelo con datos estandarizados StandarScaler de scikitlearn (Pedregosa et al., 2011), que preserva la distribución gaussiana y normaliza la tendencia central; 2) un modelo que implementa menos neuronas, lo que obliga a la fase de entrenamiento a seleccionar características más significativas; y 3) un modelo con muchas neuronas, que agrega una nueva capa y aumenta la probabilidad de ajustar todas las variables de entrada. De los submodelos evaluados, el que tuvo mejor rendimiento fue el modelo con menos neuronas, que logró una precisión del 83.17%.

3.2.3 Discusión del estado del arte

Los métodos tradicionales de evaluación de la depresión incluyen entrevistas e instrumentos de autoinforme como el DBI-II, HRSD y PHQ-9, entre otros. Sin embargo, los nuevos paradigmas de cómputo afectivo pueden actuar como apoyo para una forma objetiva de distinguir estos comportamientos debido al comportamiento cognitivo anormal reflejado en los patrones oculares.

Los estudios revisados mostraron que las personas con depresión tienden a tener dificultades para desviar la atención cuando se enfrentan a estímulos negativos. Esto se logró al implementar datos del comportamiento ocular para demostrar la correlación de las características oculares con el proceso cognitivo de la atención en la depresión.

En el caso de la depresión en niños, se encontraron cuatro artículos que discutieron poblaciones infantiles, tres estudios que utilizaron poblaciones adolescentes y dos publicaciones donde la población se definió como adultos jóvenes. Como se observa, hay pocos trabajos sobre la depresión en la juventud, pero se ha encontrado que los comportamientos asociados a la depresión en poblaciones jóvenes son similares a los patrones de comportamiento en adultos. Sin embargo, se han observado diferencias en algunos estudios entre niños y diferentes grupos de edad.

Contrariamente al enfoque usual en estímulos negativos, hay una tendencia en los niños pequeños con riesgo de depresión a evitar los estímulos emocionales. Además, se informó poca correlación en tres pruebas de atención entre niños con riesgo de depresión y un grupo de control.

Se observaron enfoques y algoritmos similares para la detección de la depresión. Algunos estudios utilizaron datos unimodales para la detección de la depresión, ya sea extrayendo características oculares con procesamiento de imágenes o al utilizar seguimiento ocular. Se observaron soluciones multimodales que fusionaron diferentes fuentes de datos, incluido el seguimiento ocular, EEG, GSR, movimientos de cabeza y habla, para mejorar la detección. Las SVM fueron los algoritmos de ML más populares, seguidos de las redes neuronales.

En la Tabla 3.4, los estudios sobre detección de la depresión seleccionaron diversas características de fijación y movimientos oculares para entrenar sus algoritmos. Estas

características han sido fundamentales en el análisis de seguimiento ocular, empleándose en la creación de mapas de fijación, mapas de movimientos sacádicos y la identificación de áreas de interés. Aunque el parpadeo y la dilatación de la pupila se utilizan menos, pueden servir como indicadores de estados mentales y emocionales.

Además, al revisar la literatura, notamos que hay menos estudios que se centran únicamente en datos de seguimiento ocular para detectar la depresión. La mayoría de los estudios hacen uso de datos de procesamiento de videos o imágenes de los ojos de los participantes.

Limitaciones

Una limitación importante es que los autores crearon y utilizaron sus propios conjuntos de datos para la investigación, debido a esto, el acceso a estos conjuntos de datos era limitado debido a la sensibilidad de los registros médicos y la información personal de los participantes. Esto dificulta la reproducción de los estudios. Además, algunos autores no informaron más métricas para la evaluación de los resultados del ML.

Alcance de la aplicación

A pesar de que la investigación revisada logró detectar la depresión, pocos de los trabajos mencionaron la posibilidad de implementar una herramienta objetiva de detección de la depresión. Esta herramienta podría utilizarse para respaldar la evaluación y prevención de la salud mental. Sin embargo, no debe reemplazar el diagnóstico médico por parte de expertos y solo debe utilizarse como una herramienta de apoyo para evaluar la gravedad de los síntomas de la depresión y hacer un seguimiento de los síntomas de un paciente durante sus visitas médicas.

Además, las características de seguimiento ocular pueden utilizarse para diferenciar entre diferentes enfermedades mentales, como la ansiedad, la depresión y el autismo. También se considera que la privacidad de los pacientes puede garantizarse con solo el seguimiento ocular como medio de recopilación de datos.

3.3 Definición de la población y muestra

Debido a que este trabajo se centra en la detección de depresión en jóvenes, para este estudio se requiere un grupo de estudio, el cual se define como un conjunto de jóvenes clasificados con depresión a través de instrumentos como el DASS-21. Además, se requiere de un grupo de control. Para este motivo se definieron las siguientes restricciones (criterios de inclusión y exclusión del estudio) para el registro de datos:

- La muestra debe ser personas jóvenes mexicanas con un perfil de educación de nivel medio hasta nivel superior entre las edades de 15 a 29 años.
- No importa el sexo del participante, sin embargo, se busca tener un número equilibrado entre hombres y mujeres.
- Los participantes no deben tener problemas físicos en los ojos (lesiones, o enfermedades oculares).
- Los participantes no deben estar diagnosticados con trastornos mentales, a excepción de depresión, ansiedad o estrés.
- La muestra será dividida dos grupos:
 - Grupo con depresión (según el instrumento DASS-21).
 - Grupo sin depresión.

La Tabla 3.5 muestra el resumen de los criterios de inclusión/exclusión.

Tabla 3.5: Criterios de selección considerados

Criterio de inclusión	Grupo depresión	Grupo de control
Edad	18 – 29 años	18 – 29 años
Genero	Hombre o mujer	Hombre o mujer
Tipo de paciente	Primera vez	--
Medicado	No	No
Problemas físicos en los ojos	No	No
Otros trastornos mentales	No	No
DASS	Mayor que depresión moderada	Menor que depresión moderada
Inventario de Beck	Mayor que moderadamente deprimido	Menor que moderadamente deprimido
Sintomatología depresiva	Positiva	Negativa

Además de los criterios de inclusión/exclusión, fue importante asentar un consentimiento con los participantes menores de edad y los padres de los mismos, donde se informe el procedimiento a realizar, los datos a recabar, como serán utilizados y como serán expuestos a estímulos emocionales y a dispositivos de captura de datos de seguimiento ocular con luces led infrarrojas. Es por este motivo que el estudio, a través de la co-directora, la doctora Leonor Rivera Rivera, participa en conjunto con el Instituto Nacional de Salud Pública (INSP).

La carta de asentamiento, la cual informa del proceso del estudio a los padres menciona el objetivo principal que es identificar factores de comportamiento visual relacionados con la salud mental, al utilizar cuestionarios y pruebas de visualización, con la participación voluntaria y confidencial de los estudiantes y sus padres. Este documento puede ser consultado en su totalidad en el Anexo 4. Mientras que la carta de consentimiento por parte de los jóvenes participantes puede ser consultada en su totalidad en el Anexo 5.

3.3.1 Colaboración con el Instituto Nacional de Salud Pública y Comité de Ética

En cumplimiento con los estándares y directrices éticas, el estudio recibió la aprobación del Comité Ético del INSP. Esto incluyó el formulario de consentimiento para los participantes, sus padres y la escuela. La aprobación del INSP y el consentimiento de los participantes fue necesario ya que el compromiso con la garantía de los derechos, el bienestar y la privacidad de los participantes en el estudio es un requerimiento importa para los estudios con personas.

La supervisión ética proporcionada por el INSP agregó una capa crucial de credibilidad e integridad al proceso de investigación, lo cual refuerza los fundamentos éticos que sustentan todo el estudio.

3.3.2 Protocolo de acción en casos de depresión

Conforme a los principios éticos y normativas de protección de datos, los cuales priorizan la privacidad y el bienestar del estudiante en todo momento, el protocolo a seguir en caso de detectar a un estudiante con posibles problemas de depresión consiste en los siguientes pasos:

- **Identificar y evaluar** los resultados obtenidos en los cuestionarios o pruebas aplicadas, al asegurar su validez y correspondencia mediante una revisión interna del equipo de investigación (expertos).
- **Notificar de manera confidencial** a las autoridades escolares, como el orientador o psicólogo de la institución, sobre la situación del estudiante, mientras se garantiza la privacidad y se evita cualquier tipo de estigmatización.
- **Recomendar una intervención y apoyo** por parte de un profesional de la salud mental, canalizando al estudiante a servicios de apoyo psicológico dentro de la institución educativa o en colaboración con el Instituto Nacional de Salud Pública (INSP).
- **Informar a los padres o tutores** si es necesario y conforme a la normativa vigente, mientras se asegura que el estudiante cuente con el apoyo adecuado para acceder a atención profesional.
- **Realizar un seguimiento del caso** en conjunto con el personal escolar y, en la medida de lo posible, con el estudiante y su familia, para verificar que reciba la atención necesaria y evaluar su evolución.

3.4 Material e instrumentos de recolección de datos

A continuación, se detallan los materiales e instrumentos utilizados en este trabajo de investigación.

3.4.1 Estímulos emocionales

Se utiliza una muestra de 30 imágenes del conjunto de estímulos emocionales en imágenes del International Affective Picture System (IAPS) de Lang, Bradley, y Uthbert (2008). Estas imágenes se clasifican en diferentes niveles de valencia positivas y negativas. Originalmente este repositorio de imágenes fue probado en países de habla inglesa, se adaptó en España y ha sido probado en México donde los valores mexicanos son similares a los de la muestra normativa: La correlación lineal encontrada ($p < 0.001$)

(Madera-Carrillo et al., 2015). El conjunto IAPS (ver Figura 3.2) cuenta con 700 estímulos visuales, cada uno clasificado según su nivel de valencia, activación y dominio (Russell and Mehrabian 1977).




Figura 3.2: Algunos estímulos de la base de datos IAPS. Fuente: International affective picture system (IAPS): Affective ratings of pictures and instruction manual, (Lang et al., 2008)

Se realizó un estudio donde se exploró cómo los jóvenes mexicanos perciben emocionalmente imágenes de IAPS. Se recopiló datos de participantes que evaluaron la valencia emocional de distintas imágenes, lo que permitió analizar patrones en la percepción emocional y comparar los resultados con estudios previos en otras poblaciones. Los resultados indican que ciertas imágenes pueden tener interpretaciones emocionales diferentes en jóvenes mexicanos en comparación con otras poblaciones, lo cual destaca la importancia de la validación cultural en estudios de emociones (Lagunes-Ramírez et al., 2023).

Finalmente, los 30 estímulos específicos de IAPS fueron seleccionados en función de los resultados. Además, se han seleccionado para no incluir imágenes que puedan activar a nivel personal alguna fobia o trauma en el paciente y según su nivel intensidad desde bajo hasta alto.

A continuación, la Tabla 3.6 muestra una comparativa de los estímulos IAPS seleccionados y sus niveles de valencia con los estudios de Lang et al., Y Madera-Carrillo:

Tabla 3.6: Evaluación y comparación de IAPS

	IAPS	Lang et al., (2008)	Madera-Carrillo et al., (2015)	Lagunes- Ramírez (2023)
Clase	Id	Valencia	Valencia	Valencia
Positivos	4612	6.82	7.6	6.88
	2341	7.38	7.63	6.86
	2340	8.03	7.63	7.35
	2347	7.83	7.65	7.22
	8170	7.63	7.66	6.74
	2151	7.32	7.68	7.01
	2332	7.64	7.71	7.57
	2091	7.68	7.73	7.58
	8190	8.1	7.74	7.22
	2165	7.63	7.74	6.83
	2655	6.88	7.79	7.41
	2155	6.78	7.83	6.52
	2057	7.81	7.89	6.75
	2540	7.63	8	6.49
	8496	7.58	8.11	7.51
Negativos	2688	2.73	2.1	2.59
	2703	1.91	2.18	1.96
	2095	1.79	2.77	1.67
	2456	2.84	3.71	2.04
	6212	2.19	2.04	1.96
	2396	4.91	4.92	1.61
	2397	4.98	5.04	2.59
	2410	4.62	4.95	1.78
	2495	5.22	5.04	2.14
	2575	5.46	5.06	1.84
	2595	4.88	4.95	2.75
	2745.1	5.31	5	2.23
	2850	5.22	5.07	2.03
	2104	4.42	4.84	2.10
	9002	3.39	4.92	2.43

3.4.2 Cuestionarios

Los instrumentos de cuestionario que fueron utilizados son:

- **CES-D (Center for Epidemiologic Studies Depression Scale):** Cuestionario diseñado para medir síntomas depresivos en la población general durante la última semana. Evalúa la frecuencia e intensidad de emociones y pensamientos relacionados con la depresión (Radloff 1977).
- **PHQ-2 (Patient Health Questionnaire-2):** Instrumento breve que evalúa la presencia de síntomas depresivos en los últimos 14 días. Se utiliza como una

herramienta de tamizaje para identificar casos que requieren una evaluación más profunda (Kroenke, Spitzer, y Williams 2003).

- **DASS-21 (Depression Anxiety Stress Scales-21):** Cuestionario de 21 ítems que mide síntomas de depresión, ansiedad y estrés en tres subescalas separadas. Es útil para evaluar la gravedad de estos síntomas en la población general y clínica (Lovibond y Lovibond 1995).
- **Datos sociodemográficos:** Conjunto de preguntas que recopilan información básica sobre los participantes, como edad, sexo, nivel educativo y antecedentes personales. Estos datos permiten contextualizar los resultados y analizar posibles factores asociados a las variables de interés.
- **Percepción de la inducción emocional:** Cuestionario que evalúa la respuesta subjetiva de los participantes ante estímulos emocionales presentados durante el estudio. Permite conocer cómo perciben e interpretan las emociones inducidas por imágenes u otros estímulos.

Estos instrumentos serán utilizados, en primera instancia, para realizar el tamizaje de jóvenes con depresión y posteriormente clasificarlos según la severidad de sus síntomas. Además, los datos sociodemográficos permiten realizar filtros de participantes en función de su estado. Finalmente, el cuestionario de percepción de la prueba será utilizado para observar si los estímulos emocionales tuvieron el impacto esperado.

3.4.3 Proceso de inducción emocional

Para realizar este proceso se adaptará la metodología del Proceso de inducción emocional (PIE) de (Soriano Terrazas, 2018; Ver Figura 3.3). Esta metodología considera cinco escenarios que utilizan estímulos audiovisuales, en este caso solo se presentaran escenarios de imágenes emocionales del repositorio IAPS, durante la exposición de los estímulos se pueden registrar y grabar datos multimodales relacionados con el comportamiento del usuario, que incluyen: datos de seguimiento ocular, video de la expresión facial del usuario,

electrocardiograma (ECG), electroencefalograma (EEG) y respuesta galvánica en piel (GSR).




Figura 3.3: Esquema del PIE. (Soriano Terrazas, 2018) . Tomado con permiso del autor

La Figura 3.4 muestra la adaptación de esta metodología al contexto de este trabajo.




Figura 3.4: Esquema del proceso de inducción emocional PIE adaptado al contexto de esta investigación

3.4.4 Hardware

A continuación, se detallan los dispositivos y requisitos técnicos utilizados en el estudio:

- **Sensor GazePoint GP3 o GP3 HD:** Se utilizará un sensor de seguimiento ocular GP3 HD, este sensor procesa imágenes grabadas a 150Hz de los ojos de los usuarios para obtener datos de cada uno de los ojos, entre estos se encuentran: Puntos de visión en la pantalla, fijaciones, sacadas y la dilatación de la pupila.
- **Base para sensor:** El sensor de seguimiento ocular se coloca en la parte inferior de pantallas de menos de 24 pulgadas y debe ser calibrado para cada usuario que lo utiliza esto para obtener mejores lecturas de los ojos de la persona. La calibración consiste en una pequeña prueba donde el usuario observa distintos puntos que aparecen en la pantalla.
- **Equipo de cómputo:**
 - o 4 Gb de RAM o más
 - o 100 Gb de espacio de almacenamiento o más
 - o Procesador Intel Core I3 o AMD Ryzen 5 o superior
- **Monitor adicional:** De al menos 1200 * 800 pixeles

Cabe destacar que adicionalmente se requiere de insumos para conexiones eléctricas y conexiones USB 3.0 adicionales si el equipo de cómputo lo requiere. Al mismo tiempo, el monitor adicional podría variar en frecuencias de refresco.

Factores ambientales para toma de muestras

Evidentemente, cualquier toma de datos en cualquier contexto requiere de un ambiente controlado. En el caso específico de este estudio se consideran los siguientes factores ambientales para obtener datos de pruebas más estables:

- Minimizar los cambios de luminosidad durante las pruebas
- Minimizar los ruidos externos y distracciones durante las pruebas
- Establecer la temperatura ambiental en un rango fijo (recomendado 22-24 grados centígrados)
- Minimizar las corrientes de aire al rostro de los participantes

- Minimizar los movimientos del usuario durante la prueba, al utilizar asientos cómodos, indicarle al usuario que no mueva demasiado su cabeza y/o cuerpo durante la prueba
- Si es posible para el usuario, retirar lentes y lentes de contacto antes de realizar la prueba
- Mantener la misma distancia del usuario a la pantalla y el sensor en la medida de lo posible durante la prueba
- Ajustar el brillo y contraste del monitor a niveles amigables con la vista de los usuarios.

3.4.5 Software

En esta sección se describen los componentes de software utilizados para la recolección de datos, así como el desarrollo y adaptación de algunos de ellos, dado que fue necesario realizar ajustes para obtener información específica del seguimiento ocular bajo ciertos requerimientos técnicos.

Gazepoint GazeControl

GazePoint GazeControl es un software desarrollado por GazePoint que permite la calibración, configuración y control de los sensores de seguimiento ocular de la marca, como el GazePoint GP3 y GP3 HD. Su principal función es proporcionar una interfaz para visualizar y registrar los datos del movimiento ocular en tiempo real, lo que facilita su uso en investigaciones, estudios de usabilidad y aplicaciones de accesibilidad. Sus características principales son:

- Calibración personalizada: Permite ajustar la precisión del seguimiento ocular con diferentes métodos de calibración (por ejemplo, de 5 o 9 puntos).
- Visualización en tiempo real: Muestra la ubicación de la mirada en la pantalla mediante un cursor o un mapa de calor.

- Exportación de datos: Guarda los registros de seguimiento ocular en formatos compatibles con herramientas de análisis como Excel o software de procesamiento de datos.
- Compatibilidad con API: Ofrece una API para integrar los datos de seguimiento ocular en aplicaciones personalizadas o experimentos científicos.
- Configuración de parámetros: Permite ajustar la frecuencia de muestreo, el filtrado de datos y otros aspectos técnicos del sensor.

Este software es ampliamente utilizado en investigaciones de interacción humano-computadora, estudios de atención visual y experimentos en neurociencia y psicología cognitiva. La Figura 3.5 ilustra su uso.




Figura 3.5: Interfaz gráfica de GazePoint Control

Python 3

Es un lenguaje de programación interpretado, de alto nivel y multiparadigma, ampliamente utilizado en desarrollo web, análisis de datos, inteligencia artificial, automatización y más. Su diseño se centra en la legibilidad del código y la simplicidad, lo que facilita su aprendizaje y uso. Cuenta con una extensa biblioteca estándar que permite realizar diversas tareas sin necesidad de instalar dependencias adicionales. Sin embargo, su comunidad activa y su constante evolución hace que exista una rica biblioteca de librerías compatibles y listas para usar en proyectos de software.

En el contexto de este trabajo se utilizaron las siguientes librerías en Python 3.7.9:

absl-py==1.4.0	MarkupSafe==2.1.2	pygaze==1.1.2
cachetools==4.2.4	matplotlib==3.5.3	pyts==0.12.0
chardet==5.2.0	moviepy==1.0.3	pytz==2023.3
charset-normalizer==3.0.1	mss==7.0.1	requests==2.31.0
colorama==0.4.6	numba==0.56.4	requests-oauthlib==1.3.1
cycler==0.11.0	numpy==1.21.6	rsa==4.9
decorator==4.4.2	oauthlib==3.2.2	scikit-learn==1.0.2
Django==3.2.20	opencv-python==4.7.0.68	scipy==1.4.1
docopt==0.6.2	opt-einsum==3.3.0	shiboken2==5.15.2.1
ffmpy==0.3.0	packaging==23.0	six==1.16.0
fonttools==4.38.0	pandas==1.3.5	tensorboard==2.1.1
gast==0.2.2	Pillow==10.0.0	tensorflow==2.1.0
grpcio==1.51.1	pipreqs==0.4.13	tensorflow-estimator==2.1.0
h5py==2.10.0	proglog==0.1.10	threadpoolctl==3.1.0
idna==3.4	protobuf==4.21.12	tqdm==4.64.1
imageio==2.25.0	psutil==5.9.4	urllib3==1.26.14
imageio-ffmpeg==0.4.8	pyasn1==0.4.8	Werkzeug==2.2.2
importlib-metadata==6.0.0	pyasn1-modules==0.2.8	wrapt==1.14.1
jobjlib==1.2.0	pymediainfo==6.0.1	yarg==0.1.9
Keras-Applications==1.0.8	pyparsing==3.0.9	zipp==3.12.1
Keras-Preprocessing==1.1.2	PyQt5==5.15.9	
kiwisolver==1.4.4	PyQt5-Qt5==5.15.2	
llvmlite==0.39.1	PyQt5-sip==12.11.1	
lxml==4.9.2	PySide2==5.15.2.1	
Markdown==3.4.1	python-dateutil==2.8.2	

UXLab

Cabe destacar que la línea de Tecnologías Inteligentes de Software (TIS) de Cenidet cuenta con una herramienta de grabación de datos multimodal denominada UXLab (Fouilloux Quiroz 2018). Esta suite integra sensores de seguimiento ocular y otros dispositivos para asegurar la sincronización de datos provenientes de múltiples fuentes. Sin embargo, UXLab es un sistema complejo que depende de numerosas librerías externas y presenta un proceso de instalación laborioso, además de requerir un consumo considerable de recursos computacionales, como memoria RAM y espacio en disco.

La Figura 3.6 muestra la arquitectura del software UXLab donde también se destaca con un recuadro rojo los componentes de ET.

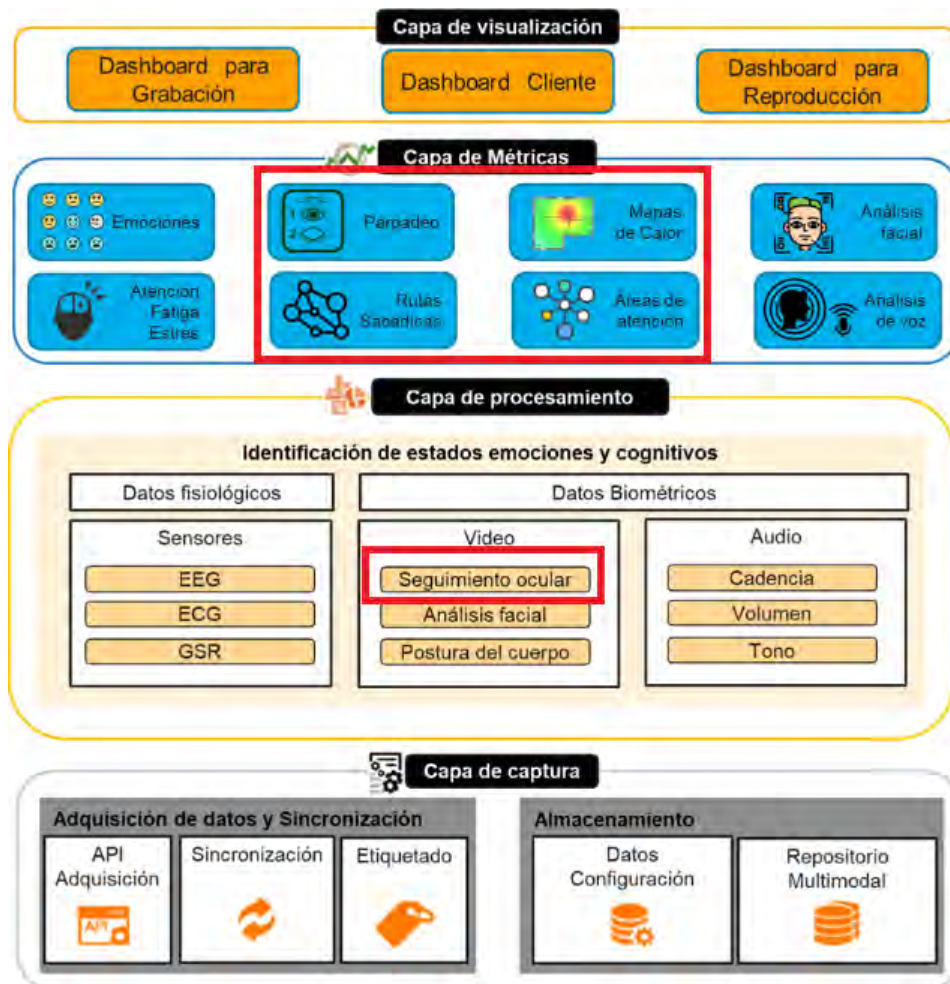


Figura 3.6: Arquitectura de UXLab

Inicialmente, se planeó utilizar UXLab para la captura de datos de seguimiento ocular de los participantes del estudio, por lo que parte del trabajo desarrollado fue la integración de la API del sensor GazePoint GP3 para la adquisición de datos. En este contexto se utilizó Python para conectar UXLab con el servicio de API del sensor GP3 a través de una conexión con el software servidor “GazePoint Control”.

La Figura 3.7 ilustra cómo este subcomponente se incorpora dentro del esquema de funcionalidades de UXLab.




Figura 3.7: Funcionales de UXLab

La integración fue exitosa, donde los datos del sensor se empaquetan y sincronizan con el resto de flujo de datos de la suite UXLab. No obstante, debido a las dificultades asociadas a la instalación y al alto consumo de recursos de UXLab, se optó por desarrollar una alternativa más ligera y eficiente, enfocada exclusivamente en la grabación de los datos esenciales para este estudio. Este nuevo software, denominado “UXLite”, permitió simplificar el proceso de adquisición de datos sin comprometer la calidad ni la precisión de la información obtenida.

Generador de métricas visuales PIE

El Generador de Métricas Visuales "PIE" es un software que fue desarrollado en este trabajo de investigación. Fue programado en el lenguaje Python y diseñado para el procesamiento y análisis de datos de seguimiento ocular obtenidos a través de pruebas realizadas con UXLab. Esta herramienta permite la extracción de métricas visuales a partir de archivos CSV de seguimiento ocular y datos de video de la pantalla del usuario, lo cual proporciona un análisis detallado del comportamiento visual en diferentes escenarios experimentales.

La Figura 3.8 muestra la interfaz gráfica del software.




Figura 3.8: Interfaz del software PIE para la generación de métricas oculares

PIE ofrece un conjunto de funcionalidades avanzadas para el análisis de datos, incluyendo la generación de métricas básicas, análisis de eventos específicos y visualización gráfica de patrones de atención. Entre sus capacidades destacan:

1) Métricas y Análisis de Seguimiento Ocular

- **Métricas básicas:** Permiten evaluar parámetros fundamentales del comportamiento visual, como la duración de la fijación y la velocidad de los movimientos sacádicos.

- **Mapas de atención:** Representaciones visuales que muestran las regiones más observadas por los participantes durante la prueba.
- **Análisis del parpadeo y dilatación pupilar:** Evaluación de la frecuencia y duración de los parpadeos, así como cambios en el diámetro de la pupila en respuesta a estímulos visuales.
- **Áreas de interés (AOIs):** Segmentación del entorno visual en regiones específicas para analizar la interacción del usuario con elementos particulares de la pantalla.

