

Tendencias y perspectivas en la detección de depresión mediante el análisis de señales Electroencefalográficas (EEG): una Revisión Sistemática de la Literatura.

Trends and perspectives in the detection of depression by analysis of Electroencephalographic (EEG) signals: a Systematic Review of the Literature.

T. Habiram Obispo-Bustillos^a, Nimrod González-Franco^b, Juan Gabriel González-Serna^c, Dante Mújica-Vargas^d, Noé Alejandro Castro-Sánchez^e

Abstract:

Currently, the diagnosis of depression is carried out through clinical interviews; taking into account the information provided by the patient, questionnaires or tests are used which help us have an approximation of the severity of the illness. To avoid human intervention in this type of diagnosis, one could resort to the analysis of electroencephalographic (EEG) signals using different machine learning techniques. This Systematic Literature Review (SLR) aims to synthesize current trends in the detection of depression through EEG signals and machine learning models. A search was conducted in PubMed, IEEEExplore, ScienceDirect, and SpringerLink where 41 works were obtained in databases and 50 works were obtained through other sources, of which 20 articles published between 2020 and 2022 were selected, which present a comparison between different processing and classification methods. In the vast majority of the works, the accuracy rate is more than 80% in a binary classification (Depression/No Depression), as a result of the study of different methodologies and machine learning models. This work aims to review the literature to offer a useful cross-section to determine the most widely used classification methods.

Keywords:

Depression, EEG and Machine Learning.

Resumen:

Actualmente el diagnóstico de la depresión se realiza mediante entrevistas clínicas; teniendo en cuenta la información que aporta el paciente, se utilizan cuestionarios o test los cuales nos ayudan a tener una aproximación de la gravedad del padecimiento. Para evitar la intervención humana en este tipo de diagnósticos, se podría recurrir al análisis de señales electroencefalográficas (EEG) con diferentes técnicas de Aprendizaje Automático. Esta Revisión Sistemática de la Literatura (RSL) tiene como objetivo sintetizar las tendencias actuales sobre la detección de la depresión a través de señales EEG y modelos de Aprendizaje Automático. Se realizó una búsqueda en PubMed, IEEEExplore, ScienceDirect y SpringerLink donde se obtuvieron 41 trabajos en bases de datos y 50 trabajos a través de otras fuentes, de los que se seleccionaron 20 artículos publicados entre 2020 y 2022, los cuales presentan una comparación entre diferentes métodos de procesamiento y clasificación. En su gran mayoría, los trabajos demuestran una tasa de precisión mayor al 80% en una clasificación binaria (Depresión/No Depresión), resultado del estudio de diferentes metodologías y modelos de Aprendizaje Automático. Este trabajo tiene como objetivo revisar la literatura para ofrecer una sección transversal útil para determinar los métodos de clasificación mayormente utilizados.

Palabras Clave:

Depresión, EEG y Aprendizaje Automático.

^a Autor de Correspondencia, CENIDET-TECNM, <https://orcid.org/0000-0002-9955-7428>, Email: m22ce052@cenidet.tecnm.mx

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

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

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

^e CENIDET-TECNM, <https://orcid.org/0000-0002-8083-3891>, Email: noe.cs@cenidet.tecnm.mx

