

Comportamiento de la Mirada y Análisis mediante Aprendizaje Automático de la Depresión en la Juventud: Una Revisión Sistemática

Gaze Behavior and Machine-Learning Analysis in Youth Depression: A Systematic Review

Derick A. Lagunes-Ramírez ^a, Gabriel González-Serna ^b, Leonor Rivera-Rivera ^c, Nimrod González-Franco ^d, Dante Mújica-Vargas ^e, María Y. Hernández-Pérez ^f

Abstract:

This review aimed to comprehend the relationship between ocular characteristics and depression in young individuals, for its application in machine learning. A systematic review was conducted to examine ocular behavior in individuals with depressive symptoms and identify eye movement patterns related to mental disorders. The search was conducted using Google Scholar, Semantic Scholar, PubMed, SpringerLink, MDPI, EBSCO, and IEEE Xplore databases. More than 50 publications from the past five years were reviewed. Correlation studies on ocular behavior in individuals with depression and control groups were examined, providing insights into the attentional component of depression. Furthermore, research on depression detection using machine learning algorithms and eye data was reviewed, involving different experimental eye-tracking paradigms and datasets to record information while participants viewed emotional visual stimuli. This review presents associations between different mental states and ocular behavior, with an emphasis on young populations. Through eye-tracking technology, it is possible to support the diagnosis of depression and, consequently, prevent its development. General trends were identified for both young and adult populations, which should be considered in future automatic detection of mental disorders using eye data.

Keywords:

Depression, Youth, Eye-tracking, Mental states, Machine Learning

Resumen:

Esta revisión tuvo como objetivo comprender la relación entre las características oculares y la depresión en personas jóvenes, para su aplicación en el aprendizaje automático. Se realizó una revisión sistemática para examinar el comportamiento ocular en personas con síntomas depresivos e identificar patrones de movimiento ocular relacionados con trastornos mentales. La búsqueda se realizó utilizando las bases de datos de Google Scholar, Semantic Scholar, PubMed, SpringerLink, MDPI, EBSCO e IEEE Xplore. Se revisaron más de 50 publicaciones de los últimos cinco años. Se revisaron estudios de correlación sobre el comportamiento ocular en personas con depresión y grupos de control, lo que proporcionó información sobre el componente de atención en la depresión. Además, se revisaron investigaciones sobre la detección de la depresión mediante algoritmos de aprendizaje automático y datos oculares donde se utilizaron diferentes paradigmas experimentales de seguimiento ocular y conjuntos de datos para registrar información mientras los participantes observaban estímulos visuales emocionales. Esta revisión presenta relaciones entre diferentes estados mentales y el comportamiento ocular, haciendo hincapié en las poblaciones jóvenes. Mediante la tecnología de seguimiento ocular, es posible apoyar el diagnóstico de la depresión y, por lo tanto, prevenir su desarrollo. Se identificaron tendencias generales para las poblaciones jóvenes y adultas, que deben considerarse en futuras detecciones automáticas de trastornos mentales utilizando datos oculares.

Palabras Clave:

Depresión, Jóvenes, Seguimiento ocular, Estados mentales, Aprendizaje automático

^a Autor de Correspondencia, TecNM/CENIDET, <https://orcid.org/0000-0003-0366-6978>, Email: d18ce078@cenidet.tecnm.mx

^b TecNM/CENIDET, <https://orcid.org/0000-0002-1874-9402>, Email: gabriel.gs@cenidet.tecnm.mx

^c Instituto Nacional de Salud Pública, <https://orcid.org/0000-0002-8501-0173>, Email: lriviera@insp.mx

^d TecNM/CENIDET, <https://orcid.org/0000-0002-1051-1379>, Email: nimrod.gf@cenidet.tecnm.mx

^e TecNM/CENIDET, <https://orcid.org/0000-0001-8665-4096>, Email: dante.mv@cenidet.tecnm.mx

^f TecNM/CENIDET, <https://orcid.org/0000-0002-8842-0899>, Email: yasmin.hp@cenidet.tecnm.mx

1 Introducción

La depresión es una enfermedad mental común que generalmente tiende a convertirse en un padecimiento crónico y deteriora sustancialmente la capacidad de una persona para asumir sus responsabilidades diarias (1). La persona afectada llega a experimentar: estado de ánimo negativo, pérdida de placer, desinterés, disminución de la energía, sentimientos de culpa, baja autoestima, trastornos del sueño o del apetito y baja concentración (2). Afecta no solo a quienes la padecen, sino también a sus familias, amigos y a la economía en general (3). Además, es la principal contribuyente a la discapacidad global, representando el 7.5% de todos los años vividos con discapacidad, y es la principal causa de muerte por suicidio (4). Hasta el 60% de las personas que cometen suicidio experimentan depresión mayor (5).

Las enfermedades mentales son una de las principales causas de enfermedad y discapacidad entre los jóvenes (6). Un estado mental de depresión puede llevar al intento de suicidio, la cuarta causa principal de muerte en todo el mundo en adolescentes mayores (15-19 años) (6).

Tradicionalmente, para evaluar a un paciente con depresión, se deben tener en cuenta las circunstancias de la persona, su historia biográfica, síntomas, historia familiar y consumo de alcohol y drogas (7). Los métodos de evaluación pueden identificar la presencia de pensamientos negativos/suicidas, desesperanza, pesimismo o autolesiones. La electroencefalografía (EEG) también se puede utilizar para detectar anomalías (8).

Las escalas de evaluación de la depresión, en lugar de diagnosticarla, sirven para evaluar la intensidad de los síntomas depresivos en los pacientes. Estas escalas pueden ser guías de entrevista o cuestionarios de autoevaluación, donde la gravedad de la depresión en el paciente se obtiene en función de la puntuación. Ejemplos incluyen la Escala de Evaluación de Hamilton para la Depresión (9), el Inventario de Depresión de Beck (10) y el Cuestionario de Conductas Suicidas-Revisado (11).