2) Visualización Avanzada de Datos

- **Mapas de calor (en video e imagen):** Representaciones gráficas acumulativas que resaltan las zonas de mayor fijación ocular a lo largo del tiempo.
- **Campos de transición de Markov:** Modelado probabilístico del desplazamiento de la mirada entre diferentes regiones de la pantalla.
- **Campos de suma y diferencia angular:** Análisis de la variación direccional del movimiento ocular.
- **Transformada de Gabor (Espectrograma):** Extracción de características visuales en el dominio de la frecuencia para estudiar patrones complejos de atención.

3) Eventos PIE y Métricas Temporales

- **Primer estímulo observado:** Registro del primer elemento visual detectado por el usuario al inicio de la prueba.
- **Tiempo gastado en estímulo:** Medición de la duración total de la fijación ocular sobre estímulos específicos.

PIE se integra como una herramienta fundamental para el análisis del comportamiento visual en estudios de inducción emocional y pruebas de usabilidad. Su capacidad para procesar grandes volúmenes de datos y generar representaciones visuales detalladas lo convierte en un recurso esencial tanto en el ámbito de la investigación académica como en aplicaciones clínicas.

Además, este software facilita la automatización del procesamiento de datos provenientes de UXLab, lo cual asegura compatibilidad con los formatos de salida de estas plataformas. Su

implementación permite obtener métricas precisas que pueden ser utilizadas para evaluar la respuesta visual ante distintos estímulos, ofreciendo así una herramienta valiosa para el estudio del comportamiento humano basado en seguimiento ocular.

UXLite

UXLite, también conocida como “QUXBox” es una herramienta computacional que fue desarrollada para la grabación de pruebas de inducción emocional con seguimiento ocular y captura de video, tanto de pantalla como de cámara web. A diferencia de UXLab, su predecesor, UXLite es una versión optimizada y ligera, diseñada para reducir el consumo de recursos computacionales sin comprometer la calidad y compatibilidad de los datos generados.

Este software, desarrollado en Python 3.7.9, emplea solo tres bibliotecas externas, lo que minimiza la necesidad de mantenimiento y simplifica su implementación en distintos entornos. Con un tamaño total de solo 100 MB y un consumo de memoria de aproximadamente 1 GB de RAM, UXLite permite la realización de pruebas en equipos de cómputo de gama baja, lo que facilita su adopción en diversos escenarios de investigación y aplicación clínica. La Figura 3.9 muestra la interfaz del programa.




Figura 3.9: Interfaz del software UXLite para la grabación de datos de seguimiento ocular en función de una inducción emocional

A pesar de su menor demanda de recursos, UXLite mantiene la compatibilidad total con los formatos de salida de UXLab, al generar archivos de seguimiento ocular y video que pueden ser procesados mediante herramientas estándar para el análisis de datos, como la generación de mapas de calor y la delimitación de áreas de interés. Además, implementa el Proceso de Inducción Emocional (PIE) lo convierte en una solución integral para el estudio de respuestas emocionales en el contexto del comportamiento ocular.

En términos operativos, UXLite ha sido probado en equipos con 8 GB de memoria RAM, esto logró grabaciones de sesiones de observación libre del PIE con una duración promedio de 22 minutos, al utilizar solo 914 MB de memoria. Su arquitectura de procesamiento multihilo optimizada permitió la captura de datos de seguimiento ocular con video de pantalla a 29.50 fps, y esto significa que garantiza la calidad y precisión de la información recolectada.

Además de su aplicación en entornos de investigación, UXLite fue la herramienta clave para la grabación de datos de seguimiento ocular en jóvenes dentro del estudio realizado en esta tesis. Su diseño modular permitió su integración como una herramienta propuesta para ser utilizada en consultorios clínicos, donde expertos en salud mental pueden emplearla como apoyo en el diagnóstico de la depresión. El flujo de UXLite se detalla en la Figura 3.10.

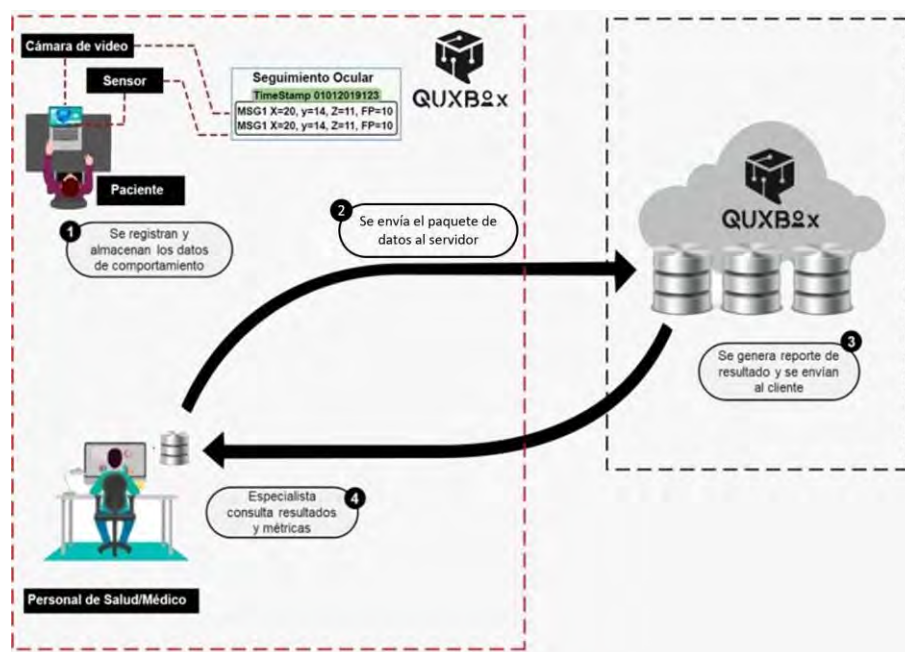


Figura 3.10: Flujo del proceso de UXLite

Esta funcionalidad se ve reforzada por su capacidad para realizar la inducción emocional, recolectar datos y enviarlos a un servidor en la nube. En este servidor, los datos son procesados y comparados con un modelo de ML, el cual analiza el comportamiento del paciente y devuelve un resultado sobre la posible presencia de síntomas depresivos.

Gracias a estas características, UXLite representa una solución accesible y eficiente para la evaluación del comportamiento ocular en entornos clínicos y de investigación, que facilita el análisis de respuestas emocionales con una infraestructura tecnológica optimizada.

3.5 Procedimiento de la recolección de datos

Para el proceso para la recolección de datos se sigue la estructura del PIE adaptado y se puede observar de forma general en la Figura 3.11.




Figura 3.11: Esquema del proceso de recolección de datos

Como se puede observar el proceso consta de 5 fases con actividades específicas, este proceso se repite por cada participante y dura aproximadamente 25 minutos por persona. Cada participación se registra con un identificador único sin registrar datos personales de los jóvenes como lo son el nombre, edad o matrícula.

Finalmente, los datos recopilados, tanto de cuestionarios como de seguimiento ocular son guardados en un repositorio de datos del cual se darán detalles más adelante en el documento.

El flujo del proceso puede apreciarse en el siguiente diagrama de flujo (ver Figura 3.12).

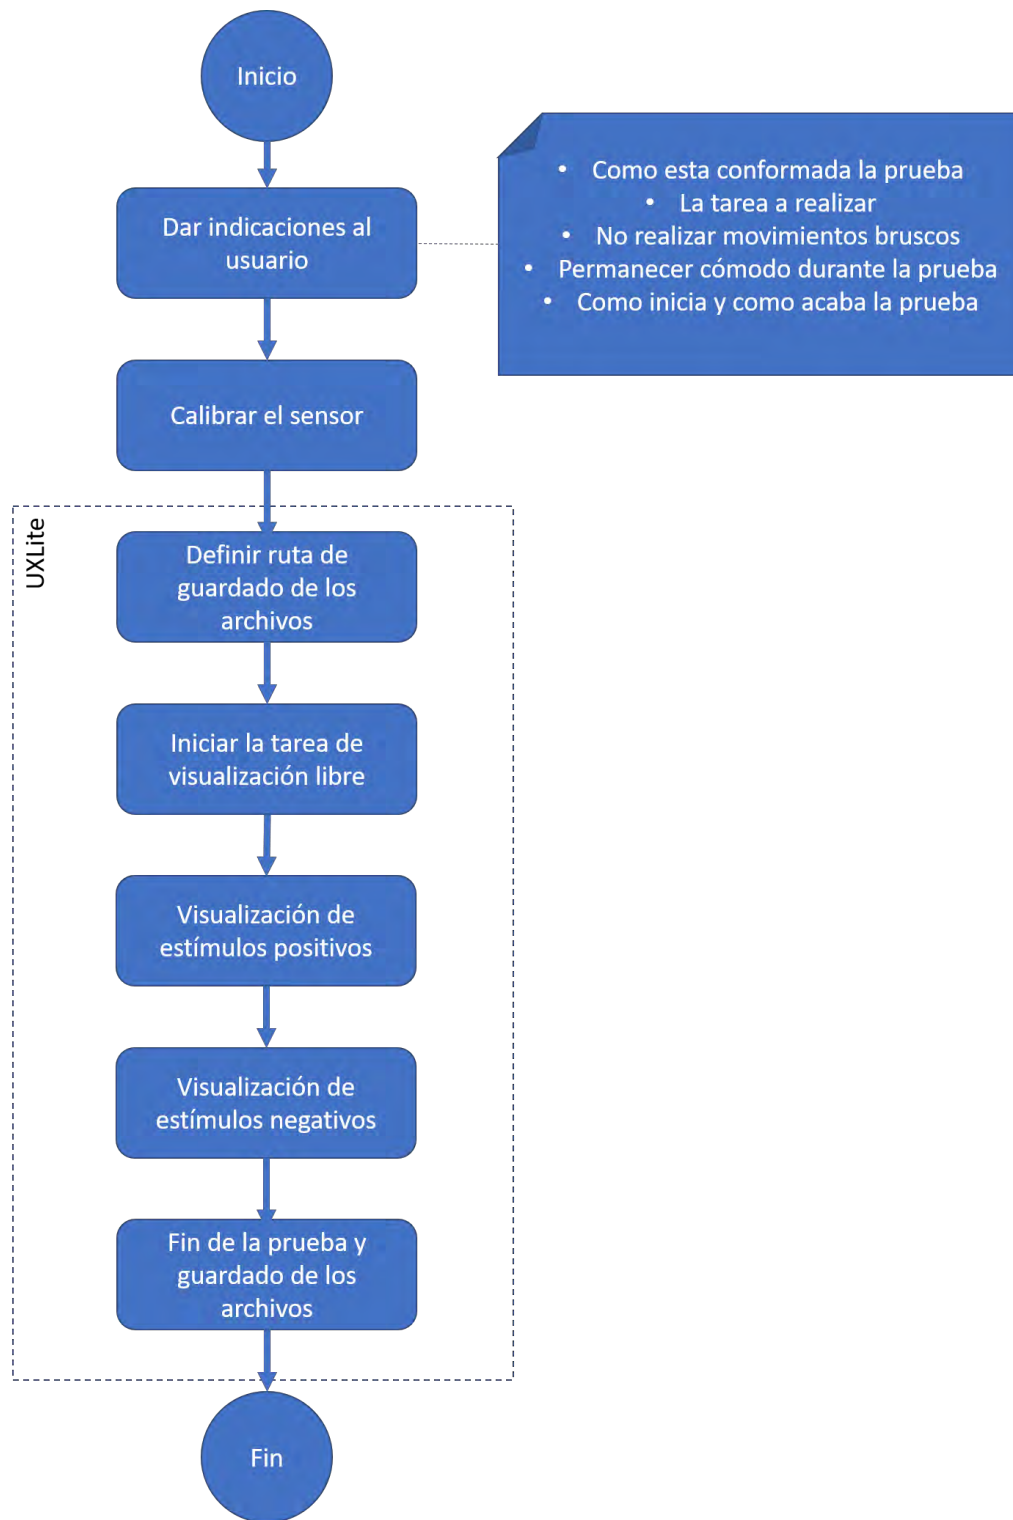


Figura 3.12: Diagrama de flujo del proceso de pruebas de seguimiento ocular

A continuación, se detallan los componentes de este proceso.

3.5.1 Cuestionario de inicio

Se debe registrar a cada participante una vez acepte el acuerdo de confidencialidad y uso de datos (si es menor de edad los padres de este también deben aceptarlo). El registro del participante puede hacerse mediante un instrumento de encuestas en línea como Google Forms o de manera manual al utilizar cuestionarios impresos, para ver un ejemplo del instrumento utilizado vea el **Anexo 6**. Cualquiera que sea el medio para que el participante conteste se debe contener:

- Ítems demográficos
- PHQ-2
- DASS-21
- Sintomatología depresiva

Posteriormente, las respuestas de los participantes deben ser almacenadas en formato CSV o Excel con las preguntas como encabezados. Luego del registro y una vez comprobados los criterios de inclusión/exclusión, se recomienda agendar una cita con el participante para la prueba de seguimiento ocular la cual tiene una duración aproximada de 30 y no requiere de procedimientos especiales o equipo por parte del usuario.

Se recomienda una espera de 1 o dos semanas después del registro para realizar la toma de datos oculares, aunque esto depende de la situación ya que la prueba puede realizarse enseguida.

3.5.2 Explicación de la prueba e indicaciones

Antes de comenzar la prueba, se proporcionan indicaciones claras al participante, para resolver cualquier duda y asegurar que comprenda el procedimiento. Las instrucciones, se dividen en las siguientes temáticas:

1. **Tarea de Visualización Libre:** Se explica que la prueba consiste en una tarea de visualización libre, en la cual el participante puede observar libremente las imágenes presentadas en la pantalla, sin estar obligado a fijar la mirada en características específicas.
2. **Posición del Participante:** Es fundamental que el participante mantenga una postura estable durante la prueba, esto evita movimientos bruscos que puedan afectar la calidad de los datos registrados. Se recomienda que el usuario adopte una posición cómoda dentro del rango óptimo del sensor GP3 para garantizar una captura precisa del seguimiento ocular.
3. **Calibración:** La calibración es un paso esencial en el que el participante observa una serie de puntos en la pantalla para garantizar una correcta captura de datos oculares. Durante la explicación de la calibración se le explica al participante que debe observar los puntos que aparecen en la pantalla sin mover la posición de su cabeza (ver Figura 3.13).




Figura 3.13: Pantalla de calibración con 5 puntos

Posteriormente se le pide que observe ciertos puntos de la pantalla para evaluar la calidad de la calibración como se ilustra en la Figura 3.14.




Figura 3.14: Pantalla de prueba de calibración

Este proceso debe repetirse tantas veces como sea necesario hasta alcanzar un nivel óptimo de precisión.

4. **Definición de la Ruta de Almacenamiento:** A través de la interfaz de UXLite, se selecciona la carpeta de destino donde se guardarán los archivos generados durante la prueba. Es importante mencionar al participante que sus datos serán guardados con fines de investigación. Se recomienda utilizar una ubicación en un disco de estado sólido (SSD) para evitar problemas de rendimiento y asegurar un almacenamiento eficiente.
5. **Explicación de la actividad:** Se le explica al participante en que consiste la prueba, la cual se trata de una actividad de visualización libre donde observara estímulos emocionales variados. Se hace hincapié que el participante no necesita reaccionar o interactuar de ninguna manera específica, solo debe observar las imágenes como guste.
6. **Inicio de la prueba:** Se le explica al participante que la actividad de visualización libre será iniciada por el evaluador mediante un botón en la interfaz gráfica de UXLite.
7. **Cierre de la prueba:** Finalmente, se le indica al usuario que al finalizar la prueba tendrá que completar unos cuestionarios.

3.5.3 Actividad de visualización libre

En el paradigma de tarea visual empleado en este estudio, los participantes realizaron una actividad de visualización libre, un enfoque dinámico que les permitió explorar y examinar los estímulos presentados en la pantalla sin restricciones impuestas. Al otorgar a los participantes total libertad para dirigir su atención de manera natural, se buscó obtener datos significativos sobre sus patrones de observación y respuesta emocional sin influencias externas.

Para garantizar la consistencia en la presentación de los estímulos, cada imagen fue mostrada de manera estandarizada. Antes de la aparición de cada estímulo, se estableció un intervalo fijo de anticipación, en el que la pantalla se tornaba oscura y se presentaban breves instrucciones. Posteriormente, las imágenes aparecían automáticamente en la pantalla con una duración de 30 segundos, lo que permitía a los participantes explorar el contenido de manera completa sin que la exposición prolongada generara habituación o disminución de la atención.

Durante la prueba, se registraron simultáneamente los datos de comportamiento visual con la API del sensor de seguimiento ocular. Estos datos fueron almacenados en un archivo de valores separados por comas (CSV), donde cada participante quedó identificado para su posterior análisis.

Al comenzar la prueba:

- La pantalla se torna oscura
- Se muestran instrucciones breves al participante
- Las imágenes aparecen automáticamente en intervalos de 20 segundos cada una

Este proceso se ilustra en la Figura 3.15.




Figura 3.15: Esquema del proceso de la prueba de inducción emocional

Al finalizar la secuencia de estímulos, se cierra la ventana de visualización y se completará la grabación de datos.

3.5.4 Cuestionario de finalización

En esta fase, se aplican nuevamente los instrumentos de evaluación PHQ-2, DASS y el cuestionario de sintomatología depresiva, con el objetivo de comparar las respuestas antes y después de la prueba. Además, se le presenta al usuario un cuestionario sobre su percepción de la prueba, donde se preguntan los siguientes ítems en una escala binaria de si o no:

1. ¿En algún momento sentiste que no estabas en una posición cómoda?
2. Las imágenes emocionales que observaste, ¿Te hicieron sentir mal?
3. ¿Tuviste problemas para mantener tu mirada en la pantalla?
4. Notaste algún efecto negativo en tu visión durante la prueba, por ejemplo, ¿Ojos cansados o secos?
5. ¿Consideras que alguna imagen es inapropiada?
6. ¿Las imágenes te hicieron pensar en algún recuerdo en particular?

Estas preguntas ayudaron a evaluar la efectividad de la inducción emocional y el estado del participante durante la prueba.

3.5.5 Actualización del repositorio de datos

Al concluir la prueba, UXLite procesa y guarda los resultados en los siguientes formatos:

1. **Archivo CSV:** Contiene los datos de seguimiento ocular:
 - a. **Fijaciones** (Tiempo, Número, Promedio, Desviación estándar)
 - b. **Pupila** (Dilatación de la pupila, Tiempo, Velocidad, Promedio, Desviación estándar)
 - c. **Parpadeos** (Tasa/Frecuencia, Número, Velocidad, Tiempo, Promedio, Desviación estándar)
 - d. **Sácadas** (Velocidad, Duración, Promedio, Desviación estándar)
 - e. **Puntos de visión**
2. **Archivo de video:** Registra la pantalla del usuario durante la prueba.

Los datos recopilados se almacenan y organizan en un repositorio de Google Drive el cual está identificado como “Depression EyeTracking DataSet” o DETDS, este sigue una estructura que incluye fecha, institución, grupo e id del participante. La Figura 3.17 muestra el procesamiento de datos crudos del sensor.




Figura 3.16: Esquema del proceso de la prueba de inducción emocional

El repositorio puede ser accedido mediante el enlace proporcionado en el Anexo 7. Posteriormente, durante el desarrollo del proyecto, estos datos son clasificados de acuerdo con los perfiles de los participantes y su sintomatología depresiva.

3.6 Ingeniería de características

A continuación, se detallan las estrategias de análisis de datos para el conjunto de datos recolectados en este estudio.

3.6.1 Extracción de características

Del conjunto de datos en crudo se deben extraer características que sean útiles para el estudio, algunas de las métricas oculares más comunes vinculadas a los procesos cognitivos atencionales y reportadas en la literatura incluyen fijaciones (por ejemplo, duración, conteo, número total, densidad espacial y número de puntos por área de interés), sacadas, parpadeos, dilatación pupilar, tiempo de permanencia, frecuencia de cambio de atención, mapas de calor y gráficos de trayectoria de la mirada. En este trabajo, se utilizó Python para procesar los

datos sin procesar del sensor y generar características relacionadas con el comportamiento ocular de los participantes.

La estrategia de extracción de características se basó en 30 archivos CSV generados para cada participante, donde cada archivo representaba un estímulo visual observado, referido aquí como un "evento". La Figura 3.17 representa el proceso de generación de eventos, donde mediante algoritmos de visión por computadora se definen las estampas de tiempo donde se muestran estímulos emocionales, posteriormente se usan estas estampas para extraer el subconjunto de datos del conjunto de datos principal. Para generar los eventos y obtener los datos se utilizó el programa generador de métricas PIE.




Figura 3.17: Esquema del proceso de definición y obtención de datos de los eventos de una prueba de inducción emocional

Cada evento contenía los registros en bruto capturados por el sensor de seguimiento ocular durante la tarea de visualización libre. Estos registros fueron procesados para derivar características adicionales, tales como:

- | | |
|--|--|
| <ul style="list-style-type: none"> • Número de fijaciones • Duración media de las fijaciones • Amplitud de las sacadas • Velocidad de las sacadas • Latencia de las sacadas | <ul style="list-style-type: none"> • Duración de las sacadas • Número de parpadeos • Duración media de los parpadeos • Frecuencia de parpadeo por minuto |
|--|--|

Además, para cada característica se calcularon estadísticas descriptivas, incluyendo medias, varianzas, desviaciones estándar, curtosis, valores mínimos y máximos. Este proceso se ve ilustrado en la Figura 3.18.




Figura 3.18: Esquema del proceso de procesamiento de características adicionales en función de datos crudos del seguimiento ocular

Estas características procesadas a partir de los datos crudos de seguimiento ocular, fueron procesadas por cada usuario y registradas en el repositorio, a continuación, se detalla cómo fueron generadas:

- **Fixation_Count:** El número de cuantas fijaciones fueron registradas durante la observación de los estímulos emocionales (5).

$$fix_count = \sum fix_events \quad (5)$$

Donde:

- fix_events = los eventos de fijación registrados

- **AVG_Fixation_Duration:** El promedio de la duración de las fijaciones registradas en segundos (6).

$$avg_fix_duration = \frac{\sum durations}{fix_count} \quad (6)$$

Donde:

- $durations$ = duración de un evento de fijación
- fix_count = conteo de las fijaciones registradas

- **AVG_Saccade_Amplitude:** El promedio de las amplitudes de las sacadas (8). La amplitud de las sacadas (7) en pixeles se calcula al utilizar la fórmula para la distancia euclidiana, donde se utiliza las coordenadas de las fijaciones de inicio y fin de la sacada para calcular la distancia de su amplitud.

$$saccade_amplitude = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (7)$$

Donde:

- x_1 = La posición x del primer punto de fijación

- x_2 = La posición x del segundo punto de fijación
- y_1 = La posición y del primer punto de fijación
- y_2 = La posición y del segundo punto de fijación

$$avg_saccade_amplitude = \frac{\sum amplitudes}{\frac{fix_count}{2} - 1} \quad (8)$$

Donde:

- $amplitudes$ = el valor de la amplitud de la sacada (8)
- fix_count = el conteo de las fijaciones registradas

AVG_Saccade_Velocity: El promedio de las velocidades de las sacadas (9). Para calcular la velocidad de una sacada

(10) se utiliza la distancia angular que es la medida del ángulo que separa dos fijaciones (en este caso se convierte en grados) y la duración en segundos de la sacada (diferencia entre las estampas de tiempo de las fijaciones que componen las sacadas). La fórmula para la distancia angular (11), requiere de "d"

- (12) que es la distancia entre los dos puntos de fijación que componen la sacada en píxeles y "D" (13) que es la distancia inter pupilar entre los ojos en píxeles (calculado a partir de datos del sensor de seguimiento ocular).

$$avg_saccade_vel = \frac{\sum saccade_vels}{\frac{fix_count}{2} - 1} \quad (9)$$

Donde:

- $saccade_vels$ = La velocidad de las sacadas registradas
- fix_count = el conteo de las fijaciones registradas

$$saccade_vel = \frac{angular_distance}{saccade_duration} \quad (10)$$

Donde:

- $angular_distance$ = (11)
- $saccade_duration$ = duración de una sacada

$$angular_distance = \arctan\left(\frac{\left(\frac{d}{2}\right)}{D}\right) * \frac{360}{(2*\pi)} \quad (11)$$

(12)

$$d = \sqrt{((x_2 - x_1)^2 + (y_2 - y_1)^2)}$$

Donde:

- x_1 = La posición x del primer punto de fijación
- x_2 = La posición x del segundo punto de fijación
- y_1 = La posición y del primer punto de fijación
- y_2 = La posición y del segundo punto de fijación

$$D = \sqrt{((x_2 - x_1)^2 + (y_2 - y_1)^2)} \quad (13)$$

Donde:

- x_1 = La posición x del primer punto de fijación
- x_2 = La posición x del segundo punto de fijación
- y_1 = La posición y del primer punto de fijación
- y_2 = La posición y del segundo punto de fijación
- **AVG_Saccade_Latency:** El promedio de la latencia entre cada sacada (16).

$$avg_saccade_latency = \frac{\sum latencies}{sacc_count} \quad (14)$$

Donde:

- latencies = el valor de las latencias registradas
- sacc_count = el número de sacadas registradas
- **AVG_Saccade_Duration:** El promedio de la duración de las sacadas (17).

$$avg_saccade_duration = \frac{\sum durations}{sacc_count} \quad (15)$$

Donde:

- durations = el valor de las duraciones de las sacadas registradas
- sacc_count = el número de sacadas registradas
- **Blink_Count:** El número de los parpadeos registrados (16).

$$blink_count = \sum blink_events \quad (16)$$

Donde:

- $blink_events$ = el número de eventos de parpadeo registrados
- **AVG_Blink_Duration:** El promedio de la duración de los parpadeos en segundos (17).

$$avg_blink_duration = \frac{\sum b_durations}{blink_count} \quad (17)$$

Donde:

- $b_durations$ = La duración en segundos de un evento de parpadeo
- $blink_count$ = (16)
- **AVG_Blink_Per_Minute:** Por cada minuto de tiempo en los datos existe un registro de bpm (blink per minute) (18). avg_bpm toma el conjunto de bpm registrados y obtiene el promedio (19).

$$bpm = \frac{\sum blink_events}{time_in_minutes} \quad (18)$$

Donde:

- $blink_events$ = el número de eventos de parpadeo registrados

$$avg_bpm = \frac{\sum bpms}{n_bpm_observations} \quad (19)$$

Donde:

- $bpms$ = (18)
- $n_bpm_observations$ = Número de observaciones de bpm

Para el conjunto de características X_Fixation_Data, Y_Fixation_Data, Left_Pupil_Size y Righth_Pupil_Size, se procesaron métricas de estadística descriptiva (Máximo, Mínimo, Promedio, Varianza, Desviación estándar, Sesgo y Curtosis) como se muestra a continuación:

- **Max:** El máximo de los valores registrados para la característica (20).

$$Max = \max(valores) \quad (20)$$

- **Min:** El mínimo de los valores registrados para la característica (21).

$$Min = \min(valores) \quad (21)$$

- **Mean:** El promedio de los valores registrados para la característica (22).

$$Mean = \frac{\sum valores}{n_valores} \quad (22)$$

- **Var:** La varianza de los valores registrados para la característica (23).

$$Var = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1} \quad (23)$$

- **SD:** La desviación estándar de los valores registrados para la característica (24).

$$SD = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}} \quad (24)$$

- **Bias:** El sesgo de los valores registrados para la característica (25).

$$Bias = \frac{n(n-1)}{(n-2)(n-3)} \times \frac{\sum_{i=1}^n (\frac{X_i - \bar{X}}{s})^3}{\left[\sum_{i=1}^n (\frac{X_i - \bar{X}}{s})^2 \right]^{3/2}} \quad (25)$$

- **Kurt:** La curtosis de los valores registrados para la característica (29).

$$Kurt = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \left(\frac{X_i - \bar{X}}{s} \right)^4 - \frac{3(n-1)^2}{(n-2)(n-3)} \quad (26)$$

Además, se agregan variables categóricas obtenidas de los formularios:

- Sex: Variable categórica, 0 indica sexo femenino mientras que 1 indica sexo masculino
- Had_Depression, Had_Anxiety y Had_Stress: Variable categórica, 0 indica la falta de un diagnóstico mientras que 1 indica la presencia de un diagnóstico previo.
- Had_Calming_Meds: Variable categórica, 0 indica la falta de toma de medicamentos calmantes mientras que 1 indica la de toma de medicamentos calmantes.
- Had_Energizing_Meds: Variable categórica, 0 indica la falta de toma de energizantes mientras que 1 indica la de toma de energizantes.