Introducción

Las personas con depresión se caracterizan por sentir tristeza, falta de concentración, baja autoestima, trastornos del sueño o del apetito, lo que afecta gravemente las capacidades de un individuo en su día a día. En su forma más severa, la depresión puede conducir al suicidio [World Health Organization, 2017]. La falta de pruebas de laboratorio para la detección de la depresión en sujetos, es una de las causas principales de un diagnóstico erróneo de este padecimiento [Mahato, 2020]. Este trabajo presenta una Revisión Sistemática de la Literatura (RSL), donde se analizan artículos relacionados con la detección de la depresión en sujetos a través de señales electroencefalográficas y una comparación entre métodos de procesamiento de señales y modelos de Aprendizaje Automático. Se estima que el cerebro humano comprende 100 mil millones de neuronas, y cada neurona tiene aproximadamente 10 000 conexiones con otras neuronas. Esta enorme red neuronal eléctricamente activa se puede dividir en muchas subredes, donde las corrientes iónicas presentes en estas subredes provocan cambios en el potencial extracelular local [Ramsey N., 2020]. A través del EEG podemos medir los potenciales cerebrales a través de electrodos montados en un gorro que se colocan al nivel del cuero cabelludo. Por ejemplo, con el EEG podemos obtener registros de la actividad eléctrica neuronal midiendo las diferencias en los potenciales de voltaje de múltiples electrodos distribuidos a lo largo del cuero cabelludo [Collell, 2015]. La banda alfa se caracteriza por una actividad de frecuencia media (8 a 13 Hz) y generalmente indica estados de vigilia relajada en adultos sanos [Berger, 1929], la banda beta se caracteriza por una actividad de frecuencia media a alta (13 a 30 Hz) relacionada con diversos estados mentales, como concentración activa [Pfurtscheller et al., 1996], la banda gamma se caracteriza por una actividad de muy alta frecuencia (30 a 200 Hz, pero normalmente no se puede medir mediante EEG cuando es superior a 100 Hz) y esta oscilación a menudo se asocia con la excitación [Hughes, 2008], la banda delta se caracteriza por una actividad de muy baja frecuencia (por debajo de 1 a 4 Hz), que generalmente se relaciona con el sueño profundo, la banda delta (la amplitud puede ser de varias décimas de mV) se asocia con estados neurales patológicos, como el coma o la pérdida del conocimiento [Hobson, 2002], y por último la banda theta ocurre como actividad de baja frecuencia (4 a 8 Hz) y generalmente se asocia con estados de sueño específicos, somnolencia y meditación [Cahn, 2006]. De manera concreta, se ha encontrado que existen diferencias significativas en las banda delta, theta, alfa [Jaworska et al., 2012] y beta [Nyström et al., 1986] en casi toda la corteza cerebral, resultando particularmente interesante el análisis de la asimetría de las ondas alfa en

la región frontal del cerebro, siendo útil para detectar depresión en un sujeto. Las técnicas de Aprendizaje Automático son parte del campo de la informática que involucra la evolución de sistemas de reconocimiento de patrones permitiendo a las computadoras aprender de errores y predecir resultados [Camacho et al., 2018]. Los pacientes con depresión muestran deficiencias en la actividad coordinada de varias regiones del cerebro que se consideran importantes para varios dominios del funcionamiento mental, como el procesamiento emocional (amígdala) [Friston, 2009; Gilson et al., 2016], procesos autorreferenciales (corteza prefrontal medial y cíngula posterior) [Gilson et al., 2016], funciones cognitivas como la memoria (hipocampo) [Friston, 2002], procesamiento visual (circunvolución fusiforme, lingual y corteza temporal lateral) [Marreiros et al., 2008] y procesamiento de la atención (corteza prefrontal dorsolateral, corteza cíngula anterior, tálamo e ínsula) [Gilson et al., 2018] y específicamente se han encontrado diferencias en las bandas beta, theta y alpha. En medicina se puede utilizar un modelo para relacionar características de señales del EEG (por ejemplo: beta, theta y alpha) con un resultado determinado (siguiendo con el ejemplo, se podría clasificar la actividad electroencefalográfica como: con depresión a sin depresión). En la primer parte de este documento nos centramos en los materiales y métodos utilizados para realizar esta Revisión Sistemática de la Literatura de acuerdo con las buenas prácticas establecidas por PRISMA, señalando los criterios de elegibilidad, estrategia de búsqueda utilizados y como se realizó la extracción de los datos de los 20 trabajos seleccionados. Posteriormente, se presentan los resultados obtenidos dando referencia al uso de la Máquina de Soporte Vectorial y la Red Neuronal Convolutiva como métodos de clasificación mayormente utilizados en la clasificación binaria de la depresión, y por último la discusión en la cual destacamos la metodología empleada en la investigación, hallazgos más relevantes y cómo estos contribuyen a la comprensión del tema abordado.