La investigación actual sugiere una correlación entre los niveles de depresión y el sesgo de atención hacia estímulos relacionados con las emociones. La tecnología de seguimiento ocular puede registrar el movimiento de los globos oculares de una persona mientras se observa un estímulo visual. Los patrones de movimiento ocular están relacionados con procesos cognitivos como los procesos de atención, los sesgos, la carga cognitiva y la participación visual (12,13). La evidencia de esta correlación se encuentra en estudios de investigación cognitiva y de seguimiento ocular (14–18). Por ejemplo, se ha correlacionado el comportamiento ocular, como el tamaño de la pupila, los parpadeos, las fijaciones y las sacadas, con la realización de tareas de diferente dificultad, como jugar Tetris (19) y tareas de búsqueda

visual (20). Además, algunos estudios han informado patrones de comportamiento ocular al enfrentar estímulos emocionales (21–27).

Por lo tanto, si la depresión está correlacionada con el procesamiento cognitivo de la atención de una persona, entonces podemos relacionar comportamiento ocular con la depresión. Los trastornos cognitivos son una característica central del cuadro clínico de la depresión (28). Además, la depresión clínica se caracteriza por una mayor atención a los estímulos disfóricos y una menor atención a los estímulos positivos en comparación con las personas sanas (29,30). Estos sesgos de atención desempeñan un papel importante en la aparición y el mantenimiento del trastorno (31).

La tecnología de seguimiento ocular proporciona una forma natural y eficiente de observar el comportamiento del usuario (24). Es más accesible que nunca debido a la simplificación de los sensores y la mejora de las cámaras digitales, lo que ha aumentado su precisión y facilidad de uso (32). Los datos oculares, como las pupilas, las fijaciones, las sacadas y los parpadeos, proporcionan información sobre los estados afectivos, el comportamiento y la atención. En comparación con otros sensores, el seguimiento ocular puede ser no invasivo, más económico y más fácil de analizar y comprender.

Esta revisión, se enfoca en estudios del comportamiento ocular y la depresión, brindando información sobre por qué el comportamiento ocular está relacionado con la depresión y cómo esta información se utiliza junto con el aprendizaje automático para predecir patrones de depresión.

Se revisaron 19 estudios de correlación y 17 estudios de detección de la depresión con el objetivo de contribuir a la identificación de comportamientos oculares relacionados con la depresión y proporcionar una base para futuros estudios de detección de la depresión. Debido a sus efectos negativos, se enfatizó la importancia de utilizar estas técnicas para abordar la depresión en jóvenes.

Este documento está estructurado en cinco secciones. En la sección 2, se detalla la metodología de revisión sistemática, la cual abarca la estrategia de búsqueda y los procesos de selección. La sección 3 ofrece una descripción de los resultados obtenidos de la búsqueda y analiza si las publicaciones recopiladas respondieron a las preguntas de investigación planteadas. En la sección 4, se lleva a cabo una discusión de los hallazgos. Por último, la sección 5 presenta las conclusiones finales sobre el tema y las posibles implicaciones para futuros trabajos.

2 Métodos

Esta revisión sigue las recomendaciones del Informe de Declaración de los Elementos Preferidos para Revisiones Sistemáticas y Metaanálisis (PRISMA) (33).

2.1 Fuentes de información

Se realizó una búsqueda bibliográfica en las siguientes bases de datos electrónicas: Google Scholar, Semantic Scholar, PubMed, SpringerLink, MDPI, EBSCO e IEEE Xplore. La búsqueda de información se llevó a cabo desde el 10 de octubre de 2022 hasta el 8 de noviembre de 2022.

2.2 Estrategia de búsqueda y elegibilidad de los estudios

La estrategia de búsqueda se basó en las características de la depresión y el movimiento ocular. Las preguntas de investigación fueron las siguientes:

1) ¿Cuáles son las características del comportamiento ocular en jóvenes con depresión?

2) ¿Cómo afectan los estímulos visuales emocionalmente cargados a los patrones de movimiento ocular de jóvenes diagnosticados con depresión en comparación con personas sin depresión?

En base en estas preguntas, la experiencia y los objetivos de la investigación se construyeron 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).

2.3 Selección de estudios

Los criterios de elegibilidad para la revisión siguieron la estructura PICOS (34), 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.

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

2.4 Procesos de recopilación de datos

La Tabla 1 lista los resultados de las bases de datos electrónicas para cada cadena de búsqueda. Las fuentes de información se categorizaron en tres tipos según los objetivos de la investigación:

- 1) Correlación del comportamiento ocular en la depresión
- 2) Detección de la depresión con datos de seguimiento ocular
- 3) Alcance y medición de la depresión en jóvenes.

Tabla 1. Número de resultados de búsqueda en bases de datos electrónicas para cada cadena de búsqueda.

Cadena de búsqueda	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

De estos estudios, se extrajo el diseño del estudio, el entorno, la población, los resultados, las variables y las características del ojo relacionadas con la depresión. Cabe mencionar que la selección se hizo por duplicado y sin presentar discrepancias.

3 Resultados

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 1 presenta el diagrama de flujo PRISMA del proceso de selección.

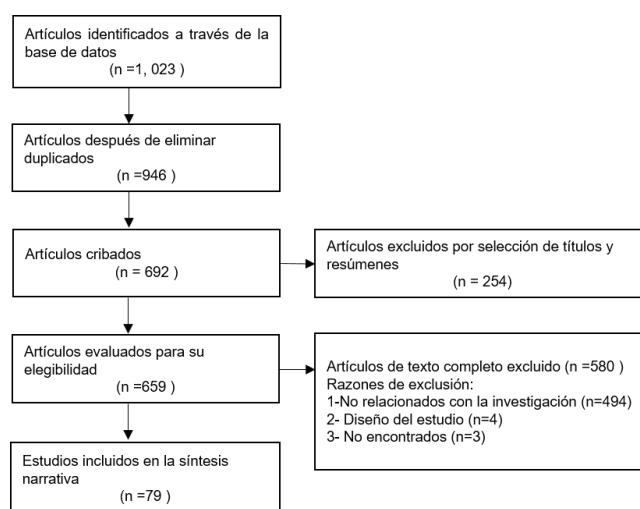


Figura 1. Diagrama de flujo de los Elementos de Información Preferidos para Revisiones Sistemáticas y Metaanálisis (PRISMA).