Finalmente, se describen las características obtenidas a partir del instrumento DASS-21 y la definición de la clase para los experimentos con algoritmos de ML supervisados, cabe señalar que, aunque se realizó una clasificación multiclase, finalmente se utilizó la clasificación binaria de con y sin depresión:

- **Depression:** El puntaje de los ítems de depresión del cuestionario DASS-21 (27).

$$Depression = \sum dass21_depression_items \quad (27)$$

- **Anxiety:** El puntaje de los ítems de ansiedad del cuestionario DASS-21 (28).

$$Anxiety = \sum dass21_anxiety_items \quad (28)$$

- **Stress:** El puntaje de los ítems de estrés del cuestionario DASS-21 (29).

$$Stress = \sum dass21_stress_items \quad (29)$$

- **Class:** La clase a la que pertenece este individuo (30) (34). En función de los puntos de corte del instrumento Dass-21: 1) 5-6 depresión leve, 2) 7-10 depresión moderada, 3) 11-13 depresión severa y 4) 14 o más, depresión extremadamente severa.

$$without_depression = \{x \mid x \leq 6\} \quad (30)$$

$$with_depression = \{x \mid x \geq 7\} \quad (31)$$

3.6.2 Análisis y preprocesamiento de los datos

Tras obtener los archivos de datos con las características extraídas, el lenguaje R fue utilizado para llevar a cabo el análisis de datos, gestionar valores atípicos y preparar la información para su uso en algoritmos de ML. En este estudio, se decidió retener los valores atípicos, ya que podrían proporcionar información relevante sobre el comportamiento de los individuos con depresión.

Manejo de valores atípicos

El método a emplear para detectar valores atípicos en los vectores de datos consistió en medir la desviación de cada característica numérica con respecto a la mediana, expresada en términos de desviaciones estándar. Al calcular esta distancia (32), se identifican valores que se alejan del centro de la distribución, lo que permitió señalar posibles valores atípicos.

$$distancia = \frac{valor - mediana}{desviación_estándar} \quad (32)$$

Se utilizó la mediana en lugar de la media, ya que es más robusta ante valores extremos, y la desviación estándar como una medida consistente para cuantificar diferencias con respecto a los valores típicos.

Una vez identificados los valores atípicos, se aplicó una función exponencial inversa para asignar pesos a los datos en función de esta distancia (33). Específicamente, para cada punto de datos x_i , se calculó su distancia a la mediana d_i (en términos de desviaciones estándar) y se asigna un peso w_i mediante la siguiente ecuación:

$$w_i = e^{-\alpha d_i} \quad (33)$$

Donde :

α es un parámetro de ajuste que controla la rapidez con la que disminuye el peso a medida que aumenta la distancia. Posteriormente, se multiplicaron los valores originales x_i por sus pesos correspondientes w_i para obtener valores ponderados (34):

$$x_i^{weighted} = w_i \cdot x_i \quad (34)$$

Este proceso permite reducir la influencia de los valores atípicos, al tiempo que preservaba la contribución de los puntos de datos cercanos a la mediana.

Limpieza de los datos

En todos los conjuntos de datos se utilizó la función “md.pattern” de la librería “mice” y la función “vis_miss” de la librería “visdat”. Ambas funciones buscan dentro de los datos y revelan si existen valores perdidos los cuales pueden afectar cálculos de estadísticos descriptivos y correlaciones. El resultado de ambas funciones es un reporte donde se muestra, si existe algún dato perdido, en cuyo caso se tendrá que rellenar ese dato al usar algunas técnicas que no alteren la estructura de los datos.

Normalización de los datos

El siguiente paso fue normalizar los datos para escalar las características numéricas en un rango de 0 a 1, esto para evitar que aquellas con valores numéricos más grandes influyeran desproporcionadamente en el modelo. La normalización se realiza con la siguiente ecuación (35):

$$x'_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (35)$$

Donde :

x_{min} y x_{max} representan los valores mínimo y máximo de cada característica del conjunto de datos, respectivamente.

Aumento de datos

En el caso del desequilibrio de clases entre sujetos con depresión y sujetos de control, se aplicaron técnicas de aumento de datos mediante el algoritmo Synthetic Minority Over-sampling Technique (SMOTE) con el paquete DMwR en R (Torgo 2010). Como resultado, se obtuvo una muestra balanceada de sujetos con depresión y sujetos de control.

Estructura del vector de datos

Finalmente, la estructura del vector de datos se compuso de 46 características por cada estímulo/imagen vista por los participantes (30 imágenes x 139 participantes). Este conjunto incluye:

1. 37 características numéricas relacionadas con métricas de seguimiento ocular, tales como:

(a) Número de fijaciones	(f) Duración de sacadas
(b) Duración de fijaciones	(g) Número de parpadeo
(c) Amplitud de sacadas	(h) Duración de parpadeos
(d) Velocidad de sacadas	(i) Frecuencia de parpadeo
(e) Latencia de sacadas	

Adicionalmente, para las siguientes características:

(j) Datos de fijación en X	(l) Tamaño de la pupila izquierda
(k) Datos de fijación en Y	(m) Tamaño de la pupila derecha

Se calcularon estadísticas como máximo, mínimo, media, varianza, desviación estándar, asimetría (skewness) y curtosis.

2. 9 características categóricas derivadas de herramientas de evaluación:

(n) Sexo	(s) Puntuación de estrés
(o) Puntuación de depresión	(t) Nivel de estrés
(p) Nivel de depresión	(u) Uso de medicación
(q) Puntuación de ansiedad	(v) Consumo de bebidas energéticas el día de la observación
(r) Nivel de ansiedad	

Este conjunto de datos permitirá realizar análisis detallados sobre la relación entre métricas de seguimiento ocular y estados cognitivos en individuos con y sin síntomas de depresión.

3.6.3 Selección de características

Los algoritmos de ML supervisado dependen de la identificación de diferencias entre dos o más clases. Sin embargo, cuando los datos de ambas clases no presentan diferencias significativas, el rendimiento de estos algoritmos puede verse considerablemente afectado. Por esta razón, se decidió realizar un proceso de selección de características, enfocándose en aquellas que mostraran las mayores diferencias entre el grupo con depresión y el grupo de control.

Para obtener diferencias entre las características del conjunto de datos, se aplican pruebas U de Mann-Whitney sobre los conjuntos originales de cada estímulo visual (sin muestras sintéticas) para analizar las diferencias entre ambos grupos.

A partir de los resultados, se seleccionan las métricas de seguimiento ocular que muestran diferencias significativas, $p < 0.05$, para construir un conjunto de datos específico que representara el comportamiento de los participantes.

Este conjunto de datos se utilizará para entrenar algoritmos de ML supervisado, donde se va a utilizar una estrategia de clasificación binaria, donde:

La clase 0 representa el grupo de control, es decir, participantes con una puntuación no depresiva en el DASS-21. Y la clase 1 representa el grupo con depresión, es decir, participantes con una puntuación depresiva.

3.7 Algoritmos de aprendizaje automático

Para esta fase se recopilará un conjunto de algoritmos de aprendizaje máquina supervisados, estos algoritmos serán entrenados y evaluados, con diferentes métricas, con el objetivo de seleccionar aquel con mejores resultados para las características oculares en la depresión.

En este estudio, se seleccionaron SVM, RF, una implementación de una red neuronal MLP y GB como los algoritmos principales debido a su eficacia comprobada en trabajos relacionados (en conjunto representan más del 50% de los algoritmos utilizados en el estado del arte), especialmente en problemas con características numéricas.

- **SVM** fue elegido porque ha demostrado un buen desempeño en espacios de alta dimensión y ha mostrado resultados prometedores en estudios similares.
- **RF** se seleccionó por su robustez y capacidad para reducir el sobreajuste, ya que promedia múltiples árboles de decisión, lo que lo hace adecuado tanto para clasificación como para regresión.
- **MLP** se incluyó debido a su capacidad para capturar patrones complejos y no lineales, esto proporciona un enfoque basado en redes neuronales para el modelado predictivo.
- **GB** se eligió por su alta precisión y su naturaleza secuencial, que le permite corregir errores iterativamente, lo que lo hace especialmente efectivo en datos estructurados.

La combinación de estos algoritmos permite una evaluación y comparación exhaustiva en términos de precisión, generalización e interpretabilidad.

Optimización de Hiperparámetros

Cada algoritmo de clasificación opera de manera diferente, por lo que es necesario explorar sus hiperparámetros óptimos. Para ello, se utilizará GridSearchCV de la librería Scikit-learn en Python, el cual evalúa exhaustivamente todas las combinaciones posibles de valores de hiperparámetros dentro de un espacio predefinido (grid de hiperparámetros).

Además, el conjunto de datos se dividirá en conjuntos de entrenamiento y prueba mediante la función `train_test_split` de Scikit-learn, donde se asignó 80% de los datos para el entrenamiento y 20% para la prueba. Se utiliza muestreo estratificado para mantener la misma proporción de cada clase (depresión y control) en ambos conjuntos.

Para garantizar una búsqueda exhaustiva de los mejores hiperparámetros, se reservará una parte del conjunto de entrenamiento específicamente para este propósito. Dado que el tamaño del conjunto de datos puede ser relativamente pequeño, se aplica validación cruzada *k-fold* en el conjunto de entrenamiento para evaluar diferentes configuraciones de hiperparámetros.

Tras identificar los hiperparámetros óptimos mediante la validación cruzada, el modelo final será entrenado con el conjunto de entrenamiento completo con los mejores valores de hiperparámetros. Finalmente, este modelo será evaluado en el conjunto de prueba para medir su rendimiento.

Evaluación de rendimiento de los algoritmos

Además, se validará la precisión del algoritmo de detección de depresión y varias métricas para los algoritmos de aprendizaje:

1. Matriz de confusión
2. Precisión
3. Sensibilidad
4. Especificidad
5. Coeficiente de correlación de Matthews
6. Puntuación F1

Seleccionar el mejor algoritmo

Se entrenarán y ejecutarán los algoritmos de selección de características con sus mejores hiperparámetros, este proceso se ilustra en la Figura 2.14. Los algoritmos y sus resultados serán comparados para seleccionar el modelo con los mejores resultados de predicción. Durante la etapa de entrenamiento el modelo aprenderá las diferencias entre los datos arrojados por un paciente con depresión y otro sin el trastorno, esto le permitirá al modelo comparar una nueva entrada de información y clasificar al paciente en un grupo u otro cuando se desee apoyar el diagnóstico de depresión.

Cuando se desee apoyar el diagnóstico de depresión, un psiquiatra puede realizar una prueba de inducción emocional al paciente y utilizar la herramienta clasificadora para determinar si su comportamiento ocular corresponde a una persona con depresión.

3.7 Herramienta de apoyo al diagnóstico

El objetivo principal de este proyecto es desarrollar una herramienta capaz de detectar la depresión en un contexto de aplicación real. Esta herramienta funcionará en conjunto con un sensor de seguimiento ocular y un proceso de inducción emocional rápido, basado en estímulos provenientes del repositorio IAPS.

Se han identificado tres posibles escenarios de aplicación:

- **Medicina general (primera línea de consulta):** Para la detección temprana de niveles de depresión en pacientes que acuden a consulta médica.
- **Escuelas y empresas:** Como parte de un programa de salud mental, el cual permitiría evaluar el bienestar emocional y facilitar la detección y tratamiento oportuno de casos. Además, podría integrarse en sistemas inteligentes de monitoreo de la salud, por ejemplo, para adultos mayores.
- **Centros de salud mental:** Para apoyar la evaluación del nivel de depresión en nuevos pacientes y monitorear la evolución de los síntomas a lo largo del tratamiento.

Desarrollo del Software

El proceso de desarrollo seguirá un modelo en cascada, estructurado en las etapas de Inicio, Análisis, Diseño, Implementación y Pruebas, donde se asegura que cada fase esté documentada de manera detallada.

Uno de los objetivos específicos del sistema es garantizar una interfaz intuitiva y accesible, que permita su uso sin necesidad de conocimientos técnicos avanzados. Los requerimientos de la aplicación, incluido el lenguaje de programación, serán definidos durante la fase de evaluación del proyecto.

Inicialmente, la herramienta contará con un conjunto específico de estímulos emocionales para la inducción y predicción de la depresión. Sin embargo, con el tiempo y en futuros desarrollos, se podrán agregar nuevos estímulos al modelo de clasificación para mejorar su precisión y aplicabilidad.

3.8 Resumen de la metodología de solución

La metodología de solución se basa en un enfoque de aprendizaje supervisado para la detección de depresión a través de seguimiento ocular. Se inicia con la revisión del estado del arte y la colaboración con el INSP para definir la población de estudio y establecer protocolos éticos. La recolección de datos se realiza mediante estímulos emocionales, seguimiento ocular con hardware especializado, y cuestionarios de referencia clínica. Posteriormente, se lleva a cabo la ingeniería de características, donde se extraen y procesan métricas visuales relevantes, incluyendo fijaciones, movimientos sacádicos y pupilometría. Se emplean técnicas de selección de características y normalización de datos para optimizar el conjunto de entrenamiento. Para el análisis, se implementan y comparan algoritmos de aprendizaje supervisado como SVM, Random Forest, MLP y Gradient Boosting, donde se ajustan hiperparámetros con validación cruzada. Finalmente, se desarrolla una herramienta de software que integra el modelo de clasificación y permite su aplicación en entornos médicos y de salud mental. La Figura 3.19 ilustra la metodología de solución gráficamente.




Figura 3.19: Metodología de solución propuesta

Capítulo 4. Resultados

4.1 Resultados de recolección de datos

El periodo de recolección de datos fue del 21 de abril del 2023 al 12 de mayo de 2023 y del 19 de mayo del 2023 al 7 de junio de 2023, se trabajó en colaboración con las preparatorias federales por cooperación (PREFECO's) Andrés Quintana Roo (AQR) y Quetzalcóatl (QZTL), ubicadas en Cuernavaca y Tepoztlán, Morelos, respectivamente. En ambas instituciones, previo acuerdo con directivos, padres de familia y una muestra aleatoria de alumnos, se llevó a cabo la grabación de datos de comportamiento ocular mientras los estudiantes eran sometidos a un proceso de inducción emocional con las herramientas UXLite y el sensor de seguimiento ocular Gazepoint GP3.

Debido a diferencias en las condiciones de los espacios de prueba, la cantidad de pruebas realizadas varió entre las instituciones: en AQR se recopilaron datos de 65 participantes, mientras que en QZTL se registraron 94. Adicionalmente, el 20 de abril de 2023 se realizaron pruebas en la Universidad Tecnológica Emiliano Zapata del Estado de Morelos (UTEZ) con 13 participantes, donde se siguió el mismo procedimiento y contando con el consentimiento de las autoridades y los estudiantes, en este caso, mayores de edad. La Figura 4.1 muestra algunas evidencias de la toma de muestras en las escuelas.



Figura 4.1: Evidencias de toma de muestras

Como resultado de este proceso, se conformó la primera versión del repositorio Depression Eye-Tracking DataSet (DETDS), el cual contiene información sobre 172 participantes y su respuesta ocular ante 30 estímulos emocionales (15 positivos y 15 negativos), cada uno presentado durante 30 segundos.

Cada conjunto de datos dentro del repositorio está identificado mediante un folio anónimo, sin información personal del participante. Dentro de cada directorio se encuentran:

- Datos de seguimiento ocular en crudo (raw data).
- Video de la pantalla con los estímulos visualizados por el participante.
- Archivo de fotogramas por segundo (FPS), utilizado para evaluar el rendimiento de la captura de video.

Además, el repositorio DETDA incluye un archivo Excel (.xls) con información detallada de los 172 participantes, así como sus resultados en los instrumentos de evaluación de salud mental. Para el análisis de este estudio, solo se consideró la variable depresión y se clasificó a los participantes en los siguientes niveles:

- **Sin depresión** (n=72)
- **Depresión leve** (n=27)
- **Depresión moderada** (n=28)
- **Depresión severa** (n=25)
- **Depresión extremadamente severa** (n=20)

En los casos donde los alumnos obtuvieron una puntuación indicativa de depresión moderada o mayor, la institución educativa fue notificada y el estudiante fue canalizado con el psicólogo escolar para recibir el seguimiento y tratamiento adecuado.

4.1.1 Resumen de la muestra

El estudio incluyó a 172 participantes jóvenes con edades entre 15 y 21 años ($\bar{x} = 16.53$), seleccionados aleatoriamente. A continuación, la Tabla 4.1, muestra los resultados de las puntuaciones del instrumento DASS-21 en la población completa.

Tabla 4.1: Resultados del instrumento DASS-21 sobre la población de estudio

		n=172	100	%
Depresión	Sin Depresión	72	41,86	%
	Depresión leve	27	15,70	%
	Depresión moderada	28	16,28	%
	Depresión severa	25	14,53	%
	Depresión extremadamente severa	20	11,63	%
Ansiedad	Sin ansiedad	57	33,14	%
	Ansiedad leve	4	2,33	%
	Ansiedad moderada	31	18,02	%
	Ansiedad severa	13	7,56	%
	Ansiedad extremadamente severa	44	25,58	%
Estrés	Sin estrés	61	35,47	%
	Estrés leve	23	13,37	%
	Estrés moderado	26	15,12	%
	Estrés severo	29	16,86	%
	Estrés extremadamente severo	10	5,81	%

La Tabla 4.2 muestra la misma información, pero clasificada entre los hombre y mujeres.

Tabla 4.2: Resultados del instrumento DASS-21 sobre la población de estudio filtrando por sexo

		Hombres			Mujeres		
		n=89	51,74	%	n=83	48,26	%
Depresión	Sin Depresión	41	23,84	%	31	18,02	%
	Depresión leve	15	8,72	%	12	6,98	%
	Depresión moderada	15	8,72	%	13	7,56	%
	Depresión severa	12	6,98	%	13	7,56	%
	Depresión extremadamente severa	6	3,49	%	14	8,14	%
Ansiedad	Sin ansiedad	32	18,60	%	34	19,77	%
	Ansiedad leve	3	1,74	%	1	0,58	%
	Ansiedad moderada	20	11,63	%	16	9,30	%
	Ansiedad severa	6	3,49	%	9	5,23	%
	Ansiedad extremadamente severa	28	16,28	%	23	13,37	%
Estrés	Sin estrés	36	20,93	%	34	19,77	%
	Estrés leve	11	6,40	%	14	8,14	%
	Estrés moderado	19	11,05	%	12	6,98	%
	Estrés severo	15	8,72	%	21	12,21	%
	Estrés extremadamente severo	8	4,65	%	2	1,16	%

Tras excluir a 33 participantes según los siguientes criterios de inclusión/exclusión:

1. Tener entre 15 y 21 años
2. no tomar medicación en el momento de la prueba
3. no presentar problemas relacionados con la vista
4. haber dado su consentimiento para participar en el estudio

El tamaño de la muestra redujo a 139 jóvenes, quienes se clasificaron en dos grupos: el grupo de control saludable ($n=82$) y el grupo de depresión ($n=57$), según los resultados obtenidos de la prueba DASS-21 para depresión.

Este procedimiento de selección garantizó que los participantes fueran apropiados para el estudio, lo que permitió una comparación adecuada entre ambos grupos en relación con los síntomas depresivos.

4.2 Análisis y procesamiento de datos positivos y negativos

Después de registrar las métricas de seguimiento ocular, los datos fueron procesados con la metodología descrita en la sección 3.5.5 del capítulo 3. Este proceso generó distintos conjuntos de datos correspondientes a toda la prueba de inducción emocional, así como archivos CSV individuales denominados eventos. Cada archivo de evento representa un subconjunto de datos oculares capturados durante la observación de un estímulo específico. Como resultado, se obtuvieron 30 archivos de evento por usuario, correspondientes a los 30 estímulos presentados (15 de valencia negativa y 15 de valencia positiva).

Para algunos análisis de datos, se combinaron los archivos de eventos según la valencia emocional del estímulo presentado (negativa o positiva). De esta manera, se logró generalizar el comportamiento de los participantes y generar dos archivos de datos consolidados, lo cual permitió un análisis más amplio y representativo.

Estos archivos, denominados a partir de este punto como `df_positivo.csv` y `df_negativo.csv`, contienen la información agrupada según la valencia de los estímulos. La Figura 4.2 ilustra

el proceso de generación de estos archivos, ilustra la integración de los eventos individuales en conjuntos de datos estructurados para su posterior análisis.




Figura 4.2: Esquema de generación de archivos df_positivo y df_negativo

A continuación, se describen los procesos realizados sobre los datos y el análisis de los mismos.

4.2.1 Limpieza de los datos de datos positivos y negativos

Para el análisis de los datos, se utilizó el lenguaje de programación R. En particular, se emplearon las funciones `md.pattern` de la librería `mice` y `vis_miss` de la librería `visdat`. Ambas funciones permiten identificar valores perdidos dentro de los vectores de datos, los cuales podrían afectar el cálculo de estadísticas descriptivas y correlaciones.

Los resultados obtenidos indicaron que los conjuntos de datos estaban completos, sin valores faltantes.

4.2.2 Análisis y manejo de valores atípicos de datos positivos y negativos

Como se observa solo algunas de las características siguen una distribución normal, por lo que se procedió a hacer un análisis de valores atípicos con boxplots (diagrama de cajas/bigotes) los cuales muestran gráficamente valores que se salen dentro de la normalidad de los datos (outliers) (ver Figura 4.3).




Figura 4.3: Boxplot para el conjunto de datos

Como se puede observar, existen datos atípicos en las siguientes características:

- AVG_Sacade_Amplitude
- AVG_Saccade_Velocity
- Blink_Count
- AVG_Blink_Duration
- AVG_Blink_Per_Minute
- Left_Pupil_Size_Min
- Left_Pupil_Size_Max
- Left_Pupil_Size_Mean

Un análisis más detallado de que datos fueron atípicos se puede observar en la Tabla 4.3.

Tabla 4.3: Observaciones de datos atípicos en ambos conjuntos de datos

	Característica	Media	Desviación estándar	Sujeto	Valor	Distancia promedio*
df_positivo	AVG_Sacade_Amplitude	242.116	86.27271	71	545.2	3.51
				77	499.0	2.98
				99	525.38	3.28
	AVG_Saccade_Velocity	1736.54	908.8369	71	4881.5	3.46
				79	4313.5	2.84
				86	4055.0	2.55
				127	4705.3	3.27
	Blink_Count	0.91282	0.5705356	44	2.73	3.19
				71	2.60	2.96
				128	2.57	2.91
	AVG_Blink_Duration	0.19226	0.1616809	36	0.57	2.32
				44	0.67	2.94
				76	0.65	2.80
				96	0.58	2.40
				99	0.75	3.43
				114	1.00	5.01
				128	0.61	2.61
	AVG_Blink_Per_Minute	40.3822	151.0529	20	559.9	3.44
				23	1523.	9.82
				44	59.51	0.13
				48	800.6	5.03
				63	58.76	0.12
	Left_Pupil_Size_Max	23.1084	4.373704	128	56.33	0.11
				106	9.89	-3.02
				109	24.71	3.23
				125	24.30	3.10
	Left_Pupil_Size_Min	14.7632	3.080517	106	8.75	-2.82
				107	32.69	3.06
	Left_Pupil_Size_Mean	20.2246	4.073402	26	0.43	3.97
				76	681.63	4.87
df_negativo	AVG_Fixation_Duration	0.21640	0.0534295	44	2.86	3.30
				121	2.47	2.63
	AVG_Saccade_Amplitude	261.156	86.32375	23	0.61	2.75
				44	0.72	3.50
				76	0.84	4.28
				99	0.54	2.29
				114	0.53	2.26
	Blink_Count	0.93604	0.5821698	23	84.52	4.04
				24	108.81	5.59
				31	52.39	1.99
				44	58.98	2.41
	AVG_Blink_Duration	0.19126	0.1522374	106	9.88	-3.30
				107	34.85	2.71
				92	22.96	2.60
	AVG_Blink_Per_Minute	21.1529	15.67829	125	23.07	2.64
				106	8.64	-3.01
	Left_Pupil_Size_Max	23.5785	4.151801	107	33.09	3.15
				106	10.14	-2.98
	Left_Pupil_Size_Min	14.9958	3.057272			
	Left_Pupil_Size_Mean	20.5796	3.970835			
	Right_Pupil_Size_Max	23.4353	4.457935			

Nota: * Distancia al promedio en términos de desviaciones estándar.

Como se puede observar en la tabla y en los boxplots, la distancia al promedio en algunos casos es evidente mientras que en otros la distancia es mínima, por lo tanto, se decidió crear diferentes umbrales para considerar atípicos legítimos y atípicos por error (ver Tabla 4.4).

Tabla 4.4: Umbrales de datos atípicos en ambos conjuntos de datos

Característica	Umbral para considerar el dato como atípico (Distancia al promedio en términos de desviaciones estándar)
AVG_Fixation_Duration	3
AVG_Saccade_Amplitude	3
AVG_Saccade_Velocity	2.5
Blink_Count	3
AVG_Blink_Duration	2
AVG_Blink_Per_Minute	1
Left_Pupil_Size_Max	3
Left_Pupil_Size_Min	3
Left_Pupil_Size_Mean	3
Right_Pupil_Size_Max	3

Concluyendo este análisis, se descartarán los datos de los sujetos: 20, 23, 36, 44, 48, 71, 76, 79, 86, 96, 99, 106, 107, 109, 114, 125, 127 del conjunto df_positivo y 23, 24, 26, 31, 44, 76, 92, 99, 106, 107, 114, 121, 125 del conjunto df_negativo ya que estos superan el umbral.

Una vez filtrados los datos se actualizan los conjuntos: df_positivo (121 filas x 18 columnas) y df_negativo (125 filas x 18 columnas). Estos conjuntos de datos se encuentran libre de valores nulos, faltantes y atípicos, además cuentan con la siguiente distribución de clases (ver Tabla 4.5).

Tabla 4.5: Distribución de las clases en los datos

	Clase	n binaria	n multiclase
df_positivo	Sin depresión	52	52
	Depresión leve	69	20
	Depresión moderada		21
	Depresión severa		16
	Depresión extremadamente severa		12
df_negativo	Sin depresión	53	53
	Depresión leve	72	21
	Depresión moderada		22
	Depresión severa		17
	Depresión extremadamente severa		12

4.2.3 Análisis de normalidad de datos positivos y negativos

El análisis de normalidad de los datos se realizó inicialmente de manera univariante, con el objetivo de seleccionar las técnicas de análisis más adecuadas (prueba t y F para datos normales o prueba U de Mann-Whitney en caso de distribución no normal).