Materiales y métodos

El desarrollo de este artículo se realizó bajo un protocolo de Revisión Sistemática de la Literatura (RSL) y una búsqueda de acuerdo con las buenas prácticas establecidas por PRISMA (del inglés *Preferred Reporting Items for Systematic reviews and Meta-Analyses*), donde el objetivo principal fue identificar tendencias principales para detectar depresión con señales EEG y métodos de Aprendizaje Automático. Se inicio con un conjunto inicial de 91 trabajos, 41 trabajos extraídos de bases de datos y 50 identificados de otras fuentes, de los cuales fueron descartados 12 registros mediante verificación de

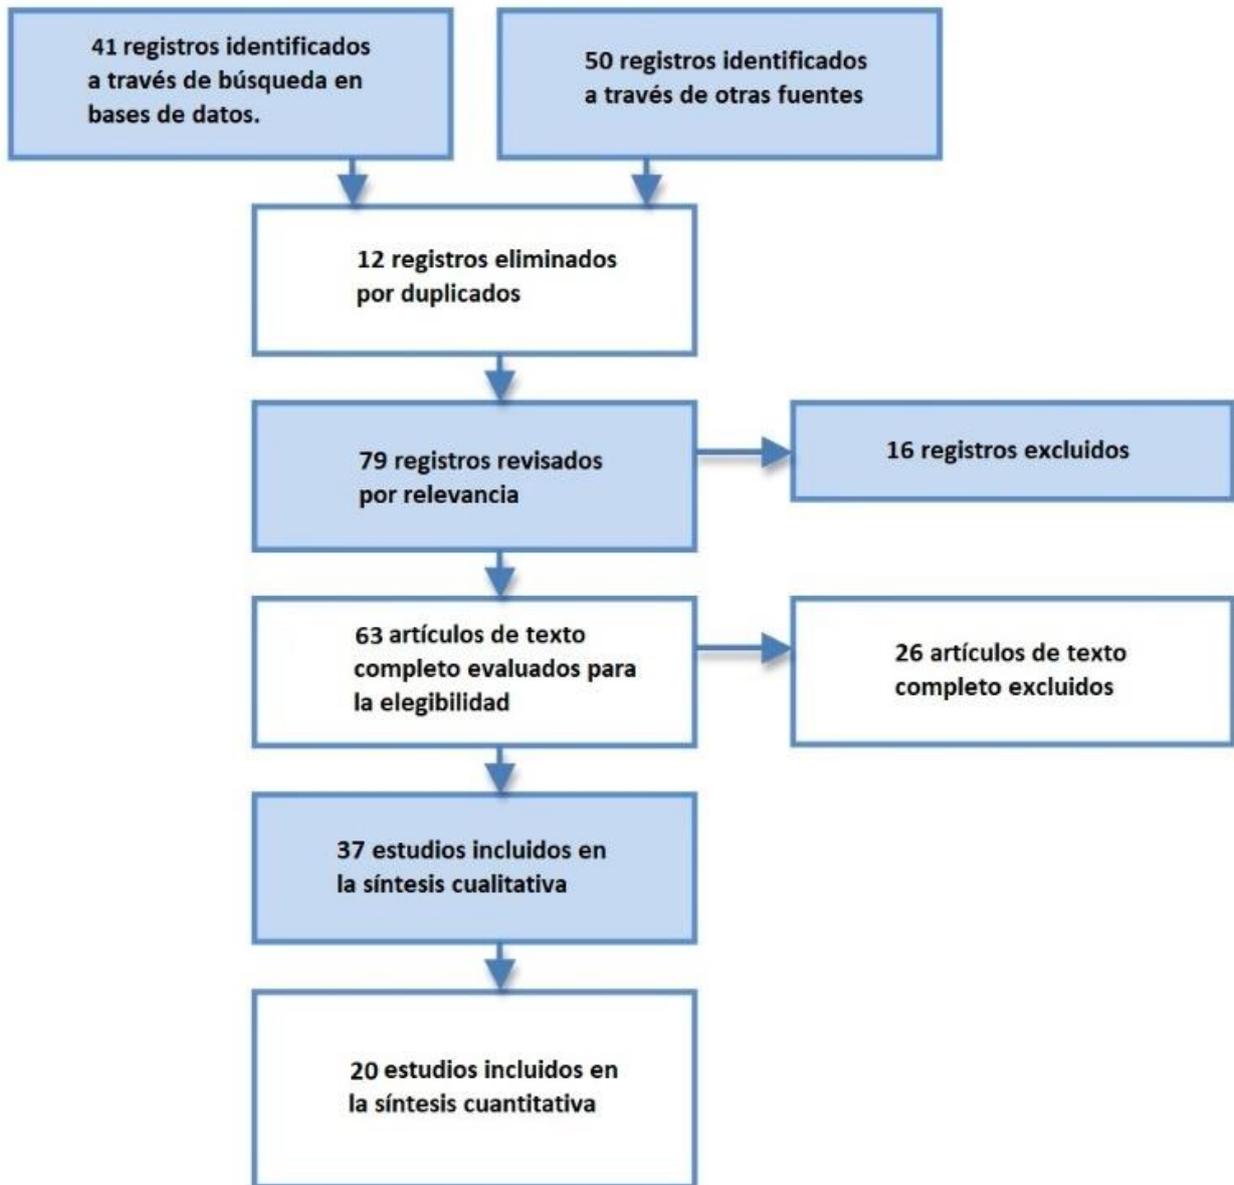


Figura 1. Diagrama de Flujo del proceso de la selección de estudios.

duplicados. Posteriormente, se realizó una revisión por relevancia, donde se seleccionaron 79 artículos por palabras clave. Por otra parte, se llevó a cabo la exclusión de 26 artículos tomando como criterio de elegibilidad el contenido de los trabajos de acuerdo al título, metodologías y resultados; la Figura 1 incluye un diagrama de flujo en el que se resume cuantitativamente el proceso de selección de estudios de acuerdo con las buenas prácticas establecidas por PRISMA.

Criterios de elegibilidad

Se consideró en los criterios de selección que se mencionen métodos de extracción de características, procesamiento de señales y modelos de Aprendizaje Automático. Se seleccionaron 20 artículos publicados entre 2020 y 2022 en PubMed, IEEExplore, ScienceDirect y SpringerLink, discriminando trabajos con una muestra de estudio no mayor a 20 sujetos, divididos entre sanos y diagnosticados con depresión bajo cuestionarios estandarizados como el Manual Diagnóstico y Estadístico de los Trastornos Mentales (DSM-V) y la Escala de depresión de Hamilton.