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 ocho conferencias.

Se clasificó los artículos en dos tipos de investigaciones:

- 1) Correlación de movimientos oculares en pacientes con depresión en comparación con un grupo de control
- 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.

3.1 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 S. Lu et al. (35), 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.

3.2 Estudios de correlación entre el comportamiento ocular y la depresión

La Tabla 2 muestra una comparación entre estudios relacionados con la correlación entre el comportamiento ocular y la depresión. En este tipo de estudios, los autores

informaron diferencias en el comportamiento ocular entre grupos con depresión y grupos de control.

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 (36) y el análisis de varianza ANOVA (37). También se observó el número de sujetos de prueba en las muestras de investigación y el tipo de muestra (niños, jóvenes o adultos).

Comenzando con estudios en niños y adolescentes, El trabajo de Burkhouse et al. (38) 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. (39) 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. (40) se observaron que los hijos de madres deprimidas tienden a evitar estímulos negativos, mientras que en Platt et al. (41) 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. (39) sugirieron que esto podría estar relacionado con la genética.

En adolescentes, el trabajo de Lu et al. (35) 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. (42) se descubrieron que los adolescentes con depresión tenían dificultades en la regulación emocional al observar estímulos emocionales. Mientras que en García et al. (43) 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. (44) se investigó la reactividad neural y pupilar a estímulos emocionales en adolescentes con depresión. Encontraron que los adolescentes con depresión tenían una mayor dilatación pupilar en respuesta a estímulos emocionales en

Tabla 2. 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
(35)	✓				✓	✓		Visualización libre	Rostros emocionales	Jóvenes y Adultos	75	90
(38)			✓				✓	Visualización libre	Rostros emocionales	Niños	--	43
(39)	✓	✓					✓	Visualización pasiva	Rostros emocionales	Niños	81	81
(40)		✓			✓			Spatial cueing task (45)	Rostros emocionales	Niños	64	69
(41)				✓	✓	✓	✓	DPT, VST & PVT	Rostros emocionales	Niños y Adultos	36	44
(42)	✓					✓		Visualización libre	IAPS	Adolescentes	37	36
(46)	✓						✓	Visualización condicionada	Rostros emocionales	Adultos	25	14
(43)	✓				✓	✓		DPT	Rostros emocionales	Adultos jóvenes	120	31
(47)			✓		✓		✓	Visualización libre	Multimedia emocional	Adultos	25	25
(44)			✓		✓			Visualización libre	Rostros emocionales	Adolescentes	26	18
(48)	✓				✓	✓		Visualización libre	Rostros emocionales	Adultos	31	50
(49)						✓	✓	ABMT	Rostros emocionales	Adultos	27	33
(50)		✓			✓		✓	Visualización libre	Rostros emocionales	Adultos	31	31
(51)	✓					✓		Visualización libre	Rostros emocionales	--	44	25
(52)	✓				✓		✓	Visualización libre	IAPS	Adultos	43	22
(53)	✓						✓	Visualización libre	Rostros emocionales	Adultos jóvenes	23	23
(54)					✓		✓	Visualización condicionada	Rostros emocionales	Adultos	29	29
(55)	✓				✓	✓		Visualización libre	Rostros emocionales	Adultos	24	24
(56)	✓			✓	✓			Visualización condicionada	Rostros emocionales	Adultos	24	29

DPT = Dot-Probe Task (57), VST = Visual-Search Task, PVT = Passive-Viewing Task, ABMT = Attentional bias modification training, IAPS = International Affective Picture System. (58).

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 han registrado. Por ejemplo, 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.

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

La Tabla 3 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, revisamos los métodos, paradigmas experimentales y datos de seguimiento ocular.

En el trabajo de S. Alghowinem et al. (3) 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. (59) 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. (60,61), 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, obteniendo la mejor precisión del 82.50% utilizando solo datos oculares y el 92.65% utilizando 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 S. Alghowinem et al. (62) se combinaron características estadísticas de comportamiento del habla, actividad ocular y movimiento de cabeza para detectar la depresión utilizando 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. (63) 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. (64), los autores detectaron la depresión entrenando 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 H. Wang et al. (65). Donde

Tabla 3. 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	
(3)	2013	SVM	75.00%	--	--	✓			126
(66)	2020	KELM	91.00%	91.06%	92.31%	✓			28
(59)	2020	SVM	79.17%	76.00%	82.61%	✓			132
(67)	2020	RNN-LSTM	94.52%	--	--	✓			20
(61)	2019	CBEM	78.50%	--	--	✓		✓	87
(62)	2018	SVM & Fusión	86.00%	--	--	✓		✓	128
(68)	2018	Adaboost	92.00%	--	--	✓			3
(63)	2021	SVM	77.00%	--	--		✓		--
(69)	2020	KELM	88.55%	87.71%	89.42%	✓			--
(60)	2020	CBEM	82.50 %	--	--	✓		✓	87
(70)	2019	FFNN	79.80%	77.20%	78.10%	✓			30
(64)	2019	SVM	86.00%	88.00%	84.00%		✓		82
(65)	2019	Regresión Logística	93.02%	88.02%	--		✓		20
(71)	2019	Red neuronal	83.17%	--	--		✓		30
(72)	2019	SVM Lineal	83.42%	--	--		✓	✓	1846
(73)	2019	Regresión Logística	79.63%	76.67%	85.19%	✓		✓	--
(74)	2016	KNN	81.00%	--	--		✓		6

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.