Para ello, se aplicó la prueba de Shapiro-Wilk a cada variable en los conjuntos df_positivo y df_negativo. Adicionalmente, se empleó la librería MVN de R, la cual ofrece diversas pruebas de análisis multivariado, algunas de las cuales también permiten evaluar la normalidad de cada variable de manera individual.

Los resultados de estas pruebas se presentan en la Tabla 4.6, donde se detalla el comportamiento de cada variable en términos de normalidad, esto para facilitar la selección de los métodos estadísticos más apropiados para el análisis posterior.

Tabla 4.6: Resultados de pruebas de normalidad univariante

	Variable	Shapiro-Wilk		Royston (Anderson-Darling)	
		Valor p	¿Es normal?	Valor p	¿Es normal?
df_positivo	Fixation_Count	0.01473	NO	0.0319	NO
	AVG_Fixation_Duration	0.0005297	NO	0.0045	NO
	AVG_Saccade_Amplitude	0.006917	NO	0.006	NO
	AVG_Saccade_Velocity	9.466e-05	NO	0.0536	SI
	Blink_Count	2.158e-05	NO	1e-04	NO
	AVG_Blink_Duration	4.754e-11	NO	<0.001	NO
	AVG_Blink_Per_Minute	2.2e-16	NO	1e-04	NO
	Left_Pupil_Size_Max	0.07391	SI	0.026	NO
	Left_Pupil_Size_Min	0.1623	SI	0.7775	SI
	Left_Pupil_Size_Mean	0.167	SI	0.0328	NO
	Right_Pupil_Size_Max	0.02693	NO	0.0135	NO
	Right_Pupil_Size_Min	0.05982	SI	0.0437	NO
	Right_Pupil_Size_Mean	0.02446	NO	0.0064	NO
	Depression	1.693e-06	NO	<0.001	NO
	Anxiety	9.352e-06	NO	1e-04	NO
	Stress	0.05095	SI	0.0766	SI
df_negativo	Fixation_Count	0.01508	NO	0.0176	NO
	AVG_Fixation_Duration	0.009684	NO	0.0334	NO
	AVG_Saccade_Amplitude	0.01854	NO	0.0462	NO
	AVG_Saccade_Velocity	0.02768	NO	0.0921	SI
	Blink_Count	1.548e-05	NO	<0.001	NO
	AVG_Blink_Duration	4.935e-07	NO	<0.001	NO
	AVG_Blink_Per_Minute	1.576e-05	NO	<0.001	NO
	Left_Pupil_Size_Max	0.02559	NO	0.013	NO
	Left_Pupil_Size_Min	0.4189	SI	0.5173	SI
	Left_Pupil_Size_Mean	0.03211	NO	0.0106	NO
	Right_Pupil_Size_Max	0.06922	SI	0.0304	NO
	Right_Pupil_Size_Min	0.04558	NO	0.0412	NO
	Right_Pupil_Size_Mean	0.03144	NO	0.0063	NO
	Depression	3.453e-06	NO	<0.001	NO
	Anxiety	8.21e-06	NO	<0.001	NO
	Stress	0.0425	NO	0.0554	SI

Además, se observaron los estadísticos descriptivos de los datos (ver Tabla 4.7).

Tabla 4.7: Estadísticos descriptivos de los datos

	Variable	$\bar{x}$	σ	$\tilde{x}$	min	max	γ_1	γ_2
df_positivo	Fixation_Count	9.22	1.97	9.07	5.00	13.13	0.04	-0.95
	AVG_Fixation_Duration	0.22	0.05	0.22	0.14	0.35	0.58	-0.25
	AVG_Saccade_Amplitude	229.90	74.52	212.33	72.87	499.07	0.70	0.59
	AVG_Saccade_Velocity	1663.86	768.60	1626.61	216.93	3978.00	0.54	0.09
	Blink_Count	0.86	0.52	0.73	0.00	2.57	0.85	0.44
	AVG_Blink_Duration	0.17	0.12	0.14	0.00	0.61	1.18	1.60
	AVG_Blink_Per_Minute	18.61	11.65	15.79	0.00	58.76	1.00	0.97
	Left_Pupil_Size_Max	23.12	3.99	22.79	12.34	31.52	0.24	-0.54
	Left_Pupil_Size_Min	14.88	2.66	14.76	8.74	22.75	0.20	-0.26
	Left_Pupil_Size_Mean	20.29	3.65	19.71	10.83	28.27	0.19	-0.68
	Right_Pupil_Size_Max	23.17	4.34	23.12	12.45	34.47	0.24	-0.66
	Right_Pupil_Size_Min	14.86	2.94	14.54	9.28	23.02	0.32	-0.57
	Right_Pupil_Size_Mean	20.31	3.88	20.24	10.85	31.17	0.21	-0.68
	Depression	6.40	5.00	5.00	0.00	21.00	0.76	-0.29
	Anxiety	6.99	5.17	7.00	0.00	19.00	0.43	-0.89
	Stress	9.36	4.67	9.00	0.00	20.00	0.01	-0.80
df_negativo	Fixation_Count	9.49	2.12	9.67	5.73	14.67	0.08	-0.77
	AVG_Fixation_Duration	0.21	0.05	0.21	0.13	0.34	0.43	-0.38
	AVG_Saccade_Amplitude	253.50	77.19	247.03	93.13	481.52	0.55	0.03
	AVG_Saccade_Velocity	1863.17	892.50	1862.37	208.88	4207.29	0.40	-0.42
	Blink_Count	0.87	0.51	0.73	0.13	2.31	0.83	0.08
	AVG_Blink_Duration	0.17	0.12	0.14	0.01	0.52	1.02	0.51
	AVG_Blink_Per_Minute	18.75	11.12	16.38	2.67	48.19	0.82	0.13
	Left_Pupil_Size_Max	23.47	3.90	23.00	14.53	32.59	0.38	-0.48
	Left_Pupil_Size_Min	15.02	2.79	15.07	8.15	21.57	0.11	-0.24
	Left_Pupil_Size_Mean	20.52	3.67	19.81	11.23	29.65	0.35	-0.47
	Right_Pupil_Size_Max	23.36	4.28	22.80	12.60	35.32	0.29	-0.42
	Right_Pupil_Size_Min	15.06	2.84	14.72	9.26	20.91	0.06	-0.89
	Right_Pupil_Size_Mean	20.46	3.87	20.25	11.08	32.03	0.32	-0.35
	Depression	6.39	4.83	5.00	0.00	18.00	0.65	-0.58
	Anxiety	7.02	5.33	6.00	0.00	19.00	0.44	-0.97
	Stress	9.14	4.78	9.00	0.00	20.00	0.03	-0.85

Nota: $\bar{x}$ = Promedio, σ = Desviación estándar, $\tilde{x}$ = Mediana, min = Mínimo, max = Máximo, γ_1 = Sesgo, γ_2 = Kurtosis.

Como se puede observar los datos no son univariadamente normales, los resultados de la prueba de Roystone para normalidad multivariante también arroja falta de normalidad en ambos conjuntos de datos (df_positivo = 4.93789e-14 y df_negativo = 1.985024e-14). Por lo tanto, se concluyó que ambos requieren de herramientas de análisis que no dependan de la normalidad de los datos.

4.2.4 Análisis de características de datos positivos y negativos

La prueba U de Mann-Whitney (también conocida como prueba de Wilcoxon-Mann-Whitney) se usa para comparar las distribuciones de dos grupos independientes. En este caso se utilizó para comprobar si existen diferencias significativas entre las características y las clases depresivas que se habían establecido previamente. Para la prueba U, si el valor $p > 0.05$, no hay evidencia suficiente para afirmar que hay una diferencia significativa en la característica entre las dos clases. En cambio, si el valor $p < 0.05$, hay evidencia suficiente para afirmar que hay una diferencia significativa en la característica entre las dos clases.

A continuación, la Tabla 4.8 presenta los resultados de la prueba U para cada característica en dos clases (con depresión y sin depresión).

Tabla 4.8: Resultados de la prueba U para las características de los conjuntos de datos para 2 clases

	Característica	Valor p	¿Diferencia significativa?
df_positivo	Fixation_Count	0.2124863	NO
	AVG_Fixation_Duration	0.4720713	NO
	AVG_Saccade_Amplitude	0.1674367	NO
	AVG_Saccade_Velocity	0.6516912	NO
	Blink_Count	0.2392686	NO
	AVG_Blink_Duration	0.1093891	NO
	AVG_Blink_Per_Minute	0.1233659	NO
	Left_Pupil_Size_Max	0.3474376	NO
	Left_Pupil_Size_Min	0.1215128	NO
	Left_Pupil_Size_Mean	0.2021298	NO
	Right_Pupil_Size_Max	0.4785634	NO
	Right_Pupil_Size_Min	0.0760363	NO
	Right_Pupil_Size_Mean	0.2481805	NO
	Depression	0	SI
	Anxiety	0.4548268	NO
	Stress	0.6777050	NO
df_negativo	Fixation_Count	0.0569685	NO
	AVG_Fixation_Duration	0.07131479	NO
	AVG_Saccade_Amplitude	0.1974312	NO
	AVG_Saccade_Velocity	0.996014	NO
	Blink_Count	0.1513314	NO
	AVG_Blink_Duration	0.1202608	NO
	AVG_Blink_Per_Minute	0.1115471	NO
	Left_Pupil_Size_Max	0.8027515	NO
	Left_Pupil_Size_Min	0.3985115	NO
	Left_Pupil_Size_Mean	0.2987503	NO
	Right_Pupil_Size_Max	0.6783998	NO
	Right_Pupil_Size_Min	0.1633732	NO
	Right_Pupil_Size_Mean	0.387442	NO
	Depression	0	SI
	Anxiety	0.1722581	NO
	Stress	0.3339591	NO

Al observar la tabla podemos darnos cuenta que el enfoque de diferenciar la depresión de manera binaria con estos conjuntos de características será difícil ya que no existen diferencias significativas entre grupos. Sin embargo, se exploró la posibilidad de que existirían diferencias entre las clases de depresión:

1. Sin depresión (SD)
2. Depresión leve (DL)
3. Depresión moderada (DM)
4. Depresión severa (DS)
5. Depresión extremadamente severa (DES)

A continuación, se realizaron pruebas U entre las 5 clases del conjunto de datos donde se utilizó una matriz con el valor p de cada característica entre las 5 posibles clases. Cada cuadro de la cuadrícula en la matriz representa 1 de las características en una forma de 4x4 como se muestra en la Figura 4.4.

Fixation_Count	AVG_Fixation_Duration	AVG_Saccade_Amplitude	AVG_Saccade_Velocity
Blink_Count	AVG_Blink_Duration	AVG_Blink_Per_Minute	Left_Pupil_Size_Max
Left_Pupil_Size_Min	Left_Pupil_Size_Mean	Right_Pupil_Size_Max	Right_Pupil_Size_Min
Right_Pupil_Size_Mean	Depression	Anxiety	Stress

Figura 4.4: Distribución de presentación de los valores p de las características en la matriz

Además, se muestra un código de color donde **rojo** representa un valor p superior a un alfa de 0.05, **amarillo** un valor muy cercano a 0.05 y **verde** un valor inferior a 0.05 (ver Figura 4.5).

	SD				DL				DM				DS				DES			
SD	1	1	1	1																
	1	1	1	1																
	1	1	1	1																
	1	1	1	1																
DL	.51	.91	.15	.40	1	1	1	1												
	.48	.53	.40	.57	1	1	1	1												
	.79	.77	.58	.53	1	1	1	1												
	.62	.000	.70	.40	1	1	1	1												
DM	.39	.62	.01	.28	.71	.51	.34	1	1	1	1									
	.005	.004	.002	.47	.05	.02	.04	.14	1	1	1	1								
	.01	.22	.47	.01	.08	.12	.20	.09	1	1	1	1								
	.22	.000	.66	.75	.08	.000	.46	.69	1	1	1	1								
DS	.25	.38	.50	.41	.72	.45	.60	.18	.81	.70	.15	.10	1	1	1	1				
	.88	.26	.90	.02	.47	.53	.54	.004	.02	.12	.01	.10	1	1	1	1				
	.08	.009	.10	.11	.15	.002	.02	.51	.61	.10	.24	.28	1	1	1	1				
	.02	.000	.05	.04	.01	.000	.03	.008	.37	.000	.18	.03	1	1	1	1				
DES	.11	.14	.49	.48	.62	.19	.10	.34	.33	.27	.01	.19	.84	.50	.26	.94	1	1	1	1
	.64	.71	.75	.74	.39	.68	.32	.89	.01	.04	.01	.49	.86	.44	.79	.06	1	1	1	1
	.22	.49	.65	.38	.19	.68	.92	.28	.008	.18	.38	.01	.01	.02	.07	.17	1	1	1	1
	.71	.000	.28	.19	.86	.000	.15	.06	.18	.000	.32	.16	.02	.000	.35	.65	1	1	1	1

Figura 4.5: Matriz de valores p resultado de la prueba U en las características de todas las clases

Gracias a la matriz anterior se puede inferir que en distintas clases existe una mayor diferencia entre las características que otras, por ejemplo, donde existe un mayor número de características en color verde existen más diferencias entre esos grupos (excepto con depression, anxiety y stress):

- Depresión Moderada / Sin Depresión (6 características diferentes)
- Depresión Moderada / Leve (2 características diferentes)
- Depresión Severa / Sin Depresión (3 características diferentes)

- Depresión Severa / Leve (5 características diferentes)
- Depresión Severa / Moderada (2 características diferentes)
- Depresión Extremadamente Severa / Moderada (6 características diferentes)
- Depresión Extremadamente Severa / Severa (5 características diferentes)

Sin embargo, lo contrario también es cierto para los otros grupos donde parecería que es muy complicado distinguir entre depresión extremadamente severa y niveles bajos de depresión.

Como parte del análisis de los datos, se realizó un Análisis de Componentes Principales (PCA) con las 13 características principales, esto con el objetivo de observar la reducción de la dimensionalidad, las características más representativas y visualizar una distribución de los datos. A continuación, se presenta la distribución de las dos primeras componentes principales de los datos en una clasificación binaria (ver Figura 4.6).




Figura 4.6: Visualización de las dos primeras componentes principales clasificadas en 2 clases

Y en una clasificación multiclase (ver Figura 4.7).




Figura 4.7: Visualización de las dos primeras componentes principales clasificadas en 5 clases (0 = SD, 1 = DL, 2 = DM, 3 = DS y 4 = DES)

Se observa una superposición significativa entre las instancias de las clases, lo que dificulta la definición de límites claros de decisión. Las fronteras entre las clases son ambiguas y las instancias de diferentes clases se entrelazan en el espacio de características, lo que contribuye a una mezcla considerable de características entre ellas. A continuación, la Figura 4.8 y Figura 4.9 muestran la proporción de la varianza de los datos explicada por cada componente principal.




Figura 4.8: Gráfico de la proporción de la varianza explicada por el PCA en el conjunto de datos df_negativo.




Figura 4.9: Gráfico de la proporción de la varianza explicada por el PCA en el conjunto de datos df_positivo

La observación de cuánta varianza explica cada componente principal en un PCA es fundamental para comprender qué tan bien las componentes capturan la información contenida en los datos originales. La varianza explica la dispersión de los datos en cada componente y proporciona información sobre cuánta información se conserva al proyectar los datos en esa componente. Una proporción de varianza del 0.95, por ejemplo, significa que la componente explica el 95% de la varianza en los datos.

La Tabla 4.9 muestra el resultado del PCA en cifras, además muestra la varianza acumulativa, desde el primer componente principal (PC) 1 hasta el 12 en ambos conjuntos de datos.

Tabla 4.9: Resultados del análisis PCA en cifras para ambos conjuntos de datos

		PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10	PC11	PC12
df_negativo	Desviación estándar	2.136	1.793	1.575	0.702	0.612	0.477	0.457	0.424	0.342	0.292	0.180	0.136
	Proporción de varianza	0.380	0.268	0.206	0.041	0.031	0.018	0.017	0.015	0.009	0.007	0.002	0.001
	Proporción acumulativa	0.380	0.648	0.855	0.896	0.927	0.946	0.963	0.978	0.988	0.995	0.998	1.0
df_positivo	Desviación estándar	2.106	1.651	1.566	1.002	0.617	0.581	0.479	0.410	0.343	0.299	0.200	0.104
	Proporción de varianza	0.369	0.227	0.204	0.083	0.031	0.028	0.019	0.014	0.009	0.007	0.003	0.000
	Proporción acumulativa	0.369	0.597	0.801	0.885	0.917	0.945	0.964	0.978	0.988	0.995	0.999	1.0

Se observa que a partir del componente principal 7 se logra una representación de más del 95% de la varianza de los datos, por lo tanto, se podría representar los datos en un espacio de 7 dimensiones/características sin perder significativamente la información esencial presente en los datos originales (13 características).

En este punto también podríamos observar que características originales son las que aportan más información a estos componentes principales. A la aportación de las variables originales en cada componente principal se le denominará como “carga”.

La Figura 4.10 y la Figura 4.11 utilizan puntos azules para representar las variables en el espacio de las dos primeras componentes principales. La dirección del punto, en relación al origen, indica la dirección en la que la variable tiene la mayor variabilidad, y la distancia del origen indica la magnitud de la carga.




Figura 4.10 Gráfico de cargas de las características en los dos primeros PC para el conjunto de datos df_negativo.




Figura 4.11 Gráfico de cargas de las características en los dos primeros PC para el conjunto de datos df_positivo.

Las variables con puntos más lejos del origen en la dirección positiva o negativa tienen cargas más grandes en esas componentes principales (La magnitud de la carga indica la importancia relativa de una variable en una componente principal específica, independientemente de la dirección). La relación entre los puntos indica la correlación entre las variables en las componentes principales. Si dos variables tienen puntos en la misma dirección, están positivamente correlacionadas en esas componentes. Si los puntos están en direcciones opuestas, están negativamente correlacionadas.

Al observar las figuras se puede concluir lo siguiente:

- En el conjunto de datos df_negativo, las características más representativas son:
 - Para la Componente Principal 1 (top 5):
 - Left_Pupil_Size_Min
 - Right_Pupil_Size_Min
 - Left_Pupil_Size_Mean
 - Left_Pupil_Size_Max
 - AVG_Blink_Duration

- o Para la Componente Principal 2 (top 5):
 - Blink_count
 - AVG_Blink_Per_Minute
 - Left_Pupil_Size_Max
 - AVG_Blink_Duration
 - Right_Pupil_Size_Max
- En el conjunto de datos df_positivo, las características más representativas son:
 - o Para la Componente Principal 1 (top 5):
 - Right_Pupil_Size_Min
 - Left_Pupil_Size_Min
 - Left_Pupil_Size_Mean
 - Left_Pupil_Size_Max
 - Right_Pupil_Size_Max
 - o Para la Componente Principal 2 (top 5):
 - Fixation_Count
 - AVG_Saccade_Amplitude
 - AVG_Blink_Duration
 - AVG_Fixation_Duration
 - Blink_Count

Las características de la pupila son las más representativas de ambos conjuntos de datos seguidas de las características del parpadeo, lo cual empata correctamente con lo observado en el estado del arte donde muchas de las investigaciones utilizan estas características para la predicción de emociones.

Sin embargo, debido a la falta de diferencias significativas entre grupos, sería muy difícil separar las clases para métodos de clasificación lineales, en este caso el mejor acercamiento para usar aprendizaje maquina seria métodos robustos o aprendizaje profundo. Por lo que se decidió cambiar el enfoque de los conjuntos de datos a uno alternativo.

4.3 Análisis y procesamiento de conjunto de datos alternativo

Luego de corroborar que los algoritmos de ML supervisados tuvieron muchos problemas con los conjuntos de datos positivos y negativos, se decidió usar un conjunto de datos alternativo. Donde se aumentó el número de características de los conjuntos de datos de eventos (37 numéricas y 9 categóricas), para ello se corrieron los algoritmos de procesamiento en cada

prueba del repositorio (tiempo de ejecución de 8.71 horas) y se realizó un análisis para observar la importancia de las nuevas características.

A continuación, se describen los procesos que se siguieron para la definición del nuevo conjunto de datos.

4.3.1 Limpieza de datos

Similar al proceso anterior, en todos los conjuntos de datos se utilizó la función “md.pattern” de la librería “mice” y la función “vis_miss” de la librería “visdat”. Ambas funciones buscan dentro de los datos y revelan si existen valores perdidos los cuales pueden afectar cálculos de estadísticos descriptivos y correlaciones. Los resultados de ambas funciones, devolvieron que ambos conjuntos de datos estaban completos.

4.3.2 Manejo de valores atípicos

Los datos utilizados en el análisis pasaron por un proceso de manejo de valores atípicos, descrito en la sección 3.6.2 del capítulo 3, para minimizar su impacto en los resultados. Se empleó un método basado en la desviación con respecto a la mediana, el cual permitió identificar valores atípicos mediante su distancia en términos de desviaciones estándar. Posteriormente, se aplicó una función exponencial inversa para asignar pesos a los datos en función de esta distancia, lo cual reduce la influencia de los valores extremos sin eliminar información relevante. Este enfoque garantizó que los cálculos estadísticos reflejaran de manera más precisa el comportamiento general de los datos, y con esto se evitan sesgos provocados por valores atípicos.

4.3.3 Preparación de datos

Una vez que se confirma que los conjuntos de datos están completos se procede a utilizar filtros en los rangos de cada columna de datos con el objetivo de normalizar la escala de la información de los conjuntos. Para esta tarea se utilizó un filtro Min-Max (35) el cual convierte la información de una columna de datos en un rango entre 0 y 1 donde 0 es el valor mínimo de la columna y 1 el valor máximo.

4.3.4 Balance de las clases

Una vez limpios y preparados los datos se observó la distribución de las clases en los conjuntos de datos de eventos (30 eventos en total), en el rango de conjuntos:

- 1-24 había un balance de 54 vectores sin depresión y 81 con depresión
- En el evento 25 hay 50 vectores sin depresión y 75 con depresión
- En el evento 26 hay 47 vectores sin depresión y 73 con depresión
- En el evento 27 hay 45 vectores sin depresión y 70 con depresión
- En el evento 28 hay 44 vectores sin depresión y 67 con depresión
- En el evento 29 hay 43 vectores sin depresión y 65 con depresión
- En el evento 30 hay 39 vectores sin depresión y 61 con depresión

El desequilibrio en el balance de clases dentro de los conjuntos de datos se debe a errores en la generación de los archivos de eventos. Particularmente, en las últimas pruebas se registraron menos datos, lo que afectó a los algoritmos encargados de generar las métricas. Estos algoritmos están diseñados para descartar un vector completo cuando detectan que la cantidad de datos disponibles es insuficiente para procesar métricas, lo que contribuyó a la disparidad en la distribución de clases.

Como resultado, en todos los conjuntos de datos, la clase minoritaria "sin depresión" fue superada por al menos 15 clases correspondientes a distintos niveles de depresión. En este estudio, se consideró como "con depresión" cualquier nivel igual o superior a Leve, según el instrumento DASS-21.

Para abordar el problema del desequilibrio de clases, se emplearon técnicas de aumento sintético de datos o sobre-muestreo con la librería DMwR de R. Esta librería proporciona una función que implementa SMOTE (Synthetic Minority Over-sampling Technique), lo que permitió generar muestras sintéticas basadas en las características de la clase minoritaria. En este caso, se incluyeron todas las características numéricas en la función y se configuraron parámetros para equilibrar el número de muestras entre las clases 0 (sin depresión) y 1 (con depresión).

4.3.5 Selección de características

A continuación, se realizó una prueba U sobre los conjuntos de datos (originales sin muestras sintéticas) para observar si existen diferencias entre los grupos para cada columna. Debido a que se deben comparar cada columna de los 30 diferentes conjuntos de datos se realizó un bucle en código de R para que imprimiera en pantalla solo aquellas columnas que muestran diferencias significativas entre los grupos de clases. La Tabla 4.10 muestra estos resultados.

Tabla 4.10: Características que si son significativamente diferentes entre las dos clases

Evento	2	3	4	8	9	10	11	12	13	14	15	16	20	21	22	23	24	25	26	27	28	29	30
Right_Pupil_Size_Min	1	1																					
Left_Pupil_Size_SK		1																					
Left_Pupil_Size_Kurt		1																					
Right_Pupil_Size_SK			1		1		1								1							1	
Right_Pupil_Size_Kurt			1		1										1								
Y_Fixation_Data_Mean				1								1											
Y_Fixation_Data_SD						1																	
AVG_Blink_Per_Minute								1		1			1						1				
X_Fixation_Data_Var								1			1				1								
X_Fixation_Data_SD								1			1												
AVG_Saccade_Velocity									1								1						
Y_Fixation_Data_SK									1				1										
Fixation_Count										1													
Blink_Count										1			1						1				
X_Fixation_Data_Max										1													
Y_Fixation_Data_Var										1													
Y_Fixation_Data_Kurt										1							1						
Left_Pupil_Size_Max												1	1							1			
Right_Pupil_Size_Max													1						1	1			
AVG_Saccade_Latency														1									
X_Fixation_Data_Min														1									
Left_Pupil_Size_Mean																		1					
AVG_Blink_Duration																			1				
Y_Fixation_Data_Min																			1				
Right_Pupil_Size_Mean																			1			1	
Left_Pupil_Size_Min																							1
Total	1	3	2	1	2	1	1	3	2	6	2	2	5	2	3	1	1	1	6	2	0	2	1

Se observa que solo algunos datos de ciertos eventos de imagen fueron significativamente diferentes entre las clases, basándonos en estos resultados, se decidió que las características más significativas para distinguir la depresión son:

1. El sesgo en la pupila derecha (5 veces)
2. El promedio de la tasa de parpadeo (4 veces)
3. La curtosis en la pupila derecha (3 veces)
4. La varianza en los datos de fijación en X (3 veces)
5. El Máximo de tamaño de ambas pupilas (3 veces)
6. El número de parpadeos (3 veces)
7. Entre otras

Debido a que los datos significativos están distribuidos en distintos conjuntos de datos, se optó por implementar una técnica de combinación para consolidar esta información en un solo conjunto, que será referido como "compuesto" en adelante. El archivo compuesto.csv aglutina los datos más relevantes mediante el cálculo de la media entre los conjuntos de datos. En casos donde la característica significativa proviene de un único conjunto, no se calculó la media; simplemente, se añadió la columna correspondiente al "compuesto". Es importante señalar que a partir del evento 24, el número de filas en los conjuntos de datos es variable. Por esta razón, se tomó la decisión de omitir los conjuntos de datos posteriores al evento 24. De esta manera, el conjunto "compuesto" presenta las siguientes características:

- | | |
|---------------------------|---------------------------|
| 1 "Right_Pupil_Size_Min" | 17 "Y_Fixation_Data_Kurt" |
| 2 "Left_Pupil_Size_SK" | 18 "Left_Pupil_Size_Max" |
| 3 "Left_Pupil_Size_Kurt" | 19 "Right_Pupil_Size_Max" |
| 4 "Right_Pupil_Size_SK" | 20 "AVG_Saccade_Latency" |
| 5 "Right_Pupil_Size_Kurt" | 21 "X_Fixation_Data_Min" |
| 6 "Y_Fixation_Data_Mean" | 22 "Class" |
| 7 "Y_Fixation_Data_SD" | |
| 8 "AVG_Blink_Per_Minute" | |
| 9 "X_Fixation_Data_Var" | |
| 10 "X_Fixation_Data_SD" | |
| 11 "AVG_Saccade_Velocity" | |
| 12 "Y_Fixation_Data_SK" | |
| 13 "Fixation_Count" | |
| 14 "Blink_Count" | |
| 15 "X_Fixation_Data_Max" | |
| 16 "Y_Fixation_Data_Var" | |

Por lo tanto, en este punto se contaba con un conjunto de datos (“compuesto.csv”) que contiene los datos más significativos entre las clases de depresión y sin depresión. Se esperan mejores resultados con este conjunto de datos.

4.4 Resultados de selección de características

En función del conjunto de datos compuesto.csv, la Tabla 4.11 presenta los resultados de las pruebas U para características específicas, los cuales indican qué estímulos revelaron diferencias significativas entre los grupos.

Ya que si el valor $p > 0.05$, no hay evidencia suficiente para afirmar que hay una diferencia significativa en la característica entre las dos clases, solo se puede aceptar la diferencia significativa si el valor $p < 0.05$. Es por esto que el vector de datos para prueba quedó conformado por 21 características, distribuidas de la siguiente manera:

- **Tamaño pupilar:** Valores máximos, asimetría (skewness) y curtosis para la pupila izquierda y derecha.
- **Métricas de fijación ocular:** Número de fijaciones, varianza y desviación estándar de las coordenadas X e Y, valores máximo y mínimo de la coordenada X (movimiento lateral), y media, asimetría (skewness) y curtosis de la coordenada Y (movimiento vertical).
- **Otras métricas de seguimiento ocular:** Número de parpadeos, tasa de parpadeo por minuto, velocidad de sacada y latencia de sacada.
- Además, el conjunto de datos incluyó la variable objetivo 'Clase', que representa el resultado de clasificación. En total, se obtuvieron 228 vectores de datos (114 pertenecientes al grupo con depresión y 114 al grupo de control)

Tabla 4.11: Diferencias entre grupos (depresión y sin depresión) en el conjunto de datos compuesto.csv

Característica	Evento	U statistic	p-value
AVG_Blink_Per_Minute	12	1829.5	0.038
	14	1804	0.029
	20	1803.5	0.028
	26	1117	0.001
AVG_Blink_Duration	26	1062	0.0004
AVG_Saccade_Latency	21	2797	0.034
AVG_Saccade_Velocity	13	2847	0.019
	23	2660	0.033
Blink_Count	14	1797.5	0.026
	20	1748	0.014
	26	1140.5	0.001
Fixation_Count	14	2775.5	0.043
Left_Pupil_Size_Kurt	3	1621	0.002
Left_Pupil_Size_Max	16	2787	0.038
	20	2770	0.045
	27	1948	0.032
Left_Pupil_Size_Mean	25	2312	0.027
Left_Pupil_Size_Min	30	1478	0.041
Left_Pupil_Size_SK	3	2925	0.007
Right_Pupil_Size_Kurt	4	2948	0.005
	9	2765	0.048
	22	2802	0.032
Right_Pupil_Size_Max	20	2811	0.029
	26	2232	0.005
	27	2024	0.010
Right_Pupil_Size_Mean	26	2084	0.047
	29	1822	0.007
Right_Pupil_Size_Min	2	2777	0.042
	3	1841	0.043
Right_Pupil_Size_SK	4	1617	0.002
	9	1781	0.022
	11	1807	0.030
	22	1754	0.016
	29	1036	0.023
X_Fixation_Data_Max	14	2777	0.042
X_Fixation_Data_Min	21	2620	0.018
X_Fixation_Data_SD	12	1674	0.006
	15	1584	0.001
X_Fixation_Data_Var	12	1733	0.012
	14	2903	0.010
	15	1578	0.001
	22	1793	0.025
Y_Fixation_Data_Kurt	14	1718	0.010
	24	1575	0.046
Y_Fixation_Data_Mean	8	2817	0.027
	16	2845	0.020
Y_Fixation_Data_Min	26	1999.5	0.044
Y_Fixation_Data_SD	10	1830	0.038
Y_Fixation_Data_SK	13	2897	0.010
	20	1699	0.008

4.4.1 Comparativa de características seleccionadas con el estado del arte

A continuación, la **¡Error! La autoreferencia al marcador no es válida.**, muestra una comparativa de todas las características identificadas en el estado del arte con aquellas que se seleccionaron en este trabajo, como se puede observar existe concordancia entre las investigaciones actuales en detección de depresión con ET y este trabajo.

Tabla 4.12: Características que se observaron en el estado del arte

		(Al-gawwam y Benaissa 2018)	(Li et al., 2020)	(Stolicyn et al., 2020)	(Zhu et al., 2020)	(Alghowine m et al., 2018)	(Pan et al., 2019)	(Wang et al., 2019)	(Zhu, Y. Wang, et al., 2019)	(Ding et al., 2019)	(Li et al., 2016)	Este trabajo
Fixation	Fixation points				✓							✓
	Dwell time / Duration					✓	✓	✓		✓	✓	✓
	Count			✓			✓	✓		✓	✓	✓
	Time			✓				✓		✓		
	Latency			✓								
	First fixation						✓			✓		
Saccades	Saccades Paths				✓							
	Path Length						✓					✓
	Start time						✓					
	Speed						✓					✓
	Count							✓				
	Amplitude								✓		✓	✓
	Latency								✓			✓
	Duration										✓	✓
Blink	Frequency					✓						✓
	Duration					✓		✓				✓
	Closed eyes					✓						
	Eyelids distance	✓										
	Count							✓				✓
Pupil	Diameter				✓				✓		✓	✓
	Change rate		✓									
	Mean and Variance										✓	✓
	Max size										✓	✓
Eye movements	Gaze direction					✓						
	Iris					✓						
	Eyelid					✓						
	Eyebrow					✓						
	Glance count							✓				
	First gaze on AOI							✓				

Posteriormente se continuo con las pruebas de entrenamiento de ML.

4.5 Entrenamiento de algoritmos de aprendizaje automático y resultados

Este informe detalla el proceso llevado a cabo para implementar diversos algoritmos de ML en Python, los cuales fueron fundamentales para llevar a cabo la tarea de clasificación en el proyecto, específicamente, la clasificación de depresión. Esta sección abarca desde la selección de los algoritmos, la optimización de hiperparámetros, la presentación de los mejores resultados obtenidos tanto en tareas de clasificación binaria.

4.5.1 Conjuntos de datos para pruebas

A continuación, se describirán los conjuntos de datos que se utilizaron para entrenar los modelos predictivos. La Tabla 4.13 muestra la información de cada conjunto de datos que se utilizó, el número de datos, clases y características.

Tabla 4.13: Resumen de los conjuntos de datos utilizados para las pruebas de clasificación

Conjunto	# de datos	Balance de clases		# de características
		Sin depresión	Con depresión	
df_positivos.csv	121	52	69	16
df_negativos.csv	125	53	72	16
compuesto.csv	228	114	114	21

Para resolver el problema del balanceo de clases se aumentó el número de muestras con los algoritmos de muestreo sintético.

4.5.2 Selección de algoritmos para pruebas de predicción

Para la selección de los algoritmos supervisados que se implementaron, se tomó en cuenta tanto la revisión de literatura, donde los algoritmos más utilizados en tareas similares son el SVM, las redes neuronales, y modelos como KELM, CBEM y la regresión logística, como las características particulares de los conjuntos de datos generados en este estudio.

Los datos utilizados presentan una estructura tabular con variables numéricas estandarizadas y un número limitado de muestras por clase, además de haber pasado por un proceso de

balanceo mediante técnicas de aumento sintético (SMOTE). Dado este contexto, se optó por algoritmos que ofrecen buen desempeño en conjuntos de datos con características similares: presencia de múltiples variables, posible ruido residual, y necesidad de generalización eficiente.

En particular, los SVM son reconocidos por su capacidad para manejar espacios de alta dimensionalidad y problemas de clasificación binaria con márgenes óptimos. Random Forest (RF) fue considerado por su robustez frente a valores atípicos y su habilidad para manejar relaciones no lineales sin requerir una transformación previa de los datos. Multi-Layer Perceptron (MLP) fue incluido por ser una red neuronal capaz de capturar patrones complejos a partir de combinaciones no lineales de características, mientras que Gradient Boosting (GB) se seleccionó por su capacidad de generar modelos de alto rendimiento a través del ensamblado de clasificadores débiles.

Esta selección busca cubrir un espectro amplio de enfoques de ML, y aumentar así la posibilidad de identificar un modelo con buen desempeño en la clasificación de niveles de depresión basados en métricas oculares.

4.5.3 Selección de y ajuste de hiperparámetros para los algoritmos

Evidentemente, cada algoritmo de clasificación funciona de una forma específica. El algoritmo de Máquinas de Soporte Vectorial (SVM) busca encontrar un hiperplano óptimo para separar clases en un espacio de características, mientras que Random Forest (RF) opera mediante la construcción de múltiples árboles de decisión independientes y combina sus predicciones. Multi Layer Perceptron (MLP) representa una red neuronal con capas múltiples, para modelar aprendizaje profundo (dependiendo de su configuración puede ser que algunos expertos difieran en llamarlo aprendizaje profundo) para modelar relaciones complejas. Por otro lado, Gradient Boosting (GB) construye modelos secuencialmente, mientras ajusta cada nuevo modelo para corregir los errores de los modelos anteriores, optimizando mediante descenso del gradiente para minimizar la función de pérdida.

Los hiperparámetros desempeñan un papel crucial en la configuración y optimización de estos algoritmos. En el caso de SVM, la elección del kernel (lineal, polinómico, radial, etc.) y la configuración de parámetros como C (regularización) y gamma son esenciales para el

rendimiento del modelo. En Random Forest (RF), la cantidad de árboles, la profundidad máxima de cada árbol y el número mínimo de muestras por hoja son hiperparámetros clave que afectan la complejidad y capacidad de generalización del bosque. Multi Layer Perceptron (MLP), al ser una red neuronal, requiere la selección de la arquitectura de la red, incluyendo el número de capas y neuronas por capa, así como la tasa de aprendizaje y la función de activación. Para Gradient Boosting (GB), los hiperparámetros incluyen el número de árboles, la tasa de aprendizaje y la profundidad máxima de cada árbol, influyendo en la capacidad del modelo para corregir errores y evitar sobreajuste. La elección adecuada de estos hiperparámetros es esencial para obtener un rendimiento óptimo de cada algoritmo en tareas específicas de ML.

Para abordar la selección de los mejores hiperparámetros para la tarea específica de clasificación se hizo uso de GridSearchCV que es un objeto de la biblioteca scikit-learn de Python (Pedregosa et al., 2011). Permite hacer uso de una técnica para encontrar los mejores hiperparámetros de un modelo mediante la evaluación exhaustiva de todas las combinaciones posibles de valores de hiperparámetros en un espacio predefinido (una matriz de hiperparámetros).

Una vez se ejecuta la instancia de GridSearchCV, se utiliza validación cruzada para evaluar el rendimiento del modelo para cada combinación de hiperparámetros. En cada iteración, una parte del conjunto de datos se utiliza para entrenar el modelo y otra parte para evaluar su rendimiento. Esto se repite varias veces, y los resultados se promedian para proporcionar una métrica de rendimiento más robusta.

Después, el modelo en conjunto con la combinación de hiperparámetros que produce el mejor rendimiento promedio en términos de la métrica especificada (por ejemplo, precisión) se selecciona como el modelo final o dicho en otras palabras el mejor modelo.

La elección de estos hiperparámetros específicos se fundamentó tanto en lo observado en el estado del arte como en una comprensión detallada del efecto que cada uno tiene sobre el comportamiento y desempeño de su respectivo algoritmo. Esta selección buscó optimizar la capacidad de generalización de los modelos, mejorar la precisión de la clasificación y adaptarse adecuadamente a la estructura de los datos utilizados en este estudio. La Tabla 4.14 muestra la configuración de hiperparámetros utilizados para cada algoritmo.

Tabla 4.14: Configuración de hiperparámetros para cada algoritmo de ML utilizado

Algoritmo	Hiperparámetros	
	Nombre	Valores (separados por comas)
SVM	C	0.001, 0.01, 0.1, 1, 5, 10, 15, 20
	Degree	2, 3, 4
	Gamma	0.01, 0.1, 1, 5, 10
	Coef0	0,1
RF	n_estimators	10, 50, 100, 200
	max_depth	None, 10, 20, 30
	min_samples_split	2, 5, 10
	min_samples_leaf	1, 2, 4
	random_state	11
GB	learning_rate	0.001, 0.01, 0.1
	n_estimators	50, 100, 200
	max_depth	3, 4, 5
	min_samples_split	2, 3, 4
MLP	epochs	5, 10, 20, 30
	batch_size	16, 32, 64
	optimizer	adam, sgd, rmsprop
	optimizer_lr	0.001, 0.01, 0.05, 0.1
	hidden_layer_sizes	{[64], [64, 32], [64, 32, 16], [64, 32, 16, 8]}
	dropout	0, 0.25, 0.5

Hiperparámetros de SVM

- **C (Parámetro de Regularización):** Se prueba una amplia gama de valores para abordar la sensibilidad del modelo a los errores de clasificación y evitar el sobreajuste o subajuste.
- **Degree (Grado del Kernel Polinómico):** Dado que SVM puede usar kernels polinómicos, se exploran varios grados para encontrar el mejor equilibrio entre capacidad para ajustarse a los datos y evitar sobreajuste.
- **Gamma (Coeficiente del Kernel RBF):** La variación en los valores de gamma afecta la influencia de un solo ejemplo de entrenamiento, lo que permite ajustar la flexibilidad del modelo.
- **Coef0 (Término Independiente en la Función del Kernel):** La exploración de diferentes valores de coef0 es esencial para adaptarse a las características específicas de los datos y mejorar la flexibilidad del modelo.

Hiperparámetros de Random Forest

- **n_estimators (Número de Árboles):** Evaluar cómo la cantidad de árboles influye en la capacidad de generalización del bosque.
- **max_depth (Profundidad Máxima de los Árboles):** Sirve para controlar la complejidad de cada árbol y evitar árboles demasiado profundos que puedan conducir a sobreajuste.
- **min_samples_split (Número Mínimo de Muestras para Dividir un Nodo Interno):** Regular la creación de nodos adicionales para evitar particiones que conduzcan a un modelo demasiado complejo.
- **min_samples_leaf (Número Mínimo de Muestras en las Hojas):** Regular la creación de hojas adicionales, influyendo en la capacidad del modelo para generalizar.
- **random_state (Semilla Aleatoria):** Fijar la semilla aleatoria asegura reproducibilidad en los experimentos.

Hiperparámetros de Gradient Boosting

- **learning_rate (Tasa de Aprendizaje):** Ajustar la tasa de aprendizaje controla la contribución de cada árbol al modelo general, lo cual afecta la convergencia y la capacidad de generalización.
- **n_estimators (Número de Árboles):** Evaluar cómo la cantidad de árboles afecta la capacidad de Gradient Boosting para corregir errores y evitar sobreajuste.
- **max_depth (Profundidad Máxima de los Árboles):** Regular la complejidad de cada árbol para evitar sobreajuste.
- **min_samples_split (Número Mínimo de Muestras para Dividir un Nodo Interno):** Controlar la creación de nodos internos para mejorar la capacidad de generalización.

Hiperparámetros de MLP

- **epochs:** Número de veces que el modelo verá el conjunto completo de entrenamiento durante el proceso de entrenamiento. Un número inapropiado de épocas puede generar sobreajuste o bajo entrenamiento del modelo.
- **batch_size:** Número de muestras de datos utilizadas en una iteración para actualizar los pesos del modelo. Afecta la velocidad y la estabilidad del entrenamiento. Un tamaño de lote pequeño puede proporcionar una actualización de peso más frecuente, pero con mayor variabilidad, mientras que un tamaño de lote grande puede proporcionar actualizaciones más estables, pero menos frecuentes.
- **optimizer (Optimizador):** Algoritmo utilizado para ajustar los pesos de la red durante el entrenamiento con el fin de minimizar la función de pérdida. Cada optimizador tiene sus propias características y puede funcionar mejor en diferentes tipos de problemas.
- **optimizer_lr (tasa de aprendizaje del optimizador):** Tasa de aprendizaje que determina el tamaño de los pasos que el optimizador toma al ajustar los pesos de la red. Puede afectar la velocidad de convergencia y la calidad del modelo final.
- **hidden_layer_sizes:** Lista que especifica el número de neuronas en cada capa oculta de la red. Ajustar el número de neuronas en cada capa oculta influye en la capacidad de la red para modelar patrones complejos. Una red con demasiadas neuronas puede sobreajustarse a los datos de entrenamiento, mientras que una red con muy pocas neuronas puede no ser lo suficientemente expresiva.
- **dropout:** Fracción de neuronas que se "apagan" durante el entrenamiento, es decir, se excluyen temporalmente de la red, lo que ayuda a prevenir el sobreajuste. es una técnica de regularización que puede mejorar la generalización del modelo.

Estos conjuntos de hiperparámetros se han seleccionado para explorar una variedad de configuraciones y garantizar una búsqueda exhaustiva de las combinaciones óptimas para cada algoritmo.

Mejores hiperparámetros

A continuación, se presentan los mejores hiperparámetros obtenidos para cada uno de los cuatro algoritmos supervisados implementados, resultado del proceso de optimización mediante **GridSearchCV** en Python:

- **SVM (Support Vector Machine)**: El modelo obtuvo su mejor rendimiento con un **parámetro de regularización $C = 0.1$** , con un **kernel polinómico de grado 4**, un **coef0 = 1** y un **valor de gamma = 0.1**. Esta configuración permitió ajustar correctamente la complejidad del modelo y capturar patrones no lineales en los datos.
- **Random Forest (RF)**: Para este modelo, los hiperparámetros óptimos fueron: **max_depth sin restricción**, **min_samples_leaf = 1**, **min_samples_split = 2** y **n_estimators = 200**, con un **random_state = 11** para garantizar la reproducibilidad de los resultados. Esta configuración maximizó la capacidad de aprendizaje del bosque sin sobreajustar los datos.
- **Gradient Boosting (GB)**: El mejor desempeño se alcanzó con una **tasa de aprendizaje (learning_rate) = 0.1**, **max_depth = 3**, **min_samples_split = 3** y **n_estimators = 200**. Esta combinación permitió un entrenamiento más gradual y controlado, lo cual mejoró la generalización del modelo.
- **Multi Layer Perceptron (MLP)**: El MLP alcanzó sus mejores resultados con un **batch_size = 16**, **30 épocas de entrenamiento**, una **tasa de dropout de 0.25** para reducir el sobreajuste y una arquitectura de capas ocultas configurada como **(64, 32, 16, 8)**. Se empleó el optimizador **rmsprop** con una **tasa de aprendizaje de 0.001**, lo cual permitió una convergencia eficiente durante el entrenamiento.

4.7 Resultados de aprendizaje automático

En esta sección se describen las funciones utilizadas para implementar el entrenamiento y pruebas de los algoritmos ML supervisados seleccionados.

4.7.1 Presentación del script para pruebas de predicción

A continuación, se muestra el código que se utilizó para realizar las pruebas con los algoritmos de ML, debido al tamaño del código se abordara por fragmentos. Uno de los objetivos principales de crear este script es la reproducibilidad de las pruebas de predicción para este y futuros trabajos.

Librerías utilizadas

En el Código 4.1, se observan todas las librerías de terceros que se utilizaron para la implementación de los diversos algoritmos, la evaluación y el manejo de los datos. Cabe destacar que “clasificadorEnsamble” fue una clase personalizada que implementa un algoritmo de clasificación por ensamble, esto será descrito más adelante.

```
import pandas as pd
import tensorflow as tf
from sklearn import svm
from sklearn.model_selection import GridSearchCV, train_test_split
from sklearn.ensemble import RandomForestClassifier
import chardet
from sklearn.metrics import accuracy_score, classification_report,
confusion_matrix
from sklearn.preprocessing import RobustScaler
from sklearn.ensemble import GradientBoostingClassifier
from tensorflow.python.keras.models import Sequential
from tensorflow.python.keras.layers import Dense, Dropout
from scikeras.wrappers import KerasClassifier
from datetime import datetime
from imblearn.combine import SMOTEENN
from imblearn.combine import SMOTETomek
from imblearn.over_sampling import SMOTE
from imblearn.over_sampling import ADASYN
from imblearn.over_sampling import BorderlineSMOTE
from imblearn.over_sampling import SVMSMOTE
from imblearn.over_sampling import SMOTENC
from imblearn.over_sampling import KMeansSMOTE
from sklearn.model_selection import cross_val_score, KFold
from collections import Counter
from sklearn.metrics import precision_recall_curve, auc
from detEnsamble import clasificadorEnsamble
```

Código 4.1 Librerías utilizadas en los scripts de Python

Definición de la clase principal y constructor

Con el objetivo de facilitar la implementación de múltiples pruebas, se desarrolló una clase principal denominada ClasificadorDepresion. Esta clase cuenta con un constructor que recibe como argumento un archivo de datos, junto con diversos parámetros que permiten configurar el proceso de clasificación de forma flexible y adaptable a diferentes escenarios de análisis. El diagrama de clases que ilustra la clase de ClasificarDepresión se puede observar en la Figura 4.12.

ClasificadorDepresion
-archivo : str -ok : bool -codificación: str -multiClass: bool -resampling: bool -tecnica_datos: str -soloDepre: bool -reporte: str -X_train : Numpy.dataframe -X_test : Numpy.dataframe -y_train : Numpy.dataframe -y_test : Numpy.dataframe -resultado_dict : dict -modelos: dict +__init__(archivo, multiclass, codificación, resampling, soloDepre, tecnica_datos. reporte) +crearConjuntos() +clasificadorArboles() +clasificadorSVM() +clasificadorGradientBoosting() +clasificadorRedNeuronal() +get_clf(n_feature_in, hidden_layer_sizes_, dropout, opt) +main()

Figura 4.12 Diagrama de clase para ClasificadorDepresion

Algunos de los atributos de clase se explican a continuación:

- **multiClass:** Controla si la clasificación es multiclase o no.
- **resampling:** Controla si se va a aplicar técnica de muestreo sintético.

- **soloDepre:** Controla si solo se utilizaran los datos de las pruebas con solo depresión (ósea sin Ansiedad y sin Estrés)
- **técnica_datos:** Controla que técnica de muestreo sintético se va a utilizar (SMOTEENN, SMOTETomek, SMOTE, ADASYN, BorderlineSMOTE, SVMSMOTE, SMOTEN o KMeansSMOTE)
- **reporte:** Controla en que archivo se escriben los resultados de los algoritmos al final de la ejecución.

También se observa que la clase contiene como atributos los conjuntos de prueba y entrenamiento además de una variable de tipo diccionario que permite guardar los modelos predictivos. Cuando se hace una instancia de esta clase, se ejecuta la función “crearConjuntos” la cual abre el archivo proporcionado para obtener los datos normalizarlos y procesar los conjuntos X_{train} , X_{test} , y_{train} y y_{test} . A continuación, se muestra, en forma de pseudocódigo, las funciones de los clasificadores dentro de la clase (ver Código 4.2, Código 4.3,

Algoritmo 3 Clasificación con Gradient Boosting usando búsqueda de cuadrícula

Require: Conjuntos de entrenamiento (X_{train}, y_{train}), y prueba (X_{test}, y_{test});

Ensure: Modelo Gradient Boosting entrenado con los mejores hiperparámetros y métricas de evaluación.

- 1: Definir el espacio de búsqueda para hiperparámetros:
 $learning_rate \in \{0.001, 0.01, 0.1\}$
 $n_{estimators} \in \{50, 100, 200\}$
 $max_depth \in \{3, 4, 5\}$
 $min_samples_split \in \{2, 3, 4\}$
 $random_state = 42$
- 2: Crear un clasificador Gradient Boosting.
- 3: Ejecutar búsqueda en malla (GridSearchCV) con validación cruzada de 5 pliegues para encontrar la mayor combinación de hiperparámetros.
- 4: Entrenar el modelo óptimo con los datos de entrenamiento (X_{train}, y_{train}).
- 5: Usar el modelo entrenado para predecir etiquetas $\hat{y}$ sobre X_{test} .
- 6: Calcular la precision del modelo sobre los datos de prueba.
- 7: Calcular métricas adicionales y generar un reporte de evaluación.

Salida: Modelo Gradient Boosting entrenado con los mejores hiperparámetros.

Código 4.4 y

Algoritmo 4 Clasificación con Red Neuronal usando búsqueda de cuadrícula

Require: Conjuntos de entrenamiento (X_{train}, y_{train}), y prueba (X_{test}, y_{test});

Ensure: Red neuronal entrenada con los mejores hiperparámetros y métricas de evaluación.

- 1: Definir la estructura del modelo (función *get_clf*):
 - 1.1 Crear una red neuronal secuencial.
 - 1.2 Agregar una capa densa de entrada con función de activación ReLU.
 - 1.3 Para cada capa oculta definida en *hidden_layer_sizes*:
 - Agregar capa densa con activación ReLu.
 - Agregar capa de abandon (Dropout) con tasa definida en *dropout*.
 - 1.4 Agregar capa de salida con activación sigmoidal (clasificación binaria).
 - 1.5 Compilar el modelo con función de pérdida *binary_crossentropy* y métrica *accuracy*.
- 2: Definir el espacio de búsqueda para hiperparámetros:

$epochs \in \{5, 10, 20, 30\}$
 $batch_size \in \{16, 32, 64\}$
 $optimizer_lr \in \{0.001, 0.01, 0.05, 0.1\}$
 $hidden_layer_sizes \in \{(64), (64,32), (64,32,16), (64,32,16,8)\}$
 $dropout = \{0, 0.25, 0.5\}$
 $opt = \{adam, sgd, rmsprop\}$
- 3: Construir un clasificador Keras mediante *KerasClassifier*, integrando *get_clf* como modelo base.
- 4: Ejecutar búsqueda en malla (GridSearchCV) con validación cruzada de 5 pliegues.
- 5: Entrenar el modelo óptimo con los datos de entrenamiento (X_{train}, y_{train}).
- 6: Usar el modelo entrenado para predecir etiquetas $\hat{y}$ sobre X_{test} .
- 7: Calcular la precision del modelo sobre los datos de prueba y la mayor configuración.
- 8: Calcular métricas adicionales y generar un reporte de evaluación.

Salida: Red neuronal entrenada con la mayor arquitectura y configuración de entrenamiento.

Código 4.5).

Algoritmo 1 Clasificación con SVM usando búsqueda de cuadrícula

Require: Conjuntos de entrenamiento (X_{train}, y_{train}), y prueba (X_{test}, y_{test}); pesos de clase (*class_weights*).

Ensure: Modelo entreado SVM con los mejores hiperparámetros y métricas de evaluación.

- 1: Definir el espacio de búsqueda para hiperparámetros:

$C \in \{0.001, 0.01, 0.1, 1, 5, 10, 15, 20\}$
 $degree \in \{2, 3, 4\}$
 $\gamma \in \{0.01, 0.1, 1, 5, 10\}$
 $coef0 \in \{0, 1\}$
 - 2: Crear un clasificador SVM con núcleo polynomial y pesos de clase ajustados.
-

-
- 3: Ejecutar búsqueda en malla (GridSearchCV) con validación cruzada de 5 pliegues para encontrar la mejor combinación de hiperparámetros.
 - 4: Entrenar el modelo óptimo con los datos de entrenamiento (X_{train}, y_{train}).
 - 5: Usar el modelo entrenado para predecir etiquetas $\hat{y}$ sobre X_{test} .
 - 6: Calcular la precisión del modelo sobre los datos de prueba.
 - 7: Calcular métricas adicionales y generar un reporte de evaluación.
-

Salida: Modelo SVM entrenado con los mejores hiperparámetros.