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). Utilizando 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 & Benaissa (68) 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 utilizando solo 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, Wang, La, et al. (72) 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 utilizando dos enfoques de redes neuronales con un autoencoder. Primero, las características se vincularon utilizando 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 utilizando 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. (73) 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 aprendizaje automático 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 aprendizaje automático 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 X. Li et al. (74), donde los autores buscaron desarrollar un enfoque objetivo para la detección de la depresión utilizando 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 utilizando selección de características basada 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. (67) 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 autorreporte 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 autorreporte. En este trabajo, los autores informaron un 95.00% de precisión en la predicción del estado de bienestar.

Mientras que en Gavrilescu & Vizireanu (70) se informó sobre un sistema para predecir los niveles de depresión, ansiedad y estrés utilizando características oculares. Los autores clasificaron los niveles de salud mental utilizando la Escala de Depresión, Ansiedad y Estrés (DASS) (75). 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, prediciendo 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 M. Li et al. (66) 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 restando 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, utilizando 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 S. Lu et al. (69) también se logró la detección de la depresión utilizando características oculares como fijaciones y un clasificador KELM con una precisión del 88.55%.

En el trabajo de Yuan & Wang (71) 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 clasificando las trayectorias oculares y las diferencias con las coordenadas de distracción. Se utilizaron 111 muestras para entrenar la red y 37 muestras para la prueba. La red neuronal se diseñó utilizando Keras de Python y se optimizó en tres submodelos: 1) un modelo con datos estandarizados utilizando StandarScaler de scikitlearn (76), 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%.

4 Discusión

Los métodos tradicionales de evaluación de la depresión incluyen entrevistas e instrumentos autoinformados 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 utilizando 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 utilizando 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 aprendizaje automático más populares, seguidos de las redes neuronales.

En la Tabla 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.

4.1 Limitaciones

Una limitación importante es que los autores crearon y utilizaron sus propios conjuntos de datos para la investigación, y 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 aprendizaje automático.

4.2 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 utilizando solo el seguimiento ocular como medio de recopilación de datos.

5 Conclusiones

Los trabajos actuales que relacionan la depresión con el comportamiento ocular aclaran que realmente existe una correlación; se observa en el sesgo atencional negativo a través de numerosos experimentos de comparación entre grupos de estudio y grupos de control. Sin embargo, algunas variables específicas deben ser investigadas más a fondo; por ejemplo, en lo que respecta a la depresión infantil, observamos que no existe un consenso en el comportamiento típico de la depresión. Algunos estudios han observado un sesgo atencional negativo en niños con riesgo de depresión o sintomatología, pero otros estudios no han encontrado ninguna correlación en absoluto. En algunos estudios, los niños no suelen prestar una atención especial a los estímulos negativos; algunos autores teorizan que este comportamiento puede explicarse mediante una estrategia de regulación emocional o factores genéticos. Se concluye que esta diferencia podría ser clave para clasificar la depresión en niños y adultos y necesita una investigación adicional.

Algo que podría convertirse en un problema son los estímulos seleccionados para la experimentación; debido a que estas imágenes deben seleccionarse cuidadosamente para el contexto de la población, ya que podrían tener diferentes efectos emocionales y cognitivos en los sujetos. En futuros trabajos, podría proponerse un conjunto de estímulos emocionales centrados solamente en la sintomatología de la depresión.

Como se muestra en la Tabla 3, no existen metodologías ni paradigmas estandarizados para los estudios de detección de la depresión. Los resultados variaron según el método, los algoritmos de clasificación y las características. La recopilación de datos a través de tareas de visualización emocional fue el método más común, y se prefirieron los algoritmos de aprendizaje automático clásicos, siendo el SVM el más utilizado. Algunos estudios han realizado una fusión de características fisiológicas, incluyendo el EEG; sin embargo, un enfoque de solo seguimiento ocular podría ser menos intrusivo para los sujetos y más fácil de implementar.

Los estudios de detección de la depresión demuestran que, mediante la implementación de diferentes algoritmos computacionales, se puede crear un modelo para la detección de la depresión basado en datos de seguimiento ocular. Del mismo modo, es posible implementar este modelo como un software que puede clasificar el sesgo de atención de una persona y, así, agregar objetividad al diagnóstico de la depresión.

Se observó un alto uso de características de fijación y sacádicas, que están más relacionadas con la atención visual. Otras características como el parpadeo y la dilatación de la pupila pueden ser volátiles debido a variables ambientales como la iluminación, la humedad, el flujo de aire y los reflejos. Además, enfermedades oculares, el uso de gafas, la rumiación, la divagación mental y la interpretación también pueden afectar la medición. Los datos de características de parpadeo y pupila pueden ser útiles para la investigación si se registran en entornos de laboratorio controlados y uniformes.

Aunque los algoritmos de clasificación clásicos siguen siendo preferidos por los investigadores, los enfoques de redes neuronales profundas pueden ofrecer más información sobre la clasificación de la salud mental utilizando imágenes como entradas. Dado que los datos de seguimiento ocular pueden representarse como series temporales, se pueden realizar diferentes transformaciones de datos para imágenes, y estas características pueden utilizarse para entrenar, por ejemplo, redes neuronales convolucionales. Solo uno de los estudios revisados exploró el aprendizaje profundo de imágenes para la clasificación de la salud mental.

Finalmente, alentamos la investigación sobre aplicaciones de prevención de la depresión, especialmente en poblaciones jóvenes, ya que la depresión tiende a afectar el desarrollo cognitivo y las enfermedades mentales como la depresión se encuentran entre las principales causas de enfermedad y discapacidad entre los adolescentes.