Código 4.2 Pseudocódigo de la función clasificadorSVM

Algoritmo 2 Clasificación con Bosques Aleatorios usando búsqueda de cuadrícula

Require: Conjuntos de entrenamiento (X_{train}, y_{train}), y prueba (X_{test}, y_{test});

Ensure: Modelo Random Forest entrenado con los mejores hiperparámetros y métricas de evaluación.

- 1: Definir el espacio de búsqueda para hiperparámetros:
 - $n_{estimators} \in \{10, 50, 100, 200\}$
 - $max_depth \in \{None, 10, 20, 30\}$
 - $min_samples_split \in \{2, 5, 10\}$
 - $min_samples_leaf \in \{1, 2, 4\}$
 - $random_state = 11$
- 2: Crear un clasificador Random Forest.
- 3: Ejecutar búsqueda en malla (GridSearchCV) con validación cruzada de 3 pliegues para encontrar la mejor combinación de hiperparámetros.
- 4: Entrenar el modelo óptimo con los datos de entrenamiento (X_{train}, y_{train}).
- 5: Obtener la importancia de las características del modelo entrenado.
- 6: Usar el modelo entrenado para predecir etiquetas $\hat{y}$ sobre X_{test} .
- 7: Calcular la precisión del modelo sobre los datos de prueba.
- 8: Calcular métricas adicionales y generar un reporte de evaluación.

Salida: Modelo Random Forest entrenado con los mejores hiperparámetros.

Código 4.3 Pseudocódigo de la función clasificadorArboles

Algoritmo 3 Clasificación con Gradient Boosting usando búsqueda de cuadrícula

Require: Conjuntos de entrenamiento (X_{train}, y_{train}), y prueba (X_{test}, y_{test});

Ensure: Modelo Gradient Boosting entrenado con los mejores hiperparámetros y métricas de evaluación.

- 1: Definir el espacio de búsqueda para hiperparámetros:
 - $learning_rate \in \{0.001, 0.01, 0.1\}$
 - $n_{estimators} \in \{50, 100, 200\}$
 - $max_depth \in \{3, 4, 5\}$
 - $min_samples_split \in \{2, 3, 4\}$
 - $random_state = 42$
 - 2: Crear un clasificador Gradient Boosting.
-

-
- 3: Ejecutar búsqueda en malla (GridSearchCV) con validación cruzada de 5 pliegues para encontrar la mejor combinación de hiperparámetros.
 - 4: Entrenar el modelo óptimo con los datos de entrenamiento (X_{train}, y_{train}).
 - 5: Usar el modelo entrenado para predecir etiquetas $\hat{y}$ sobre X_{test} .
 - 6: Calcular la precisión del modelo sobre los datos de prueba.
 - 7: Calcular métricas adicionales y generar un reporte de evaluación.
-

Salida: Modelo Gradient Boosting entrenado con los mejores hiperparámetros.

Código 4.4 Pseudocódigo de la función clasificadorGradientBoosting

Algoritmo 4 Clasificación con Red Neuronal usando búsqueda de cuadrícula

Require: Conjuntos de entrenamiento (X_{train}, y_{train}), y prueba (X_{test}, y_{test});

Ensure: Red neuronal entrenada con los mejores hiperparámetros y métricas de evaluación.

- 1: Definir la estructura del modelo (función `get_clf`):
 - 1.1 Crear una red neuronal secuencial.
 - 1.2 Agregar una capa densa de entrada con función de activación ReLU.
 - 1.3 Para cada capa oculta definida en *hidden_layer_sizes*:
 - Agregar capa densa con activación ReLU.
 - Agregar capa de abandono (Dropout) con tasa definida en *dropout*.
 - 1.4 Agregar capa de salida con activación sigmoidea (clasificación binaria).
 - 1.5 Compilar el modelo con función de pérdida *binary_crossentropy* y métrica *accuracy*.
- 2: Definir el espacio de búsqueda para hiperparámetros:
 - epochs* $\in \{5, 10, 20, 30\}$
 - batch_size* $\in \{16, 32, 64\}$
 - optimizer_lr* $\in \{0.001, 0.01, 0.05, 0.1\}$
 - hidden_layer_sizes* $\in \{(64), (64,32), (64,32,16), (64,32,16,8)\}$
 - dropout* $\in \{0, 0.25, 0.5\}$
 - opt* = {adam, sgd, rmsprop}
- 3: Construir un clasificador Keras mediante *KerasClassifier*, integrando *get_clf* como modelo base.
- 4: Ejecutar búsqueda en malla (GridSearchCV) con validación cruzada de 5 pliegues.
- 5: Entrenar el modelo óptimo con los datos de entrenamiento (X_{train}, y_{train}).
- 6: Usar el modelo entrenado para predecir etiquetas $\hat{y}$ sobre X_{test} .
- 7: Calcular la precisión del modelo sobre los datos de prueba y la mejor configuración.
- 8: Calcular métricas adicionales y generar un reporte de evaluación.

Salida: Red neuronal entrenada con la mejor arquitectura y configuración de entrenamiento.

Código 4.5 Pseudocódigo de la función clasificadorRN

Como se puede observar todas las funciones de los clasificadores siguen cierto patrón que comienza desde la configuración de varios hiperparámetros seguido de la ejecución de los algoritmos para posteriormente decidir cual tuvo los mejores resultados, los archivos de reporte que se mencionan registran los resultados de la matriz de confusión de los mejores modelos entrenados durante las iteraciones y las métricas de evaluación: Accuracy, recall, f1-score- PR-AUC y el coeficiente de correlación de Matthews.

Main

La función main (ver Código 4.6) se llama cuando se busca realizar el entrenamiento de todos los algoritmos en función de un archivo de datos previamente procesado y limpio, los resultados de los mismos quedan registrados en el archivo de reporte y esta estructura de código es especialmente útil con ciclos for para probar con diversos parámetros como multiclase, oversampling, etc.

Algoritmo 5 Ejecución principal de los clasificadores

Require: Archivo CSV de datos *archivo*, variable de control *ok*.

Ensure: Modelos entrenados y resultados almacenados en archivo de salida

- 1: Si *ok* = True entonces
 - 2: Abrir archivo en modo lectura binaria.
 - 3: Detectar la codificación del archivo usando *chardet*.
 - 4: Asignar la codificación detectada a la variable *codificacion*.
 - 5: Para cada par (etiqueta, método) en

$\{("RF", \text{clasificadorArboles}),$
 $("SVM", \text{clasificadorSVM}),$
 $("GB", \text{clasificadorGradientBoosting}),$
 $("NN", \text{ClasificadorRedNeuronal})\}$

hacer
 Intentar
 modelos[etiqueta] = método()
 Si ocurre error e
 imprimir "error en algoritmos: " + e
 Fin Intentar
 - 6: Abrir archivo resultados.txt en modo de escritura/apéndice.
 - 7: Para cada par (etiqueta, contenido) en resultado_dict:

Escribir la etiqueta y el contenido en el archivo de resultados.
-

8: Sino

Imprimir: “Error al crear el algoritmo, posiblemente hay muy pocas muestras en el dataset”

Salida: Modelos generados (según disponibilidad) y resultados guardados.

Código 4.6 Pseudocódigo de la función main

4.7.2 Evaluación del rendimiento de los algoritmos de aprendizaje automático

La efectividad de los modelos se evaluó con varias métricas, entre ellas: precisión (accuracy), exhaustividad (recall), F1-score, PR AUC (Área bajo la curva de Precisión-Recall) y MCC (coeficiente de correlación de Matthews) (Matthews 1975).

Estas métricas fueron seleccionadas debido a que ofrecen una visión más completa del rendimiento de los modelos, especialmente en situaciones con desequilibrio entre clases, como es el caso del presente estudio.

- Accuracy proporciona una medida general del número de predicciones correctas, pero puede ser engañosa en conjuntos desbalanceados.
- Recall es útil para evaluar cuántos de los casos positivos fueron correctamente identificados, lo cual es esencial en problemas de salud mental, donde la detección de casos es prioritaria.
- F1-score combina precisión y recall, lo que resulta especialmente relevante cuando se busca un equilibrio entre ambas.
- PR AUC se prefiere sobre ROC AUC en contextos desbalanceados, ya que evalúa la calidad del modelo al identificar positivos en proporciones realistas.
- MCC, por su parte, ofrece una medida robusta y balanceada del rendimiento del modelo, incluso cuando las clases tienen tamaños muy distintos, al considerar verdaderos y falsos positivos y negativos en su cálculo.

4.7.3 Resultados del entrenamiento y validación cruzada de los algoritmos

En la Tabla 4.15 se muestran los resultados de la ejecución de estos algoritmos tal como se define en el método main.

Tabla 4.15: Resultados de algoritmos de ML

Model	Accuracy		Recall		F1-score		PR-AUC	MCC
	Class 0	Class 1	Class 0	Class 1	Class 0	Class 1		
	0	1	0	1	0	1		
SVM	86%	83%	74%	83%	77%	79%	83%	0.57
RF	86%	83%	83%	87%	84%	85%	88%	0.69
MLP	81%	76%	74%	83%	77%	79%	83%	0.57
GB	95%	81%	78%	96%	86%	88%	89%	0.75

En la evaluación de los modelos de clasificación para la detección de depresión basada en características de seguimiento ocular, el modelo Gradient Boosting (GB) alcanzó el mayor valor de MCC con 0.75, lo que refleja su superior capacidad para clasificar correctamente tanto las clases positivas como las negativas. El coeficiente de correlación de Matthews (MCC) es especialmente útil en contextos donde existe un desbalance de clases, como en este caso, ya que considera verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos en una sola métrica equilibrada. A diferencia de métricas como la precisión, el MCC ofrece una medida más robusta del rendimiento real del modelo, incluso cuando una clase está sobrerrepresentada, lo que lo convierte en un indicador clave en problemas de clasificación binaria con distribución desigual.

El modelo Random Forest (RF), con un MCC de 0.69, le siguió de cerca, lo cual demostró también un rendimiento sólido. No obstante, mientras GB superó a RF en términos de MCC, el modelo RF logró una mayor precisión global, con un 84% frente al 82% de GB. Si bien la precisión (accuracy) representa el porcentaje de clasificaciones correctas en relación con el total de predicciones, puede resultar engañosa en conjuntos de datos desbalanceados. Por ejemplo, un modelo podría obtener una alta precisión simplemente al predecir siempre la clase mayoritaria. En este sentido, aunque RF muestra un mejor rendimiento general, GB tiene una ventaja al balancear la clasificación entre clases, lo cual es crucial para identificar correctamente a los participantes con posibles síntomas de depresión.

El análisis comparativo resalta que los métodos de ensamblado, como RF y GB, generalmente superan a los algoritmos individuales como SVM y MLP en esta tarea. Esto pone de manifiesto la ventaja de aprovechar múltiples árboles de decisión y técnicas de potenciación (boosting) para mejorar tanto la precisión como la sensibilidad de los modelos

en tareas sensibles como la detección de síntomas depresivos a partir de datos de seguimiento ocular. Además de MCC y precisión, se utilizaron otras métricas complementarias como recall, F1-score y área bajo la curva Precision-Recall (PR AUC), para garantizar una evaluación exhaustiva del desempeño de los modelos. Cada una de estas métricas ofrece una perspectiva distinta, que permite validar la capacidad de los modelos no solo para acertar en general, sino también para identificar adecuadamente los casos positivos, minimizar errores críticos como los falsos negativos, y ofrecer predicciones confiables incluso en condiciones de desbalance de clases.

4.7.4 Otros resultados

En esta sección se describen los experimentos de entrenamiento de los algoritmos de ML que utilizaron otros conjuntos de datos, con el objetivo de comparar los resultados finales con estas iteraciones preliminares de entrenamiento y prueba. Cabe destacar que estas pruebas fueron finalmente descartadas debido a su bajo desempeño o escasa capacidad de generalización.

Se utilizaron los conjuntos de datos `df_positivos.csv` y `df_negativos.csv`. Para estos se entrenaron los mismos algoritmos de ML supervisados que tomaron en cuenta un análisis de optimización de hiper parámetros con la misma metodología. En este caso los mejores hiperparámetros fueron:

- **Support Vector Machine (SVM):** El modelo alcanzó su mejor rendimiento con un parámetro de regularización $C = 20$, un kernel polinómico de grado 2, $\text{coef0} = 1$ y un valor de $\text{gamma} = 0.01$. Esta configuración permitió controlar de manera más estricta los errores de clasificación mediante un alto valor de C , al tiempo que el kernel de segundo grado capturó relaciones no lineales moderadas en los datos. El valor bajo de gamma evitó el sobreajuste al limitar la influencia de cada punto de datos en la frontera de decisión.
- **Random Forest (RF):** Los hiperparámetros óptimos fueron: `max_depth` sin restricción, `min_samples_leaf` = 4, `min_samples_split` = 10 y `n_estimators` = 10, con un `random_state` = 11 para garantizar la reproducibilidad. Esta configuración favoreció un modelo más conservador, con árboles menos profundos y nodos internos

más robustos, lo que ayudó a prevenir el sobreajuste a pesar del bajo número de árboles en el bosque.

- **Gradient Boosting (GB):** El mejor desempeño se obtuvo con una tasa de aprendizaje (`learning_rate`) = 0.001, `max_depth` = 3, `min_samples_split` = 2 y `n_estimators` = 50. Esta configuración permitió un entrenamiento lento y controlado, que favorece la generalización y evita el ajuste excesivo. A pesar del número reducido de árboles, el aprendizaje fue suficientemente preciso para captar patrones relevantes en los datos.
- **Multi Layer Perceptron (MLP):** El modelo de red neuronal obtuvo sus mejores resultados al implementar el optimizador 'adam', con 64 unidades en la primera y segunda capa oculta, y una inicialización de pesos mediante 'glorot_uniform', la cual promueve una mejor distribución inicial que facilita la convergencia del modelo. Esta arquitectura balanceó la capacidad de aprendizaje con una buena eficiencia computacional, logrando una adecuada representación de los datos sin caer en sobreajuste.

Después de un proceso de entrenamiento y validación que tomó al menos tres días, se obtuvieron los mejores resultados en términos del promedio de precisión para la tarea de clasificación. En esta fase, solo el conjunto de datos correspondiente a los estímulos negativos mostró un desempeño superior en cuanto a precisión durante la prueba inicial de clasificación. No obstante, al aplicar validación cruzada, su rendimiento se redujo drásticamente: el mayor porcentaje de precisión no superó el 43%, lo cual indica un desempeño inferior al de una clasificación aleatoria. La Tabla 4.16 presenta estos resultados en detalle.

Tabla 4.16: Resumen de los mejores desempeños para la clasificación de `df_negativos` y `df_positivos`

Algoritmo	Dataset	Filtro	Técnica	Balance	Precisión		Recall		f1-score		PR_AUC	Precisión CV
					clase 0	clase 1	clase 0	clase 1	clase 0	clase 1		
RF	negativos.csv	SD	BorderlineSMOTE	(18,18)	100	80	75	100	86	89	90	36
RF	negativos.csv	SD	SVMSMOTE	(18,18)	100	80	75	100	86	89	90	33
SVM	negativos.csv	SD	SVMSMOTE	(18,18)	100	80	75	100	86	89	90	43

RF	negativos.csv	SD	KMeansSmote	(19,19)	100	80	75	100	86	89	90	33
----	---------------	----	-------------	---------	-----	----	----	-----	----	----	----	----

Cabe destacar que la clasificación multiclase no arrojó resultados satisfactorios, por lo que se decidió descartarla en etapas tempranas del análisis. Además, todos los mejores desempeños se obtuvieron al utilizar conjuntos de datos que incluían únicamente vectores correspondientes a participantes con diagnóstico exclusivo de depresión, es decir, sin etiquetas asociadas a ansiedad o estrés. Esta decisión redujo significativamente el número de muestras disponibles, lo que impactó la capacidad de generalización de los modelos.

Aunque la precisión fue alta en la mayoría de los casos durante la fase de entrenamiento, los valores obtenidos mediante validación cruzada mostraron una disminución considerable. Esto sugiere que los clasificadores no generalizan adecuadamente ante nuevos datos, lo cual limita su aplicabilidad en escenarios reales.

El problema de clasificación y propuesta de modelo de ensamble

Como se evidenció en el análisis preliminar de los primeros conjuntos de datos, no se identificaron diferencias estadísticamente significativas entre las muestras correspondientes a individuos con puntajes DASS-21 indicativos de sintomatología depresiva y aquellas que no cumplían con dicho criterio. Esta ausencia de distinción clara entre ambas categorías representó una limitación importante para los modelos de clasificación iniciales, reduciendo su capacidad para discriminar de manera efectiva entre los dos grupos. Ante este desafío, se consideró pertinente explorar estrategias adicionales que permitieran optimizar el desempeño del sistema de clasificación.

Una de las estrategias implementadas fue la integración de un enfoque de aprendizaje por ensamble. Este método consiste en la combinación de múltiples clasificadores individuales, cuya finalidad es generar una predicción conjunta que supere en rendimiento a la de cualquier modelo considerado de forma aislada. El principio subyacente en este tipo de enfoques es que la agregación de distintos modelos, cada uno con sus propias fortalezas y limitaciones, puede ofrecer una mayor robustez y precisión en la tarea de clasificación. En este caso específico, la decisión final del sistema de ensamble se determina a partir de una votación ponderada de las predicciones generadas por cada clasificador integrante.

Un ejemplo representativo de algoritmo de ensamble es el Random Forest (RF), el cual combina múltiples árboles de decisión entrenados sobre subconjuntos aleatorios de los datos y características. Su predicción final se obtiene mediante votación mayoritaria, lo que mejora la precisión y reduce el riesgo de sobreajuste en comparación con modelos individuales.

Para llevar a cabo esta propuesta, se diseñó e implementó la clase clasificadorEnsamble, cuyo código se presenta a continuación (ver Código 4.7).

Algoritmo 6 Clasificación por Ensamble Ponderado

Require: Lista de clasificadores base *classifiers*, pesos asociados *weights*, datos de entrada *X*, etiquetas *y*

Ensure: Predicción binaria basada en la combinación ponderada de los clasificadores entrenados.

Fase de Entrenamiento (fit)

- 1: Para cada clasificador $clf \in classifiers$
 Entrenar clf con los datos (X, y)
 Fin Para

Fase de Predicción (predict)

- 2: Si *weights* es *None*
 Lanzar excepción: “Ingresa los pesos de cada clasificador”
- 3: Si $|weights| \neq |classifiers|$
 Lanzar excepción: “# de pesos != al número de clasificadores”
- 4: Si $\sum weights \neq 1.0$
 Lanzar excepción: “el total del peso debe ser igual a 1.0”
- 5: Inicializar lista *predictions*
- 6: Para cada clasificador $clf \in classifiers$
 agregar $clf.predict(X)$ a *predictions*
 Fin Para
- 7: Calcular *weighted_predictions* como:

$$\sum_{i=1}^n w_i \cdot p_i$$
 donde:
 $w_i \in weights$
 $p_i \in predictions$
- 8: Retornar vector binario donde:
 $output_j = 1$ si $weighted_prediction_j \geq 0.05$,
 0 en otro caso.

Salida: Vector de predicciones binarias ensambladas.

Código 4.7 Pseudocódigo de la clase clasificadorEnsamble

Para entrenar el clasificador de ensamble, se emplearon todos los modelos individuales previamente evaluados. A cada uno se le asignó un peso proporcional a su rendimiento medido por la métrica F1-score (36), calculada como:

$$f1 = 2 \times \left(\frac{\text{precisión} \times \text{recall}}{\text{precisión} + \text{recall}} \right) \quad (36)$$

Los resultados obtenidos por este modelo de ensamble se presentan en la Tabla 4.17, donde se muestra su desempeño sobre los mismos conjuntos de datos utilizados para los clasificadores individuales:

Tabla 4.17: Resumen de los conjuntos de datos utilizados para las pruebas de clasificación con el clasificadorEnsamble

Algoritmo	Dataset	Filtro	Técnica	Balance	Precisión		Recall		f1-score		PR_AUC	Precisión CV
					clase 0	clase 1	clase 0	clase 1	clase 0	clase 1		
E	negativos.csv	SD	BorderlineSMOTE	(18,18)	100	80	75	100	86	89	90	28
E	negativos.csv	SD	SVMSMOTE	(18,18)	100	80	75	100	86	89	90	32
E	negativos.csv	SD	KMeansSmote	(19,19)	100	80	75	100	86	89	90	40
E	Evento6stats.csv	SD	BorderlineSMOTE	(21,21)	100	80	80	100	89	89	90	54
E	Evento6stats.csv	SD	SMOTE	(21,21)	80	75	80	75	80	75	80	60
E	Evento6stats.csv	SD	SVMSMOTE	(21,21)	100	67	60	100	75	80	83	54
E	Evento9stats.csv	SD	SMOTETomek	(13,13)	75	100	100	67	86	80	91	30
E	Evento9stats.csv	SD	SMOTE	(21,21)	100	71	50	100	67	83	85	43
E	Evento9stats.csv	SD	BorderlineSMOTE	(21,21)	60	50	60	50	60	50	61	49
E	Evento9stats.csv	SD	SVMSMOTE	(21,20)	60	50	60	50	60	50	61	49
E	Evento9stats.csv	SD	KMeansSmote	(21,22)	80	75	80	75	80	75	80	28

Se observa que el algoritmo de ensamble logró una ligera mejora en la precisión y en el F1-score con respecto a los clasificadores individuales, particularmente en los conjuntos con técnicas de sobremuestreo como BorderlineSMOTE y SVM SMOTE. No obstante, al aplicar validación cruzada, los valores de precisión decrecen de manera considerable, lo que indica que el modelo aún no logra una buena capacidad de generalización.

Aunque la propuesta del clasificador de ensamble permitió mejorar ligeramente los resultados obtenidos con los modelos individuales, los resultados continúan limitados y reflejan la complejidad del problema de clasificación en este dominio. Se requieren conjuntos de datos más discriminativos y posiblemente el uso de técnicas adicionales de extracción de características o normalización para mejorar la estabilidad y robustez de los modelos predictivos.

Capítulo 5. Discusión

Este estudio resalta el potencial de las métricas de seguimiento ocular, combinadas con algoritmos de ML supervisado, como herramientas efectivas para identificar síntomas depresivos en población joven. Los resultados obtenidos abren nuevas posibilidades para el desarrollo de tecnologías diagnósticas innovadoras en el ámbito de la salud mental, particularmente en escenarios de detección temprana y no invasiva.

Durante el análisis de las características derivadas del seguimiento ocular, no todas las métricas mostraron diferencias estadísticamente significativas entre los jóvenes con síntomas depresivos y los controles sanos. A través de pruebas estadísticas U-Test, se evaluó la relevancia de cada métrica y estímulo, los resultados muestran que solo ciertos indicadores, dependientes del tipo de estímulo emocional presentado, permitieron distinguir entre ambos grupos. Esta variabilidad subraya la importancia de una cuidadosa selección tanto de métricas como de estímulos durante el diseño experimental. Además, se identificó que el contexto de las imágenes emocionales juega un papel fundamental, especialmente en población joven, debido a posibles diferencias culturales que afectan la percepción y reacción emocional ante determinados contenidos visuales.

Inicialmente, se intentó generalizar el comportamiento ocular mediante conjuntos de datos derivados de la observación de estímulos negativos y positivos. No obstante, los resultados obtenidos con estas configuraciones fueron deficientes y en un esfuerzo por mejorar los resultados, se desarrolló un algoritmo de clasificación por ensamble, que combinó las decisiones de varios clasificadores individuales ponderados según su f1-score. Aunque esta estrategia logró una ligera mejora en precisión sobre los conjuntos de datos utilizados, la validación cruzada reveló un rendimiento inconsistente, lo cual indica que el modelo aún no generalizaba adecuadamente.

Esto motivó el rediseño del conjunto de datos con técnicas adicionales como el balanceo con SMOTE y la filtración por etiquetas específicas, logrando así una mejora significativa en el desempeño de los modelos.

Aunque estudios previos han documentado la relación entre el comportamiento ocular y la depresión en adultos, existe aún poca investigación centrada en adolescentes. Nuestros hallazgos sugieren que algunos patrones, como la duración de fijaciones y la velocidad de sacadas, también presentan diferencias significativas en jóvenes con síntomas depresivos, lo

cual respalda la hipótesis de que los mecanismos cognitivos y atencionales vinculados a la depresión pueden manifestarse de forma similar en distintas etapas del desarrollo. Sin embargo, en investigaciones con niños, los resultados han sido mixtos: mientras Gibb et al., (2016) observaron evitación de estímulos negativos en hijos de madres con depresión, Platt et al., (2022) no encontraron una correlación clara entre síntomas depresivos y pruebas de atención en niños en riesgo. Estas diferencias podrían explicarse por factores genéticos o por la etapa de desarrollo, como argumenta Owens et al., (2016), lo cual refuerza la necesidad de seguir la investigación sobre cómo varían estos procesos en diferentes edades.

Desde el punto de vista computacional, el estudio empleó algoritmos clásicos de ML supervisado para procesar características numéricas derivadas del comportamiento visual. Random Forest (RF) fue el modelo con mejor desempeño, este alcanzó una precisión promedio del 84% tanto en la clase depresiva como en la sana, seguido por SVM, Gradient Boosting (GB) y una red neuronal de tipo MLP. Algunos modelos, sin embargo, mostraron mayor eficacia al clasificar a los participantes sanos, un factor relevante en escenarios donde se busca minimizar falsos positivos.

A pesar de que se utilizaron únicamente características numéricas, el seguimiento ocular tiene un gran potencial para generar representaciones visuales del comportamiento, como mapas de calor. Estas representaciones pueden convertirse en espectrogramas y usarse como entrada para modelos de aprendizaje profundo, como redes neuronales convolucionales (CNN), lo que permitiría capturar patrones espaciales y temporales más complejos que podrían mejorar la capacidad de detección de los síntomas depresivos.

Una de las aplicaciones prácticas más prometedoras derivadas de este estudio es el desarrollo de una herramienta de apoyo al diagnóstico basada en web. Actualmente, esta herramienta requiere el uso del sensor de seguimiento ocular GP3 HD; sin embargo, se contempla la implementación de tecnologías de visión por computadora que permitan capturar métricas oculares con cámaras web convencionales. Esta adaptación haría el software mucho más accesible, práctico y económico en entornos clínicos y escolares con recursos limitados.

Desde una perspectiva teórica, este trabajo respalda la viabilidad del uso de métricas de seguimiento ocular como indicadores confiables de depresión. En términos prácticos, clínicas, escuelas y otros entornos de atención a jóvenes podrían incorporar estas tecnologías

para facilitar la detección temprana de síntomas depresivos, contribuyendo así a una atención más oportuna, eficiente y basada en evidencia.

No obstante, el uso de estas tecnologías plantea importantes consideraciones éticas. La recopilación de datos biométricos sensibles, como los movimientos oculares, implica riesgos relacionados con la privacidad, ya que los participantes pueden no ser plenamente conscientes del nivel de información que se puede inferir sobre su salud mental. El consentimiento informado es fundamental para asegurar una participación ética, así como la claridad respecto al uso, almacenamiento y protección de la información. Además, debe evitarse la aplicación de estas tecnologías en contextos inadecuados, como ambientes laborales o aseguradoras, donde podrían generar discriminación o estigmatización. Por tanto, se requiere un enfoque ético, responsable y centrado en el bienestar del usuario para el desarrollo y la implementación de estas herramientas.

Capítulo 6. Conclusiones y trabajos futuros

A partir del desarrollo de esta investigación, se concluye que es factible proponer un modelo computacional basado en patrones de comportamiento ocular que permite detectar síntomas de depresión clínica, pues se puede aportar una herramienta de apoyo para los profesionales de la salud mental, en especial para psiquiatras encargados de la evaluación y el seguimiento de pacientes con este trastorno.

Entre los principales logros destacan:

- La construcción de un conjunto de datos original de seguimiento ocular, obtenido mediante la interacción de participantes con y sin diagnóstico clínico de depresión, expuestos a estímulos emocionales validados internacionalmente. Este conjunto de datos constituye un insumo relevante para investigaciones futuras en el área de salud mental y visión computacional.
- La identificación de patrones oculares asociados a niveles de depresión, como menor número de fijaciones, mayor duración de las mismas, reducción de la amplitud sacádica y cambios en la frecuencia de parpadeo, métricas que correlacionaron con los puntajes obtenidos en la escala DASS-21.
- La evaluación y comparación de distintos algoritmos de ML, entre los cuales el modelo de Random Forest (RF) logró la mayor precisión (84%) para clasificar participantes con base en sus métricas de seguimiento ocular, esto demostró el potencial de estas herramientas en aplicaciones de salud mental.
- La implementación de un sistema funcional y adaptable, que integra el modelo computacional y puede ser utilizado en entornos clínicos, educativos o laborales como un instrumento de tamizaje no invasivo para detectar síntomas depresivos y realizar un seguimiento del estado emocional.

Además, los resultados obtenidos refuerzan la viabilidad de emplear tecnología de seguimiento ocular combinada con inteligencia artificial como una alternativa objetiva, accesible y no intrusiva para la detección temprana de trastornos mentales, en particular la depresión, que representa una de las principales causas de discapacidad y afectación cognitiva en jóvenes.

No obstante, esta investigación también puso de manifiesto algunas limitaciones, principalmente el tamaño y diversidad de la muestra, aspectos que limitan la generalización

de los resultados. Por ello, futuros trabajos deberán considerar muestras más amplias y representativas, así como la implementación de técnicas avanzadas de selección de características que permitan mejorar aún más el desempeño de los modelos clasificadores.

Finalmente, se concluye que la incorporación de tecnologías como el eye-tracking en entornos clínicos, escolares o laborales podría transformar la forma en que se monitorean y detectan síntomas depresivos, lo cual puede permitir intervenciones tempranas y personalizadas. Este enfoque interdisciplinario, que combina ciencia de datos, psicología y tecnología, tiene el potencial de contribuir significativamente al bienestar emocional de las personas y al fortalecimiento de los servicios de salud mental.

6.1 Aportaciones

A continuación, se describen las principales aportaciones del proyecto desarrollado.

6.1.1 Software

Se desarrolló una herramienta computacional de apoyo al diagnóstico temprano de síntomas depresivos en población joven, denominada UXLite/QuxBox. Esta herramienta permite el registro y análisis de métricas oculares derivadas de la exposición a estímulos visuales emocionales. Actualmente, el sistema se implementa mediante un sensor GP3 HD de seguimiento ocular, sin embargo, su arquitectura fue diseñada con la posibilidad de adaptarse a sistemas de visión por computadora convencionales que empleen cámaras web. Esta adaptación futura permitiría ampliar su uso de forma más accesible, económica y no invasiva, lo cual facilita su implementación en entornos clínicos y educativos.

Además, se tiene un registro ante el registro público del derecho al autor (INDAUTOR) que protege el código de QUXBox como programa de computación (ver Anexo 8).

6.1.2 Métodos

Se propuso una metodología integral que combina el uso de estímulos visuales controlados, la extracción de métricas oculares relevantes y el empleo de algoritmos clásicos de ML

supervisado, como Random Forest (RF), Support Vector Machines (SVM), Gradient Boosting (GB) y redes neuronales multicapa (MLP). Esta metodología puede ser aplicada a cualquier tipo de estudio que recolecte información del comportamiento humano a través de sensores biométricos o fisiológicos ya que estandariza la inducción emocional con el tipo de estímulos y el tiempo de exposición y los instrumentos que miden el estado de la salud mental de los participantes sin depender de obtener datos personales.

Adicionalmente, se diseñó un clasificador de ensamble ponderado que combina la salida de múltiples algoritmos según su desempeño, el cual mejora levemente la precisión de clasificación, aunque con limitaciones en la generalización. También se realizó un análisis estadístico (U-Test) para seleccionar métricas discriminantes y estimular un diseño experimental más preciso.

6.1.3 Publicaciones

Durante toda la investigación se realizaron las siguientes publicaciones en congresos y revistas, a continuación, se presenta el título de las publicaciones y un breve resumen del contenido:

- Patrones de comportamiento ocular durante inducción emocional en diferentes intensidades (Lagunes-Ramírez, Gonzáles-Serna, y Rivera-Rivera 2021): Este estudio analizó datos de seguimiento ocular de usuarios que participaron en un proceso de inducción emocional en un entorno de laboratorio. El objetivo fue obtener información útil para aplicaciones de computación afectiva mediante sensores de seguimiento ocular. Los datos se recopilaron a través de un sensor infrarrojo y la plataforma de grabación multimodal UXLab. Los participantes fueron expuestos a estímulos emocionales clasificados como positivos, neutros y negativos. El estudio identificó ciertos patrones de comportamiento vinculados al tipo de estímulo presentado, concluyendo que el seguimiento ocular puede proporcionar información relevante para aplicaciones de computación afectiva que consideren el contexto del usuario, como las emociones.

- Un vistazo más profundo a la visualización de datos del seguimiento ocular (Lagunes-Ramírez, Gonzáles-Serna, y Rivera-Rivera 2022): Este artículo revisa técnicas comunes para la visualización de datos de seguimiento ocular, haciendo énfasis en análisis visuales como mapas de calor (heatmaps), rutas de exploración visual (scanpaths) y áreas de interés (AOI). Estos métodos son fundamentales para interpretar los datos de movimientos oculares y comprender los patrones de atención visual.
- Validación de la escala de valencia para repositorios de imágenes emocionales en poblaciones de adultos jóvenes mexicanos (Lagunes-Ramírez et al., 2023): Este estudio analizó la evaluación de imágenes de dos repositorios de imágenes emocionales (IAPS y OASIS) en una población de adultos jóvenes mexicanos. La comparación mostró similitudes con los estudios originales, pero también reveló sesgos en la recepción de algunos estímulos negativos y neutros, posiblemente debido a diferencias temporales, generacionales y culturales. El estudio recomienda considerar estos factores al seleccionar imágenes y repositorios para futuras investigaciones.
- Comportamiento de la mirada y análisis mediante aprendizaje automático de la depresión en la juventud: una revisión sistemática (Lagunes-Ramírez et al., 2024): Esta revisión sistemática tuvo como objetivo comprender la relación entre el comportamiento ocular y la depresión en personas jóvenes, con aplicaciones en ML. Se revisaron estudios que analizaron el comportamiento visual en individuos con síntomas depresivos, se identificaron patrones oculares asociados a trastornos mentales. Los hallazgos sugieren que la tecnología de seguimiento ocular puede ser una herramienta útil para apoyar el diagnóstico y la prevención de la depresión en la juventud.
- Through the Youth Eyes: Training Depression Detection Algorithms with Eye Tracking Data (Lagunes-Ramírez et al., 2025): Este artículo aborda el entrenamiento de algoritmos de detección de depresión que utilizan datos de seguimiento ocular, se destaca el potencial del análisis de movimientos oculares para identificar síntomas depresivos en poblaciones jóvenes.

6.2 Trabajos futuros

Uno de los pasos siguientes más relevantes consiste en realizar pruebas de campo con la herramienta UXLite/QuxBox, mientras se emplean muestras más representativas de población joven en contextos reales, para posteriormente validar su desempeño con pacientes diagnosticados clínicamente. Esto permitirá evaluar la precisión del sistema en condiciones fuera del laboratorio y refinar sus modelos de predicción con nuevos datos.

Adicionalmente, se debe considerar incorporar técnicas de aprendizaje profundo basadas en representaciones visuales del comportamiento ocular. Si bien inicialmente se propuso el uso de redes neuronales convolucionales (CNN) como parte del enfoque predictivo, esta idea fue descartada temporalmente durante el análisis de datos, debido a que este tipo de modelos requiere grandes volúmenes de datos para ser efectivos. Diversos estudios sugieren la necesidad de contar con miles de registros por clase, mientras que en el presente trabajo el tamaño del conjunto de datos recolectado es limitado (aproximadamente 130 registros en algunos casos).

No obstante, se contempla que en futuros trabajos se podría utilizar la información ocular recolectada para generar representaciones visuales como mapas de calor y convertirlas en espectrogramas, que sí podrían aprovechar la capacidad de generalización de las CNN. Esta vía permitiría aprovechar los beneficios del aprendizaje profundo para mejorar la precisión y robustez del sistema.

Asimismo, será necesario seguir la refinación de la selección de estímulos visuales utilizados, ya que se debe tener en cuenta su contenido emocional y el contexto sociocultural de la población objetivo, ya que los significados y respuestas a ciertas imágenes pueden variar considerablemente entre grupos culturales.

Capítulo 7. Referencias

- Al-gawwam, Sarmad, and Mohammed Benaissa. 2018. "Depression Detection From Eye Blink Features." Pp. 388–92 in *2018 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*. IEEE.
- Alejandres Sanchez, Hugo. 2016. "Evaluación Centrada En El Usuario de Sistemas de Recomendación Sensibles Al Contexto: Efecto de Interfaces Multimodales Interactivas y Esquemas de Explicación En La Experiencia Del Usuario."
- Alghowinem, Sharifa, Roland Goecke, Michael Wagner, Julien Epps, Matthew Hyett, Gordon Parker, and Michael Breakspear. 2018. "Multimodal Depression Detection: Fusion Analysis of Paralinguistic, Head Pose and Eye Gaze Behaviors." *IEEE Transactions on Affective Computing* 9(4):478–90. doi: 10.1109/TAFFC.2016.2634527.
- Alghowinem, Sharifa, Roland Goecke, Michael Wagner, Gordon Parker, and Michael Breakspear. 2013. "Eye Movement Analysis for Depression Detection." Pp. 4220–24 in *2013 IEEE International Conference on Image Processing*. IEEE.
- Andrade Perez, Delia Marlen. 2023. "Método Para Cartografiar Mapas de Calor Emocionales Mediante La Fusión de Datos de Seguimiento Ocular y Datos de Valencia/Activación." Centro Nacional de Investigación y Desarrollo Tecnológico.
- APA. 2013. *Diagnostic and Statistical Manual of Mental Disorders (5th Ed.)*. Washington, DC: APA.
- Arai, Kohei. 2015. "Relations between Psychological Status and Eye Movements." *International Journal of Advanced Research in Artificial Intelligence* 4(6). doi: 10.14569/IJARAI.2015.040603.
- Arana Llanes, Julia Yazmin. 2020. "Explotación de Estados Cognitivos En Entornos E-Learning a Partir de BCI No Invasivas." Centro Nacional de Investigación y Desarrollo Tecnológico.
- Armitage, R. 2007. "Sleep and Circadian Rhythms in Mood Disorders." *Acta Psychiatrica Scandinavica* 115(s433):104–15.
- Armstrong, Thomas, and Bunmi O. Olatunji. 2012. "Eye Tracking of Attention in the Affective Disorders: A Meta-Analytic Review and Synthesis." *Clinical Psychology Review* 32(8):704–23. doi: 10.1016/j.cpr.2012.09.004.
- Banuelos Lozoya, Edgar Omar. 2023. "Metodología Para Complementar La Evaluación de

- UX Interpretando La Carga de Trabajo a Partir de Datos Fisiológicos de Los Usuarios.” Centro Nacional de Investigación y Desarrollo Tecnológico.
- Beck, Aaron T., Robert A. Steer, and Gregory K. Brown. 1996. *BDI-II, Beck Depression Inventory: Manual*. San Antonio, TX: The Psychological Corporation.
- Begić, Dražen, Vesna Popović-Knapić, Jasmina Grubisin, Biljana Kosanović Rajačić, Igor Filipčić, Irma Telarović, and Miro Jakovljević. 2011. “Quantitative Electroencephalography in Schizophrenia and Depression.” *Psychiatria Danubina* 23:355–62.
- Bergstrom, J. R., and A. Schall. 2014. *Eye Tracking in User Experience Design*. Maarssen, Netherlands: Elsevier Gezondheidszorg.
- Bodenschatz, Charlott Maria, Marija Skopinceva, Theresa Ruß, Anette Kersting, and Thomas Suslow. 2020. “Face Perception without Subjective Awareness – Emotional Expressions Guide Early Gaze Behavior in Clinically Depressed and Healthy Individuals.” *Journal of Affective Disorders* 265:91–98. doi: 10.1016/j.jad.2020.01.039.
- Bodenschatz, Charlott Maria, Marija Skopinceva, Theresa Ruß, and Thomas Suslow. 2019. “Attentional Bias and Childhood Maltreatment in Clinical Depression - An Eye-Tracking Study.” *Journal of Psychiatric Research* 112:83–88. doi: 10.1016/j.jpsychires.2019.02.025.
- Borys, Magdalena, and Plechawska-Wójcik Małgorzata. 2017. “Eye-Tracking Metrics in Perception and Visual Attention Research.” *European Journal of Medical Technologies* 3(16):11–23.
- Burkhouse, Katie L., Max Owens, Cope Feurer, Effua Sosoo, Anastacia Kudinova, and Brandon E. Gibb. 2017. “Increased Neural and Pupillary Reactivity to Emotional Faces in Adolescents with Current and Remitted Major Depressive Disorder.” *Social Cognitive and Affective Neuroscience* 12(5):783–92. doi: 10.1093/scan/nsw184.
- Burkhouse, Katie L., Greg J. Siegle, Mary L. Woody, Anastacia Y. Kudinova, and Brandon E. Gibb. 2015. “Pupillary Reactivity to Sad Stimuli as a Biomarker of Depression Risk: Evidence from a Prospective Study of Children.” *Journal of Abnormal Psychology* 124(3):498–506. doi: 10.1037/abn0000072.
- CASIA. 2005. “CASIA Iris Image Database Version 3.0 (CASIA-IrisV3).”
- Cerecero-García, Diego, Fernando Macías-González, Tania Arámburo-Muro, and Sergio

- Bautista-Arredondo. 2020. “Síntomas Depresivos y Cobertura de Diagnóstico y Tratamiento de Depresión En Población Mexicana.” *Salud Pública de México* 62(6, Nov-Dic):840–50. doi: 10.21149/11558.
- Chen, Siyuan, Julien Epps, Natalie Ruiz, and Fang Chen. 2011. “Eye Activity as a Measure of Human Mental Effort in HCI.” P. 315 in *Proceedings of the 15th international conference on Intelligent user interfaces - IUI '11*. New York, New York, USA: ACM Press.
- Cuevas Chavez, Patricia Alejandra. 2020. “Detección Automática de Ansiedad a Través Del Monitoreo de Sensores Vestibles.” Centro Nacional de Investigación y Desarrollo Tecnológico.
- Davidson, R. J. 2004. “Well-Being and Affective Style: Neural Substrates and Biobehavioural Correlates.” *Philosophical Transactions of the Royal Society B: Biological Sciences* 359(1449):1395–1411. doi: 10.1098/rstb.2004.1510.
- Derrickson, Bryan, and Gerard J. Tortora. 2006. *Principios de Anatomía y Fisiología*. 11th ed. edited by Editorial Médica Panamericana S.A. México.
- Ding, Xinfang, Xinxin Yue, Rui Zheng, Cheng Bi, Dai Li, and Guizhong Yao. 2019. “Classifying Major Depression Patients and Healthy Controls Using EEG, Eye Tracking and Galvanic Skin Response Data.” *Journal of Affective Disorders* 251:156–61. doi: 10.1016/j.jad.2019.03.058.
- Disner, S. G., C. G. Beevers, E. A. Haigh, and A. T. Beck. 2011. “Neural Mechanisms of the Cognitive Model of Depression.” *Nature Reviews Neuroscience* 12(8):467–77. doi: 10.1038/nrn3027.
- Duchowski, Andrew T., Margaux M. Price, Miriah Meyer, and Pilar Orero. 2012. “Aggregate Gaze Visualization with Real-Time Heatmaps.” Pp. 13–20 in *Proceedings of the Symposium on Eye Tracking Research and Applications*. New York, NY, USA: ACM.
- Eisenlohr-Moul, T. A., S. S. Girdler, K. M. Schmalenberger, D. N. Dawson, and P. Surana. 2017. “The Association of Premenstrual Dysphoric Disorder with Suicidality and Major Depression.” *Journal of Affective Disorders* 208:1–7.
- Farnsworth, Bryn. 2016. “What Is Eye Tracking and How Does It Work?”
- Fava, M., and K. S. Kendler. 2000. “Major Depressive Disorder.” *Neuron* 28(2):335–41.
- Figueiredo, G. R., W. L. Ripka, E. F. R. Romanelli, and L. Ulbricht. 2019. “Attentional Bias

- for Emotional Faces in Depressed and Non-Depressed Individuals: An Eye-Tracking Study.” Pp. 5419–22 in *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE.
- Fouilloux Quiroz, David Eduardo. 2018. “Método Para Integrar y Sincronizar Datos EEG y Multimedia Para Su Aplicación En El Proceso de Evaluación de La Experiencia Del Usuario.” Centro Nacional de Investigación y Desarrollo Tecnológico.
- Fredrickson, B. L. 2001. “The Role of Positive Emotions in Positive Psychology: The Broaden-and-Build Theory of Positive Emotions.” *American Psychologist* 56(3):218–26. doi: 10.1037/0003-066X.56.3.218.
- Fredrickson, B. L., and T. Joiner. 2002. “Positive Emotions Trigger Upward Spirals toward Emotional Well-Being.” *Psychological Science* 13(2):172–75. doi: 10.1111/1467-9280.00431.
- Fuhl, Wolfgang, Thomas Kuebler, Hanna Brinkmann, Raphael Rosenberg, Wolfgang Rosenstiel, and Enkelejda Kasneci. 2018. “Region of Interest Generation Algorithms for Eye Tracking Data.” Pp. 1–9 in *Proceedings of the 3rd Workshop on Eye Tracking and Visualization*. New York, NY, USA: ACM.
- Galindo-Vázquez, Oscar, Mónica Ramírez-Orozco, Rosario Costas-Muñiz, Luis A. Mendoza-Contreras, Germán Calderillo-Ruiz, and Abelardo Meneses-García. 2020. “Síntomas de Ansiedad, Depresión y Conductas de Autocuidado Durante La Pandemia de COVID-19 En La Población General.” *Gaceta de México* 156(4). doi: 10.24875/GMM.20000266.
- Garcia Pinzon, Gabriel Alejandro. 2020. “Procesamiento de Datos Fisiológicos Para Detectar Estados Emocionales En El Proceso de Evaluación de La Experiencia de Usuario.” Centro Nacional de Investigación y Desarrollo Tecnológico.
- Garcia, Sarah E., Sara M. S. Francis, Erin B. Tone, and Erin C. Tully. 2019. “Understanding Associations between Negatively Biased Attention and Depression and Social Anxiety: Positively Biased Attention Is Key.” *Anxiety, Stress, & Coping* 32(6):611–25. doi: 10.1080/10615806.2019.1638732.
- Gavrilescu, Mihai, and Nicolae Vizireanu. 2019. “Predicting Depression, Anxiety, and Stress Levels from Videos Using the Facial Action Coding System.” *Sensors* 19(17):3693. doi: 10.3390/s19173693.

- Gerdes, Antje B. M., Georg W. Alpers, Hanna Braun, Sabrina Köhler, Ulrike Nowak, and Lisa Treiber. 2020. “Emotional Sounds Guide Visual Attention to Emotional Pictures: An Eye-Tracking Study with Audio-Visual Stimuli.” *Emotion*. doi: 10.1037/emo0000729.
- Gibb, Brandon E., Seth D. Pollak, Greg Hajcak, and Max Owens. 2016. “Attentional Biases in Children of Depressed Mothers: An Event-Related Potential (ERP) Study.” *Journal of Abnormal Psychology* 125(8):1166–78. doi: 10.1037/abn0000216.
- Girden, Ellen R. 1992. *ANOVA: Repeated Measures*. Sage.
- Godara, Malvika, Alvaro Sanchez-Lopez, and Rudi De Raedt. 2019. “Music to My Ears, Goal for My Eyes? Music Reward Modulates Gaze Disengagement from Negative Stimuli in Dysphoria.” *Behaviour Research and Therapy* 120:103434. doi: 10.1016/j.brat.2019.103434.
- González, David Andrés, Areli Reséndiz, and Isabel Reyes. 2015. “Adaptation of the BDI–II in Mexico.” *Salud Mental* 38(4):237–44. doi: 10.17711/SM.0185-3325.2015.033.
- González Franco, Nimrod. 2017. “Metodología UXEeg Para La Evaluación de La Experiencia Del Usuario En Personas Con Discapacidad a Partir de Interfaces Cerebro Computadora.”
- Gotlib, I. H., and J. Joormann. 2010. “Cognition and Depression: Current Status and Future Directions.” *Annual Review of Clinical Psychology* 6:285–312. doi: 10.1146/annurev.clinpsy.121208.131305.
- Greimel, E., C. Piechaczek, M. Schulte-Rüther, L. Feldmann, and G. Schulte-Körne. 2020. “The Role of Attentional Deployment during Distancing in Adolescents with Major Depression.” *Behaviour Research and Therapy* 126:103554. doi: 10.1016/j.brat.2020.103554.
- Guo, Fu, Yi Ding, Weilin Liu, Chang Liu, and Xuefeng Zhang. 2016. “Can Eye-Tracking Data Be Measured to Assess Product Design?: Visual Attention Mechanism Should Be Considered.” *International Journal of Industrial Ergonomics* 53:229–35. doi: 10.1016/j.ergon.2015.12.001.
- Hamilton, J. P., G. Chen, M. E. Thomason, M. E. Schwartz, and I. H. Gotlib. 2012. “Neural Systems Approaches to Understanding Major Depressive Disorder: An Intrinsic Functional Organization Perspective.” *Neurobiology of Disease* 52:4–11. doi:

- 10.1016/j.nbd.2012.01.015.
- Hamilton, M. 1960. "A RATING SCALE FOR DEPRESSION." *Journal of Neurology, Neurosurgery & Psychiatry* 23(1):56–62. doi: 10.1136/jnnp.23.1.56.
- Henry, Julie D., and John R. Crawford. 2005. "The Short-Form Version of the Depression Anxiety Stress Scales (DASS-21): Construct Validity and Normative Data in a Large Non-Clinical Sample." *British Journal of Clinical Psychology* 44(2):227–39. doi: 10.1348/014466505X29657.
- Hernandez Perez, Luis Alfredo. 2022. "Método Para La Detección de Emociones Mediante El Análisis de Expresión Facial En Videos de Evaluación de La Experiencia de Usuario." Centro Nacional de Investigación y Desarrollo Tecnológico.
- Ho, Hong-Fa. 2014. "The Effects of Controlling Visual Attention to Handbags for Women in Online Shops: Evidence from Eye Movements." *Computers in Human Behavior* 30:146–52. doi: 10.1016/j.chb.2013.08.006.
- Holmqvist, Kenneth, Marcus Nyström, Richard Andersson, Richard Dewhurst, Jarodzka Halszka, and Joost van de Weijer. 2011. *Eye Tracking: A Comprehensive Guide to Methods and Measures*. United Kingdom: Oxford University Press.
- Holzman, P. S., and S. Mehrotra. 2019. "Eye Tracking as a Tool for Understanding Depression: A Systematic Review." *Journal of Affective Disorders* 245:493–502.
- Isaac, L., R. W. Buchanan, and J. K. Gollan. 2020. "Attentional Biases in Major Depressive Disorder: Evidence from Eye-Tracking Studies." *Cognitive Therapy and Research* 44(3):482–95.
- Isaacowitz, Derek M., Heather A. Wadlinger, Deborah Goren, and Hugh R. Wilson. 2006. "Selective Preference in Visual Fixation Away from Negative Images in Old Age? An Eye-Tracking Study." *Psychology and Aging* 21(1):40–48. doi: 10.1037/0882-7974.21.1.40.
- Jaime Diaz, Karen Jannete. 2023. "Metodología Para El Reconocimiento de Emociones Basado En Datos Fisiológicos Multimodales Mediante La Selección de Características Relevantes." Centro Nacional de Investigación y Desarrollo Tecnológico.
- Jin, Alvin B., Lindsey H. Steding, and Andrea K. Webb. 2015. "Reduced Emotional and Cardiovascular Reactivity to Emotionally Evocative Stimuli in Major Depressive Disorder." *International Journal of Psychophysiology* 97(1):66–74. doi:

- 10.1016/j.ijpsycho.2015.04.014.
- Johansson, Birger, and Christian Balkenius. 2018. “A Computational Model of Pupil Dilation.” *Connection Science* 30(1):5–19. doi: 10.1080/09540091.2016.1271401.
- Joseph, Antony William, and Ramaswamy Muruges. 2020. “Potential Eye Tracking Metrics and Indicators to Measure Cognitive Load in Human-Computer Interaction Research.” *Journal of Scientific Research* 64(01):168–75. doi: 10.37398/JSR.2020.640137.
- Kendler, K. S. 2016. “The Nature of Psychiatric Diagnoses: DSM-5 and Beyond.” *World Psychiatry* 15(1):23–25.
- Khubchandani, Jagdish, Sushil Sharma, Fern J. Webb, Michael J. Wiblishauser, and Sharon L. Bowman. 2021. “Post-Lockdown Depression and Anxiety in the USA during the COVID-19 Pandemic.” *Journal of Public Health* 43(2):246–53. doi: 10.1093/pubmed/fdaa250.
- Kim, Minah, Jungha Lee, Soo Yong Lee, Minji Ha, Inkyung Park, Jiseon Jang, Moonyoung Jang, Sunghyun Park, and Jun Soo Kwon. 2024. “Development of an Eye-Tracking System Based on a Deep Learning Model to Assess Executive Function in Patients with Mental Illnesses.” *Scientific Reports* 14(1):18186. doi: 10.1038/s41598-024-68586-2.
- Klawohn, Julia, Alec Bruchnak, Kreshnik Burani, Alexandria Meyer, Amit Lazarov, Yair Bar-Haim, and Greg Hajcak. 2020. “Aberrant Attentional Bias to Sad Faces in Depression and the Role of Stressful Life Events: Evidence from an Eye-Tracking Paradigm.” *Behaviour Research and Therapy* 135:103762. doi: 10.1016/j.brat.2020.103762.
- Krejtz, Izabela, Paweł Holas, Marzena Rusanowska, and John B. Nezlek. 2018. “Positive Online Attentional Training as a Means of Modifying Attentional and Interpretational Biases among the Clinically Depressed: An Experimental Study Using Eye Tracking.” *Journal of Clinical Psychology* 74(9):1594–1606. doi: 10.1002/jclp.22617.
- Kroenke, Kurt, Robert L. Spitzer, and Janet B. W. Williams. 2003. “The Patient Health Questionnaire-2.” *Medical Care* 41(11):1284–92. doi: 10.1097/01.MLR.0000093487.78664.3C.
- Lagunes-Ramírez, Derick A., Gabriel Gonzáles-Serna, and Leonor Rivera-Rivera. 2021. “Patrones de Comportamiento Ocular Durante Inducción Emocional En Diferentes Intensidades.” Pp. 74–79 in *Jornada de Ciencia y Tecnología Aplicada*. Vol. 4.