Agradecimientos

Este trabajo fue respaldado por el Tecnológico Nacional de México (TecNM), campus Cenidet y el Consejo Nacional de Ciencia y Tecnología (Conacyt), y fue financiado por TecNM [número de subvención 10434.21-P].

Referencias

- [1]. Marcus M, Yasamy MT, Ommeren M, Chisholm D, Saxena S. Depression: A global public health concern. *World Heal Organ Pap Depress*. 2012 Jan 1;6–8.
- [2]. OMS. Depression Facts. 2021.
- [3]. Alghowinem S, Goecke R, Wagner M, Parker G, Breakspear M. Eye movement analysis for depression detection. In: 2013 IEEE International Conference on Image Processing [Internet]. IEEE; 2013. p. 4220–4. Available from: <http://ieeexplore.ieee.org/document/6738869/>
- [4]. OMS. Depression and other common mental disorders: global health estimates [Internet]. World Health Organization. Geneva; 2017. p. 1–24. Available from: <https://apps.who.int/iris/bitstream/handle/10665/254610/WHO-MSD-MER-2017.2-eng.pdf?sequence=1%0Ahttp://apps.who.int/iris/bitstream/handle/10665/254610/WHO-MSD-MER-2017.2-eng.pdf;jsessionid=0886B5297E6F5A04AA4F2F2FD5FE36F9?sequence=1%0Ahttp://apps.who.int/>
- [5]. Ng C, How C, Ng Y. Depression in primary care: assessing suicide risk. *Singapore Med J* [Internet]. 2017 Feb;58(2):72–7. Available from: <http://www.smj.org.sg/article/depression-primary-care-assessing-suicide-risk>
- [6]. OMS. Adolescent mental health [Internet]. 2020. Available from: <https://www.who.int/news-room/fact-sheets/detail/adolescent-mental-health>
- [7]. National Institute of Mental Health (NIMH). Depression [Internet]. 2021. Available from: https://www.nimh.nih.gov/sites/default/files/documents/health/publications/depression/21-mh-8079-depression_0.pdf
- [8]. Wu C-T, Huang H-C, Huang S, Chen I-M, Liao S-C, Chen C-K, et al. Resting-State EEG Signal for Major Depressive Disorder Detection: A Systematic Validation on a Large and Diverse Dataset. *Biosensors* [Internet]. 2021 Dec 6;11(12):499. Available from: <https://www.mdpi.com/2079-6374/11/12/499>
- [9]. Hamilton M. A RATING SCALE FOR DEPRESSION. *J Neurol Neurosurg Psychiatry* [Internet]. 1960 Feb 1;23(1):56–62. Available from: <https://jnnp.bmj.com/lookup/doi/10.1136/jnnp.23.1.56>
- [10]. Beck AT, Steer RA, Brown GK. BDI-II, Beck Depression Inventory: Manual. San Antonio, TX: The Psychological Corporation; 1996.
- [11]. Osman A, Bagge CL, Gutierrez PM, Konick LC, Kopper BA, Barrios FX. The Suicidal Behaviors Questionnaire-Revised (SBQ-R): Validation with Clinical and Nonclinical Samples. *Assessment* [Internet]. 2001 Dec 26;8(4):443–54. Available from: <http://journals.sagepub.com/doi/10.1177/107319110100800409>