- Cuernavaca.
- Lagunes-Ramírez, Derick A., Gabriel Gonzáles-Serna, and Leonor Rivera-Rivera. 2022. “Un Vistazo Más Profundo a La Visualización de Datos Del Seguimiento Ocular.” in *Jornada de Ciencia y Tecnología Aplicada*. Vol. 8. Cuernavaca.
- Lagunes-Ramírez, Derick A., Gabriel González-Serna, Nimrod González-Franco, Dante Mújica-Vargas, María-Yasmín Hernández-Pérez, José-Alejandro Reyes-Ortiz, and Leonor Rivera-Rivera. 2023. “Validación de La Escala de Valencia Para Repositorios de Imágenes Emocionales En Poblaciones de Adultos Jóvenes Mexicanos.” *Research in Computing Science* 152(9):67–80.
- Lagunes-Ramírez, Derick Axel. 2020. “Método Para Analizar El Movimiento Ocular de Usuarios Para Generar Métricas y Correlación Con Estados Emocionales y Cognitivos.” Centro nacional de investigación y desarrollo tecnológico.
- Lagunes-Ramírez, Derick Axel, Gabriel González-Serna, Leonor Rivera-Rivera, Nimrod González-Franco, María Y. Hernández-Pérez, and José A. Reyes-Ortiz. 2025. “Through the Youth Eyes: Training Depression Detection Algorithms with Eye Tracking Data.” *IEEE Latin America Transactions* 23(1):6–16. doi: 10.1109/TLA.2025.10810399.
- Lagunes-Ramírez, Derick Axel, Gabriel González-Serna, Leonor Rivera-Rivera, Nimrod González-Franco, Dante Mújica-Vargas, and María Y. Hernández-Pérez. 2024. “Comportamiento de La Mirada y Análisis Mediante Aprendizaje Automático de La Depresión En La Juventud: Una Revisión Sistemática.” *XIKUA Boletín Científico de La Escuela Superior de Tlahuelilpan* 12(23):56–68. doi: 10.29057/xikua.v12i23.11808.
- Lagunes-Ramírez, Derick, Gabriel Gonzalez-Serna, Maximo Lopez-Sanchez, Olivia Fragoso-Diaz, Noe Castro-Sanchez, and Juan Olivares-Rojas. 2020. “Study of the User’s Eye Tracking to Analyze the Blinking Behavior While Playing a Video Game to Identify Cognitive Load Levels.” Pp. 1–5 in *2020 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*. IEEE.
- Lang, P. J., M. M. Bradley, and B. N. Uthbert. 2008. *International Affective Picture System (IAPS): Affective Ratings of Pictures and Instruction Manual*. Gainesville, Florida.
- Li, Mi, Lei Cao, Qian Zhai, Peng Li, Sa Liu, Richeng Li, Lei Feng, Gang Wang, Bin Hu, and Shengfu Lu. 2020. “Method of Depression Classification Based on Behavioral and Physiological Signals of Eye Movement.” *Complexity* 2020:1–9. doi:

- 10.1155/2020/4174857.
- Li, Xiaowei, Tong Cao, Shuting Sun, Bin Hu, and Martyn Ratcliffe. 2016. “Classification Study on Eye Movement Data: Towards a New Approach in Depression Detection.” Pp. 1227–32 in *2016 IEEE Congress on Evolutionary Computation (CEC)*. IEEE.
- Lim, Jia Zheng, James Mountstephens, and Jason Teo. 2020. “Emotion Recognition Using Eye-Tracking: Taxonomy, Review and Current Challenges.” *Sensors* 20(8):2384. doi: 10.3390/s20082384.
- Lovibond, Peter F., and Sydney H. Lovibond. 1995. “The Structure of Negative Emotional States: Comparison of the Depression Anxiety Stress Scales (DASS) with the Beck Depression and Anxiety Inventories.” *Behaviour Research and Therapy* 33(3):335–43. doi: 10.1016/0005-7967(94)00075-U.
- Lu, Shengfu, Sa Liu, Mi Li, Xin Shi, and Richeng Li. 2020. “Depression Classification Model Based on Emotionally Related Eye-Movement Data and Kernel Extreme Learning Machine.” *Journal of Medical Imaging and Health Informatics* 10(11):2668–74. doi: 10.1166/jmihi.2020.3198.
- Lu, Shengfu, Jiying Xu, Mi Li, Jia Xue, Xiaofeng Lu, Lei Feng, Bingbing Fu, Gang Wang, Ning Zhong, and Bin Hu. 2017. “Attentional Bias Scores in Patients with Depression and Effects of Age: A Controlled, Eye-Tracking Study.” *Journal of International Medical Research* 45(5):1518–27. doi: 10.1177/0300060517708920.
- Lu, Yifei, Wei-Long Zheng, Binbin Li, and Bao-Liang Lu. 2015. “Combining Eye Movements and EEG to Enhance Emotion Recognition.” Pp. 1170–76 in *Proceedings of the 24th International Conference on Artificial Intelligence, IJCAI’15*. AAAI Press.
- Ludwig-Walz, Helena, Indra Dannheim, Lisa M. Pfadenhauer, Jörg M. Fegert, and Martin Bujard. 2022. “Increase of Depression among Children and Adolescents after the Onset of the COVID-19 Pandemic in Europe: A Systematic Review and Meta-Analysis.” *Child and Adolescent Psychiatry and Mental Health* 16(1):109. doi: 10.1186/s13034-022-00546-y.
- MacLeod, Colin, Andrew Mathews, and Philip Tata. 1986. “Attentional Bias in Emotional Disorders.” *Journal of Abnormal Psychology* 95(1):15–20. doi: 10.1037/0021-843X.95.1.15.
- Madera-Carrillo, Humberto, Daniel Zarabozo, Marina Ruiz-Díaz, and Priscila Nanclares.

2015. *El Sistema Internacional de Imágenes Afectivas (IAPS) En Población Mexicana. Autoevaluación Con Maniqués y Etiquetas.*
- Mallick, Rohit, David Slayback, Jon Touryan, Anthony J. Ries, and Brent J. Lance. 2016. “The Use of Eye Metrics to Index Cognitive Workload in Video Games.” Pp. 60–64 in *2016 IEEE Second Workshop on Eye Tracking and Visualization (ETVIS)*. IEEE.
- Marcus, M., Mohammad Taghi Yasamy, M. Ommeren, D. Chisholm, and S. Saxena. 2012. “Depression: A Global Public Health Concern.” *World Health Organization Paper on Depression* 6–8.
- Matthews, B. W. 1975. “Comparison of the Predicted and Observed Secondary Structure of T4 Phage Lysozyme.” *Biochimica et Biophysica Acta (BBA) - Protein Structure* 405(2):442–51. doi: 10.1016/0005-2795(75)90109-9.
- McIntire, Lindsey K., R. Andy McKinley, Chuck Goodyear, and John P. McIntire. 2014. “Detection of Vigilance Performance Using Eye Blinks.” *Applied Ergonomics* 45(2):354–62. doi: 10.1016/j.apergo.2013.04.020.
- Melrose, S. 2015. “Seasonal Affective Disorder: An Overview of Assessment and Treatment Approaches.” *Depression Research and Treatment* 2015:1–6.
- Methley, Abigail M., Stephen Campbell, Carolyn Chew-Graham, Rosalind McNally, and Sudeh Cheraghi-Sohi. 2014. “PICO, PICOS and SPIDER: A Comparison Study of Specificity and Sensitivity in Three Search Tools for Qualitative Systematic Reviews.” *BMC Health Services Research* 14(1):579. doi: 10.1186/s12913-014-0579-0.
- Mitre-Hernandez, Hugo, Roberto Covarrubias-Carrillo, and Carlos Lara-Alvarez. 2020. “Pupillary Responses for Cognitive Load Measurement: Classifying Difficulty Levels in an Educational Video Game (Preprint).” *JMIR Serious Games*. doi: 10.2196/21620.
- Moher, David, Alessandro Liberati, Jennifer Tetzlaff, and Douglas G. Altman. 2009. “Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement.” *PLoS Medicine* 6(7):e1000097. doi: 10.1371/journal.pmed.1000097.
- Mohri, M., A. Rostamizadeh, and A. Talwalkar. 2012. *Foundations of Machine Learning (Adaptive Computation and Machine Learning Series)*. The MIT Press.
- Morales Morante, Jose Alberto. 2021. “Metodología Para El Preprocesamiento y Clasificación de Datos Fisiológicos Multimodales Basado En El Modelo Valencia-Excitación.” Centro Nacional de Investigación y Desarrollo Tecnológico.

- National Institute of Mental Health (NIMH). 2021. “Depression.”
- Nestler, E. J., M. Barrot, and R. J. DiLeone. 2002. “Neurobiology of Depression.” *Neuron* 34(1):13–25.
- Ng, CW, CH How, and YP Ng. 2017. “Depression in Primary Care: Assessing Suicide Risk.” *Singapore Medical Journal* 58(2):72–77. doi: 10.11622/smedj.2017006.
- Nguyen, Dong, Canh Nguyen, Thuan Duong-Ba, Hung Nguyen, Anh Nguyen, and Tuan Tran. 2017. “Joint Network Coding and Machine Learning for Error-Prone Wireless Broadcast.” Pp. 1–7 in *2017 IEEE 7th Annual Computing and Communication Workshop and Conference (CCWC)*. IEEE.
- Ochsner, K. N., and J. J. Gross. 2005. “The Cognitive Control of Emotion.” *Trends in Cognitive Sciences* 9(5):242–49. doi: 10.1016/j.tics.2005.03.010.
- Oei, Tian P. S., Sukanlaya Sawang, Yian Wei Goh, and Firdaus Mukhtar. 2013. “Using the Depression Anxiety Stress Scale 21 (DASS-21) across Cultures.” *International Journal of Psychology* 48(6):1018–29. doi: 10.1080/00207594.2012.755535.
- Olbrich, Sebastian, and Martijn Arns. 2013. “EEG Biomarkers in Major Depressive Disorder: Discriminative Power and Prediction of Treatment Response.” *International Review of Psychiatry* 25(5):604–18. doi: 10.3109/09540261.2013.816269.
- Oliva, Manuel, and Andrey Anikin. 2018. “Pupil Dilation Reflects the Time Course of Emotion Recognition in Human Vocalizations.” *Scientific Reports* 8(1):4871. doi: 10.1038/s41598-018-23265-x.
- OMS. 2017. “Depression and Other Common Mental Disorders: Global Health Estimates.” *World Health Organization* 1–24.
- OMS. 2019. “Suicide.”
- OMS. 2020. “Adolescent Mental Health.”
- OMS. 2021. “Depression Facts.”
- OMS. 2022. *International Classification of Diseases 11th Revision (ICD-11)*.
- OMS. 2025. “Salud Mental.”
- OMS, and G. Motturi. 2021. “Suicide Prevention.”
- Otte, C., S. M. Gold, B. W. Penninx, C. M. Pariante, A. Etkin, M. Fava, and A. F. Schatzberg. 2016. “Major Depressive Disorder.” *Nature Reviews Disease Primers* 2(1):16065.
- Owens, Max, Ashley J. Harrison, Katie L. Burkhouse, John E. McGeary, Valerie S. Knopik,

- Rohan H. C. Palmer, and Brandon E. Gibb. 2016. “Eye Tracking Indices of Attentional Bias in Children of Depressed Mothers: Polygenic Influences Help to Clarify Previous Mixed Findings.” *Development and Psychopathology* 28(2):385–97. doi: 10.1017/S0954579415000462.
- Pan, Zeyu, Huimin Ma, Lin Zhang, and Yahui Wang. 2019. “Depression Detection Based on Reaction Time and Eye Movement.” Pp. 2184–88 in *2019 IEEE International Conference on Image Processing (ICIP)*. IEEE.
- Pariante, C. M., and S. L. Lightman. 2008. “The HPA Axis in Major Depression: Classical Theories and New Developments.” *Trends in Neurosciences* 31(9):464–68.
- Parkitny, Luke, and James McAuley. 2010. “The Depression Anxiety Stress Scale (DASS).” *Journal of Physiotherapy* 56(3):204. doi: 10.1016/S1836-9553(10)70030-8.
- Pedregosa, F., G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. 2011. “Scikit-Learn: Machine Learning in {P}ython.” *Journal of Machine Learning Research* 12:2825–30.
- Platt, B., A. Sfârlea, C. Buhl, J. Loechner, J. Neumüller, L. Asperud Thomsen, K. Starman-Wöhrle, E. Salemink, and G. Schulte-Körne. 2022. “An Eye-Tracking Study of Attention Biases in Children at High Familial Risk for Depression and Their Parents with Depression.” *Child Psychiatry & Human Development* 53(1):89–108. doi: 10.1007/s10578-020-01105-2.
- Posner, Michael I. 1980. “Orienting of Attention.” *Quarterly Journal of Experimental Psychology* 32(1):3–25. doi: 10.1080/00335558008248231.
- Radloff, Lenore Sawyer. 1977. “The CES-D Scale.” *Applied Psychological Measurement* 1(3):385–401. doi: 10.1177/014662167700100306.
- Rivera-Rivera, Leonor, Eduardo Fonseca-Pedrero, Marina Séris-Martínez, Argelia Vázquez-Salas, and Luz Myriam Reynales-Shigematsu. 2020. “Prevalencia y Factores Psicológicos Asociados Con Conducta Suicida En Adolescentes. Ensanut 2018-19.” *Salud Pública de México* 62(6, Nov-Dic):672–81. doi: 10.21149/11555.
- Russell, James A., and Albert Mehrabian. 1977. “Evidence for a Three-Factor Theory of Emotions.” *Journal of Research in Personality* 11(3):273–94. doi: 10.1016/0092-6566(77)90037-X.

- Sakai, Tsugunosuke, Haruya Tamaki, Yosuke Ota, Ryohei Egusa, Shigenori Inagaki, Fusako Kusunoki, Masanori Sugimoto, and Hiroshi Mizoguchi. 2017. “EDA-BASED ESTIMATION OF VISUAL ATTENTION BY OBSERVATION OF EYE BLINK FREQUENCY.” *International Journal on Smart Sensing and Intelligent Systems* 10(2):296–307. doi: 10.21307/ijssis-2017-212.
- Salvucci, Dario D., and Joseph H. Goldberg. 2000. “Identifying Fixations and Saccades in Eye-Tracking Protocols.” Pp. 71–78 in *Proceedings of the symposium on Eye tracking research & applications - ETRA '00*. New York, New York, USA: ACM Press.
- Sanchez, Alvaro, Nuria Romero, and Rudi De Raedt. 2017. “Depression-Related Difficulties Disengaging from Negative Faces Are Associated with Sustained Attention to Negative Feedback during Social Evaluation and Predict Stress Recovery” edited by P. Allen. *PLOS ONE* 12(3):e0175040. doi: 10.1371/journal.pone.0175040.
- Santella, Anthony, and Doug DeCarlo. 2004. “Robust Clustering of Eye Movement Recordings for Quantification of Visual Interest.” Pp. 27–34 in *Proceedings of the Eye tracking research & applications symposium on Eye tracking research & applications - ETRA '2004*. New York, New York, USA: ACM Press.
- Secretaría de Salud. 2022. *2º Diagnóstico Operativo de Salud Mental y Adicciones*.
- Shafiei, Somayeh B., Zaeem Lone, Ahmed S. Elsayed, Ahmed A. Hussein, and Khurshid A. Guru. 2020. “Identifying Mental Health Status Using Deep Neural Network Trained by Visual Metrics.” *Translational Psychiatry* 10(1):430. doi: 10.1038/s41398-020-01117-5.
- Shamah-Levy, Teresa, Edgar Vielma-Orozco, Octavio Heredia-Hernández, Martín Romero-Martínez, J. aime Mojica-Cuevas, Lucía Cuevas-Nasu, Julio Antonio Santaella-Castell, and Juan Rivera-Dommarco. 2020. *Encuesta Nacional de Salud y Nutrición 2018-19: Resultados Nacionales*. Cuernavacam México: Instituto Nacional de Salud Pública.
- Sheline, Y. I., M. H. Gado, and H. C. Kraemer. 2003. “Untreated Depression and Hippocampal Volume Loss.” *American Journal of Psychiatry* 160(8):1516–18.
- Shen, Ruizhe, Qi Zhan, Yu Wang, and Huimin Ma. 2021. “Depression Detection by Analysing Eye Movements on Emotional Images.” Pp. 7973–77 in *ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE.

- Shojaeizadeh, Mina, Soussan Djamasbi, Randy C. Paffenroth, and Andrew C. Trapp. 2019. “Detecting Task Demand via an Eye Tracking Machine Learning System.” *Decision Support Systems* 116:91–101. doi: 10.1016/j.dss.2018.10.012.
- Singh, M. K., and I. H. Gotlib. 2014. “The Neuroscience of Depression: Implications for Assessment and Intervention.” *Behavioral Research and Therapy* 62:60–73.
- Skinner, Ian W., Markus Hübscher, G. Lorimer Moseley, Hopin Lee, Benedict M. Wand, Adrian C. Traeger, Sylvia M. Gustin, and James H. McAuley. 2018. “The Reliability of Eyetracking to Assess Attentional Bias to Threatening Words in Healthy Individuals.” *Behavior Research Methods* 50(5):1778–92. doi: 10.3758/s13428-017-0946-y.
- Slomian, J., G. Honvo, P. Emonts, J. Y. Reginster, and O. Bruyère. 2019. “Consequences of Maternal Postpartum Depression: A Systematic Review of Maternal and Infant Outcomes.” *Women’s Health* 15:1745506519844044.
- Smilek, Daniel, Jonathan S. A. Carriere, and J. Allan Cheyne. 2010. “Out of Mind, Out of Sight.” *Psychological Science* 21(6):786–89. doi: 10.1177/0956797610368063.
- Soriano Terrazas, Jeovanni. 2018. “Metodología Para Caracterizar e Inducir Estados Mentales a Través de Realidad Virtual Inmersiva e Interfaz Cerebro Computadora.” Centro nacional de investigación y desarrollo tecnológico.
- Stolicyn, Aleks, J. Douglas Steele, and Peggy Seriès. 2020. “Prediction of Depression Symptoms in Individual Subjects with Face and Eye Movement Tracking.” *Psychological Medicine* 1–9. doi: 10.1017/S0033291720003608.
- Student. 1908. “THE PROBABLE ERROR OF A MEAN.” *Biometrika* 6(1):1–25. doi: 10.1093/biomet/6.1.1.
- Suslow, Thomas, Anja Hußlack, Anette Kersting, and Charlott Maria Bodenschatz. 2020. “Attentional Biases to Emotional Information in Clinical Depression: A Systematic and Meta-Analytic Review of Eye Tracking Findings.” *Journal of Affective Disorders* 274:632–42. doi: 10.1016/j.jad.2020.05.140.
- Tang, Weina, Ciqing Bao, Ling Xu, Jie Zhu, Wenqian Feng, Wenmiao Zhang, Cong Lin, Lan Chen, Qianqian Cheng, Penghao Ding, Meixi Zhou, Ying Bao, Xin Yu, Ke Zhao, and Jincai He. 2019. “Depressive Symptoms in Late Pregnancy Disrupt Attentional Processing of Negative–Positive Emotion: An Eye-Movement Study.” *Frontiers in Psychiatry* 10. doi: 10.3389/fpsy.2019.00780.

- Tolentino, J. C., and S. L. Schmidt. 2018. “DSM-5 Criteria and Depression Severity: Implications for Clinical Practice.” *Frontiers in Psychiatry* 9:450.
- Torgo, Luis. 2010. “DMwR: Functions and Data for ‘Data Mining with R.’”
- Unruh, Kathryn E., James W. Bodfish, and Katherine O. Gotham. 2020. “Adults with Autism and Adults with Depression Show Similar Attentional Biases to Social-Affective Images.” *Journal of Autism and Developmental Disorders* 50(7):2336–47. doi: 10.1007/s10803-018-3627-5.
- Valstar, Michel, Björn Schuller, Kirsty Smith, Timur Almaev, Florian Eyben, Jarek Krajewski, Roddy Cowie, and Maja Pantic. 2014. “AVEC 2014: 3D Dimensional Affect and Depression Recognition Challenge.” Pp. 3–10 in *Proceedings of the 4th International Workshop on Audio/Visual Emotion Challenge - AVEC '14*. New York, New York, USA, New York, USA: ACM Press.
- Valstar, Michel, Björn Schuller, Kirsty Smith, Florian Eyben, Bihan Jiang, Sanjay Bilakhia, Sebastian Schnieder, Roddy Cowie, and Maja Pantic. 2013. “AVEC 2013.” Pp. 3–10 in *Proceedings of the 3rd ACM international workshop on Audio/visual emotion challenge*. New York, NY, USA: ACM.
- Valstar, Michel, Björn W. Schuller, Jarek Krajewski, Roddy Cowie, and Maja Pantic. 2014. “AVEC 2014: The 4th International Audio/Visual Emotion Challenge and Workshop.” Pp. 1243–44 in *Proceedings of the 22nd ACM international conference on Multimedia*. New York, NY, USA: ACM.
- Vazquez, Carmelo, Ivan Blanco, Alvaro Sanchez, and Richard J. McNally. 2016. “Attentional Bias Modification in Depression through Gaze Contingencies and Regulatory Control Using a New Eye-Tracking Intervention Paradigm: Study Protocol for a Placebo-Controlled Trial.” *BMC Psychiatry* 16(1):439. doi: 10.1186/s12888-016-1150-9.
- Villalobos, Dolores, Javier Pacios, and Carmelo Vázquez. 2021. “Cognitive Control, Cognitive Biases and Emotion Regulation in Depression: A New Proposal for an Integrative Interplay Model.” *Frontiers in Psychology* 12. doi: 10.3389/fpsyg.2021.628416.
- Wang, Hong, Ying Zhou, Fengping Yu, Lili Zhao, Caiyu Wang, and Yanju Ren. 2019. “Fusional Recognition for Depressive Tendency With Multi-Modal Feature.” *IEEE*

- Access* 7:38702–13. doi: 10.1109/ACCESS.2019.2899352.
- Watson, D., and L. A. Clark. 1984. “Negative Affectivity: The Disposition to Experience Aversive Emotional States.” *Psychological Bulletin* 96(3):465–90. doi: 10.1037/0033-2909.96.3.465.
- Wu, Chien-Te, Hao-Chuan Huang, Shiuan Huang, I. Ming Chen, Shih-Cheng Liao, Chih-Ken Chen, Chemin Lin, Shwu-Hua Lee, Mu-Hong Chen, Chia-Fen Tsai, Chang-Hsin Weng, Li-Wei Ko, Tzyy-Ping Jung, and Yi-Hung Liu. 2021. “Resting-State EEG Signal for Major Depressive Disorder Detection: A Systematic Validation on a Large and Diverse Dataset.” *Biosensors* 11(12):499. doi: 10.3390/bios11120499.
- Yaroslavsky, Ilya, Eric S. Allard, and Alvaro Sanchez-Lopez. 2019. “Can’t Look Away: Attention Control Deficits Predict Rumination, Depression Symptoms and Depressive Affect in Daily Life.” *Journal of Affective Disorders* 245:1061–69. doi: 10.1016/j.jad.2018.11.036.
- Yuan, Yifang, and Qingxiang Wang. 2019. “Detection Model of Depression Based on Eye Movement Trajectory.” Pp. 612–13 in *2019 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*. IEEE.
- Zagermann, Johannes, Ulrike Pfeil, and Harald Reiterer. 2016. “Measuring Cognitive Load Using Eye Tracking Technology in Visual Computing.” Pp. 78–85 in *Proceedings of the Beyond Time and Errors on Novel Evaluation Methods for Visualization - BELIV '16*. New York, New York, USA: ACM Press.
- Zagermann, Johannes, Ulrike Pfeil, and Harald Reiterer. 2018. “Studying Eye Movements as a Basis for Measuring Cognitive Load.” Pp. 1–6 in *Extended Abstracts of the 2018 CHI Conference on Human Factors in Computing Systems*. New York, NY, USA: ACM.
- Zhao, Qiangfeng, Xiong Jiao, Yingying Tang, Shan Chen, Shanbao Tong, Jijun Wang, and Junfeng Sun. 2019. “Temporal Characteristics of Attentional Disengagement from Emotional Facial Cues in Depression.” *Neurophysiologie Clinique* 49(3):235–42. doi: 10.1016/j.neucli.2019.03.001.
- Zhu, Jing, Ying Wang, Rong La, Jiawei Zhan, Junhong Niu, Shuai Zeng, and Xiping Hu. 2019. “Multimodal Mild Depression Recognition Based on EEG-EM Synchronization Acquisition Network.” *IEEE Access* 7:28196–210. doi:

10.1109/ACCESS.2019.2901950.

Zhu, Jing, Zihan Wang, Tao Gong, Shuai Zeng, Xiaowei Li, Bin Hu, Jianxiu Li, Shuting Sun, and Lan Zhang. 2020. “An Improved Classification Model for Depression Detection Using EEG and Eye Tracking Data.” *IEEE Transactions on NanoBioscience* 19(3):527–37. doi: 10.1109/TNB.2020.2990690.

Zhu, Jing, Zihan Wang, Shuai Zeng, Xiaowei Li, Bin Hu, Xin Zhang, Chen Xia, Lan Zhang, and Zhijie Ding. 2019. “Toward Depression Recognition Using EEG and Eye Tracking: An Ensemble Classification Model CBEM.” Pp. 782–86 in *2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*. IEEE.

Capítulo 8. Anexos

Anexo 1: Inventario de depresión de Beck

Enlace:

https://docs.google.com/document/d/1V5ZuMqQSMktyct2lUR8tN_5wJoPxdpGn/edit?usp=sharing&ouid=105908976113829380096&rtpof=true&sd=true

Anexo 2: Escala de depresión de Hamilton

Enlace:

https://docs.google.com/document/d/1V3OBPhEr7P3FCbP-AwsPrewl7ed4XVch/edit?usp=drive_link&ouid=105908976113829380096&rtpof=true&sd=true

Anexo 3: DASS-21

Enlace:

https://docs.google.com/document/d/1UyLxKrnHDZUQxIY_HPfzXaKSj_2RSkk/edit?usp=drive_link&ouid=105908976113829380096&rtpof=true&sd=true

Anexo 4: Carta consentimiento y asentimiento dirigida a padres

Enlace:

<https://docs.google.com/document/d/12KhdvORtFjH4TW9wIjoP5MxL8naLL9ng/edit?usp=sharing&ouid=105908976113829380096&rtpof=true&sd=true>

Anexo 5: Carta consentimiento y asentimiento dirigida a alumnos

Enlace:

<https://docs.google.com/document/d/1iiQwUi2sCRbQUROFYc-4t7poDfxskf8m/edit?usp=sharing&ouid=105908976113829380096&rtpof=true&sd=true>

Anexo 6: Cuestionario

https://docs.google.com/document/d/1VEilvrBwG6SRIKAEVnksbokPdMUY0Fp/edit?usp=drive_link&ouid=105908976113829380096&rtpof=true&sd=true

Anexo 7: DETDS

https://drive.google.com/drive/folders/1wGcWKnOgc_3uCRn31cvaERJ1Hum7uOEY?usp=drive_link

Anexo 8: Registro del código de QUXBox en INDAUTOR

https://drive.google.com/file/d/1b18qNk_6G6R56ae8S_NvQtocx9TxQ3Jp/view?usp=drive_link