- [12]. Chen S, Epps J, Ruiz N, Chen F. Eye activity as a measure of human mental effort in HCI. In: Proceedings of the 15th international conference on Intelligent user interfaces - IUI '11 [Internet]. New York, New York, USA: ACM Press; 2011. p. 315. Available from: <http://portal.acm.org/citation.cfm?doid=1943403.1943454>
- [13]. McIntire LK, McKinley RA, Goodyear C, McIntire JP. Detection of vigilance performance using eye blinks. Appl Ergon [Internet]. 2014 Mar;45(2):354–62. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0003687013000938>
- [14]. Joseph AW, Murugesh R. Potential Eye Tracking Metrics and Indicators to Measure Cognitive Load in Human-Computer Interaction Research. J Sci Res [Internet]. 2020 Jan 1;64(01):168–75. Available from: http://www.bhu.ac.in/research_pub/jsr/Volumes/JSR_64_01_2020/37.pdf
- [15]. Lagunes-Ramírez D, Gonzalez-Serna G, Lopez-Sanchez M, Fragoso-Diaz O, Castro-Sanchez N, Olivares-Rojas J. Study of the User's Eye Tracking to Analyze the Blinking Behavior While Playing a Video Game to Identify Cognitive Load Levels. In: 2020 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC) [Internet]. IEEE; 2020. p. 1–5. Available from: <https://ieeexplore.ieee.org/document/9258693/>
- [16]. Mitre-Hernandez H, Covarrubias-Carrillo R, Lara-Alvarez C. Pupillary Responses for Cognitive Load Measurement: Classifying Difficulty Levels in an Educational Video Game (Preprint). JMIR Serious Games [Internet]. 2020 Jun 19; Available from: <http://preprints.jmir.org/preprint/21620/accepted>
- [17]. Wang Q, Yang S, Liu M, Cao Z, Ma Q. An eye-tracking study of website complexity from cognitive load perspective. Decis Support Syst [Internet]. 2014 Jun;62:1–10. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0167923614000402>
- [18]. Zagermann J, Pfeil U, Reiterer H. Measuring Cognitive Load using Eye Tracking Technology in Visual Computing. In: Proceedings of the Beyond Time and Errors on Novel Evaluation Methods for Visualization - BELIV '16 [Internet]. New York, New York, USA: ACM Press; 2016. p. 78–85. Available from: <http://dl.acm.org/citation.cfm?doid=2993901.2993908>
- [19]. Mallick R, Slayback D, Touryan J, Ries AJ, Lance BJ. The use of eye metrics to index cognitive workload in video games. In: 2016 IEEE Second Workshop on Eye Tracking and Visualization (ETVIS) [Internet]. IEEE; 2016. p. 60–4. Available from: <http://ieeexplore.ieee.org/document/7851168/>
- [20]. Zagermann J, Pfeil U, Reiterer H. Studying Eye Movements as a Basis for Measuring Cognitive Load. In: Extended Abstracts of the 2018 CHI Conference on Human Factors in Computing Systems [Internet]. New York, NY, USA: ACM; 2018. p. 1–6. Available from: <https://dl.acm.org/doi/10.1145/3170427.3188628>
- [21]. Gerdes ABM, Alpers GW, Braun H, Köhler S, Nowak U, Treiber L. Emotional sounds guide visual attention to emotional pictures: An eye-tracking study with audio-visual stimuli. Emotion [Internet]. 2020 Mar 19; Available from: <http://doi.apa.org/getdoi.cfm?doi=10.1037/emo0000729>
- [22]. Lagunes-Ramírez DA, González-Serna G, Rivera-Rivera L. Patrones de comportamiento ocular durante inducción emocional en diferentes intensidades. Jorn Cienc y Tecnol Apl [Internet]. 2021;4(2):74–9. Available from:
- [23]. Lim JZ, Mountstephens J, Teo J. Emotion Recognition Using Eye-Tracking: Taxonomy, Review and Current Challenges. Sensors [Internet]. 2020 Apr 22;20(8):2384. Available from: <https://www.mdpi.com/1424-8220/20/8/2384>
- [24]. Lu Y, Zheng W-L, Li B, Lu B-L. Combining Eye Movements and EEG to Enhance Emotion Recognition. In: Proceedings of the 24th International Conference on Artificial Intelligence [Internet]. AAAI Press; 2015. p. 1170–6. (IJCAI'15). Available from: <http://dl.acm.org/citation.cfm?id=2832249.2832411>
- [25]. Pavlov S V., Korenyok V V., Reva N V., Tumlialis A V., Loktev K V., Aftanas LI. Effects of long-term meditation practice on attentional biases towards emotional faces: An eye-tracking study. Cogn Emot [Internet]. 2015 Jul 4;29(5):807–15. Available from: <http://www.tandfonline.com/doi/full/10.1080/02699931.2014.945903>
- [26]. Skinner IW, Hübscher M, Moseley GL, Lee H, Wand BM, Traeger AC, et al. The reliability of eyetracking to assess attentional bias to threatening words in healthy individuals. Behav Res Methods [Internet]. 2018 Oct 15;50(5):1778–92. Available from: <http://link.springer.com/10.3758/s13428-017-0946-y>
- [27]. Wei-Long Zheng, Bo-Nan Dong, Bao-Liang Lu, Zheng W, Dong B, Lu B, et al. Multimodal emotion recognition using EEG and eye tracking data. In: 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society [Internet]. IEEE; 2014. p. 5040–3. Available from: <http://ieeexplore.ieee.org/document/6944757/>
- [28]. Perini G, Cotta Ramusino M, Sinforiani E, Bernini S, Petrachi R, Costa A. Cognitive impairment in depression: recent advances and novel treatments. Neuropsychiatr Dis Treat [Internet]. 2019 May;Volume 15:1249–58. Available from: <https://www.dovepress.com/cognitive-impairment-in-depression-recent-advances-and-novel-treatment-peer-reviewed-article-NDT>
- [29]. Suslow T, Hußlack A, Kersting A, Bodenschatz CM. Attentional biases to emotional information in clinical depression: A systematic and meta-analytic review of eye tracking findings. J Affect Disord [Internet]. 2020 Sep;274:632–42. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0165032720311381>
- [30]. Zhao Q, Jiao X, Tang Y, Chen S, Tong S, Wang J, et al. Temporal Characteristics of Attentional Disengagement from Emotional Facial Cues in Depression. Neurophysiol Clin [Internet]. 2019 Jun;49(3):235–42. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0987705318302375>
- [31]. Vazquez C, Blanco I, Sanchez A, McNally RJ. 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 [Internet]. 2016 Dec 8;16(1):439. Available from: <http://bmcpsychiatry.biomedcentral.com/articles/10.1186/s12888-016-1150-9>
- [32]. Ho H-F. The effects of controlling visual attention to handbags for women in online shops: Evidence from eye movements. Comput Human Behav [Internet]. 2014 Jan;30:146–52. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0747563213003051>
- [33]. Moher D, Liberati A, Tetzlaff J, Altman DG. Preferred

Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. *PLoS Med* [Internet]. 2009 Jul 21;6(7):e1000097. Available from: <https://dx.plos.org/10.1371/journal.pmed.1000097>

- [34]. Methley AM, Campbell S, Chew-Graham C, McNally R, Cheraghi-Sohi S. PICO, PICOS and SPIDER: a comparison study of specificity and sensitivity in three search tools for qualitative systematic reviews. *BMC Health Serv Res* [Internet]. 2014 Dec 21;14(1):579. Available from: <https://bmchealthservres.biomedcentral.com/articles/10.1186/s12913-014-0579-0>
- [35]. Lu S, Xu J, Li M, Xue J, Lu X, Feng L, et al. Attentional bias scores in patients with depression and effects of age: a controlled, eye-tracking study. *J Int Med Res* [Internet]. 2017 Oct 29;45(5):1518–27. Available from: <http://journals.sagepub.com/doi/10.1177/0300060517708920>
- [36]. Student. THE PROBABLE ERROR OF A MEAN. *Biometrika* [Internet]. 1908 Mar 1;6(1):1–25. Available from: <https://academic.oup.com/biomet/article-lookup/doi/10.1093/biomet/6.1.1>
- [37]. Girden ER. ANOVA: Repeated measures. Sage; 1992.
- [38]. Burkhouse KL, Siegle GJ, Woody ML, Kudinova AY, Gibb BE. Pupillary reactivity to sad stimuli as a biomarker of depression risk: Evidence from a prospective study of children. *J Abnorm Psychol* [Internet]. 2015 Aug;124(3):498–506. Available from: <http://doi.apa.org/getdoi.cfm?doi=10.1037/abn0000072>
- [39]. Owens M, Harrison AJ, Burkhouse KL, McGeary JE, Knopik VS, Palmer RHC, et al. Eye tracking indices of attentional bias in children of depressed mothers: Polygenic influences help to clarify previous mixed findings. *Dev Psychopathol* [Internet]. 2016 May 1;28(2):385–97. Available from: https://www.cambridge.org/core/product/identifier/S0954579415000462/type/journal_article
- [40]. Gibb BE, Pollak SD, Hajcak G, Owens M. Attentional biases in children of depressed mothers: An event-related potential (ERP) study. *J Abnorm Psychol* [Internet]. 2016 Nov;125(8):1166–78. Available from: <http://doi.apa.org/getdoi.cfm?doi=10.1037/abn0000216>
- [41]. Platt B, Sfärlea A, Buhl C, Loechner J, Neumüller J, Asperud Thomsen L, et al. An Eye-Tracking Study of Attention Biases in Children at High Familial Risk for Depression and Their Parents with Depression. *Child Psychiatry Hum Dev* [Internet]. 2022 Feb 4;53(1):89–108. Available from: <http://link.springer.com/10.1007/s10578-020-01105-2>
- [42]. Greimel E, Piechaczek C, Schulte-Rüther M, Feldmann L, Schulte-Körne G. The role of attentional deployment during distancing in adolescents with major depression. *Behav Res Ther* [Internet]. 2020 Mar;126:103554. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S000579672030005X>
- [43]. Garcia SE, Francis SMS, Tone EB, Tully EC. Understanding associations between negatively biased attention and depression and social anxiety: positively biased attention is key. *Anxiety, Stress Coping* [Internet]. 2019 Nov 2;32(6):611–25. Available from: <https://www.tandfonline.com/doi/full/10.1080/10615806.2019.1638732>
- [44]. Burkhouse KL, Owens M, Feurer C, Sosoo E, Kudinova A, Gibb BE. Increased neural and pupillary reactivity to emotional faces in adolescents with current and remitted major depressive

disorder. *Soc Cogn Affect Neurosci* [Internet]. 2017 May 1;12(5):783–92. Available from: <https://academic.oup.com/scan/article/12/5/783/2726393>

- [45]. Posner MI. Orienting of Attention. *Q J Exp Psychol*. 1980 Feb;32(1):3–25.
- [46]. Sanchez A, Romero N, De Raedt R. Depression-related difficulties disengaging from negative faces are associated with sustained attention to negative feedback during social evaluation and predict stress recovery. Allen P, editor. *PLoS One* [Internet]. 2017 Mar 31;12(3):e0175040. Available from: <https://dx.plos.org/10.1371/journal.pone.0175040>
- [47]. Jin AB, Steding LH, Webb AK. Reduced emotional and cardiovascular reactivity to emotionally evocative stimuli in major depressive disorder. *Int J Psychophysiol* [Internet]. 2015 Jul;97(1):66–74. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0167876015001622>
- [48]. Klawohn J, Bruchnak A, Burani K, Meyer A, Lazarov A, Bar-Haim Y, et al. Aberrant attentional bias to sad faces in depression and the role of stressful life events: Evidence from an eye-tracking paradigm. *Behav Res Ther* [Internet]. 2020 Dec;135:103762. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0005796720302163>
- [49]. Krejtz I, Holas P, Rusanowska M, Nezelek JB. Positive online attentional training as a means of modifying attentional and interpretational biases among the clinically depressed: An experimental study using eye tracking. *J Clin Psychol* [Internet]. 2018 Sep;74(9):1594–606. Available from: <http://doi.wiley.com/10.1002/jclp.22617>
- [50]. Bodenschatz CM, Skopinceva M, Ruß T, Suslow T. Attentional bias and childhood maltreatment in clinical depression - An eye-tracking study. *J Psychiatr Res* [Internet]. 2019 May;112:83–8. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0022395618313232>
- [51]. Figueiredo GR, Ripka WL, Romanelli EFR, Ulbricht L. Attentional bias for emotional faces in depressed and non-depressed individuals: an eye-tracking study. In: 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) [Internet]. IEEE; 2019. p. 5419–22. Available from: <https://ieeexplore.ieee.org/document/8857878/>
- [52]. Tang W, Bao C, Xu L, Zhu J, Feng W, Zhang W, et al. Depressive Symptoms in Late Pregnancy Disrupt Attentional Processing of Negative–Positive Emotion: An Eye-Movement Study. *Front Psychiatry* [Internet]. 2019 Oct 31;10. Available from: <https://www.frontiersin.org/article/10.3389/fpsy.2019.00780/full>
- [53]. Yaroslavsky I, Allard ES, Sanchez-Lopez A. Can't look Away: Attention control deficits predict Rumination, depression symptoms and depressive affect in daily Life. *J Affect Disord* [Internet]. 2019 Feb;245:1061–9. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0165032718314150>
- [54]. Bodenschatz CM, Skopinceva M, Ruß T, Kersting A, Suslow T. Face perception without subjective awareness – Emotional expressions guide early gaze behavior in clinically depressed and healthy individuals. *J Affect Disord* [Internet]. 2020 Mar;265:91–8. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0165032719315885>
- [55]. Unruh KE, Bodfish JW, Gotham KO. Adults with Autism and Adults with Depression Show Similar Attentional Biases to

Social-Affective Images. J Autism Dev Disord [Internet]. 2020 Jul 7;50(7):2336–47. Available from: <http://link.springer.com/10.1007/s10803-018-3627-5>

- [56]. Godara M, Sanchez-Lopez A, De Raedt R. Music to my ears, goal for my eyes? Music reward modulates gaze disengagement from negative stimuli in dysphoria. Behav Res Ther [Internet]. 2019 Sep;120:103434. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0005796719301202>
- [57]. MacLeod C, Mathews A, Tata P. Attentional bias in emotional disorders. J Abnorm Psychol [Internet]. 1986;95(1):15–20. Available from: <http://doi.apa.org/getdoi.cfm?doi=10.1037/0021-843X.95.1.15>
- [58]. Lang PJ, Bradley MM, Uthbert BN. International affective picture system (IAPS): Affective ratings of pictures and instruction manual. Gainesville, Florida.; 2008.
- [59]. Stolicyn A, Steele JD, Seriès P. Prediction of depression symptoms in individual subjects with face and eye movement tracking. Psychol Med [Internet]. 2020 Nov 9;1–9. Available from: https://www.cambridge.org/core/product/identifier/S0033291720003608/type/journal_article
- [60]. Zhu J, Wang Z, Gong T, Zeng S, Li X, Hu B, et al. An Improved Classification Model for Depression Detection Using EEG and Eye Tracking Data. IEEE Trans Nanobioscience [Internet]. 2020 Jul;19(3):527–37. Available from: <https://ieeexplore.ieee.org/document/9079496/>
- [61]. Zhu J, Wang Z, Zeng S, Li X, Hu B, Zhang X, et al. Toward Depression Recognition Using EEG and Eye Tracking: An Ensemble Classification Model CBEM. In: 2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM) [Internet]. IEEE; 2019. p. 782–6. Available from: <https://ieeexplore.ieee.org/document/8983225/>
- [62]. Alghowinem S, Goecke R, Wagner M, Epps J, Hyett M, Parker G, et al. Multimodal Depression Detection: Fusion Analysis of Paralinguistic, Head Pose and Eye Gaze Behaviors. IEEE Trans Affect Comput [Internet]. 2018 Oct 1;9(4):478–90. Available from: <https://ieeexplore.ieee.org/document/7763752/>
- [63]. Shen R, Zhan Q, Wang Y, Ma H. Depression Detection by Analysing Eye Movements on Emotional Images. In: ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) [Internet]. IEEE; 2021. p. 7973–7. Available from: <https://ieeexplore.ieee.org/document/9414663/>
- [64]. Pan Z, Ma H, Zhang L, Wang Y. Depression Detection Based on Reaction Time and Eye Movement. In: 2019 IEEE International Conference on Image Processing (ICIP) [Internet]. IEEE; 2019. p. 2184–8. Available from: <https://ieeexplore.ieee.org/document/8803181/>
- [65]. Wang H, Zhou Y, Yu F, Zhao L, Wang C, Ren Y. Fusional Recognition for Depressive Tendency With Multi-Modal Feature. IEEE Access [Internet]. 2019;7:38702–13. Available from: <https://ieeexplore.ieee.org/document/8667078/>
- [66]. Li M, Cao L, Zhai Q, Li P, Liu S, Li R, et al. Method of Depression Classification Based on Behavioral and Physiological Signals of Eye Movement. Complexity [Internet]. 2020 Jan 14;2020:1–9. Available from: <https://www.hindawi.com/journals/complexity/2020/4174857/>
- [67]. Shafiei SB, Lone Z, Elsayed AS, Hussein AA, Guru KA. Identifying mental health status using deep neural network

trained by visual metrics. Transl Psychiatry [Internet]. 2020 Dec 14;10(1):430. Available from: <http://www.nature.com/articles/s41398-020-01117-5>

- [68]. Al-gawwam S, Benaissa M. Depression Detection From Eye Blink Features. In: 2018 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT) [Internet]. IEEE; 2018. p. 388–92. Available from: <https://ieeexplore.ieee.org/document/8642682/>
- [69]. Lu S, Liu S, Li M, Shi X, Li R. Depression Classification Model Based on Emotionally Related Eye-Movement Data and Kernel Extreme Learning Machine. J Med Imaging Heal Informatics [Internet]. 2020 Nov 1;10(11):2668–74. Available from: <https://www.ingentaconnect.com/content/10.1166/jmihi.2020.3198>
- [70]. Gavrilescu M, Vizireanu N. Predicting Depression, Anxiety, and Stress Levels from Videos Using the Facial Action Coding System. Sensors [Internet]. 2019 Aug 25;19(17):3693. Available from: <https://www.mdpi.com/1424-8220/19/17/3693>
- [71]. Yuan Y, Wang Q. Detection Model of Depression Based on Eye Movement Trajectory. In: 2019 IEEE International Conference on Data Science and Advanced Analytics (DSAA) [Internet]. IEEE; 2019. p. 612–3. Available from: <https://ieeexplore.ieee.org/document/8964128/>
- [72]. Zhu J, Wang Y, La R, Zhan J, Niu J, Zeng S, et al. Multimodal Mild Depression Recognition Based on EEG-EM Synchronization Acquisition Network. IEEE Access [Internet]. 2019;7:28196–210. Available from: <https://ieeexplore.ieee.org/document/8653893/>
- [73]. Ding X, Yue X, Zheng R, Bi C, Li D, Yao G. Classifying major depression patients and healthy controls using EEG, eye tracking and galvanic skin response data. J Affect Disord [Internet]. 2019 May;251:156–61. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0165032718330064>
- [74]. Li X, Cao T, Sun S, Hu B, Ratcliffe M. Classification study on eye movement data: Towards a new approach in depression detection. In: 2016 IEEE Congress on Evolutionary Computation (CEC) [Internet]. IEEE; 2016. p. 1227–32. Available from: <http://ieeexplore.ieee.org/document/7743927/>
- [75]. Parkitny L, McAuley J. The Depression Anxiety Stress Scale (DASS). J Physiother [Internet]. 2010;56(3):204. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1836955310700308>
- [76]. Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, et al. Scikit-learn: Machine Learning in {P}ython. J Mach Learn Res. 2011;12:2825–30.