Estrategia de búsqueda

Las estrategias de búsqueda de datos son fundamentales para garantizar la exhaustividad y la relevancia de la información recopilada en una revisión sistemática de la literatura. Se emplearon estrategias de búsqueda combinadas, que incluyeron la consulta de bases de datos especializadas en neurociencia y psicología, así como la búsqueda manual en revistas y congresos relevantes. Además, se utilizaron términos específicos relacionados con la detección de depresión y el análisis de señales Electroencefalográficas para maximizar la eficacia de la búsqueda. Estas estrategias de búsqueda rigurosas permitieron identificar y seleccionar la información más relevante y actual sobre las tendencias y perspectivas en la detección de depresión mediante el análisis de señales Electroencefalográficas. Se utilizaron dos cadenas de búsqueda conectadas mediante el operador lógico AND como se muestra en la Figura 2, donde se ejecutaron las palabras clave en los buscadores de las 4 bases de datos de artículos previamente mencionados.

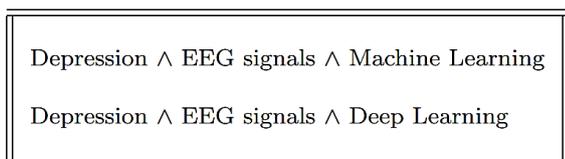


Figura 2. Cadenas de búsqueda.

Extracción de datos

Los 20 artículos que fueron incluidos en la síntesis cuantitativa se analizaron a profundidad e individualmente, sus respectivos porcentajes según las fuentes de información de donde se extrajeron dichos trabajos se describen en la Figura 3. Se utilizó una hoja de cálculo en Excel para realizar la tabulación del conjunto de trabajos cuantitativos de los cuales se extrajeron las referencias del trabajo (p. ej., autores principales, año de publicación), propósito del estudio, diseño experimental, muestras de estudio (p. ej., tamaño de muestra), métodos y técnicas (p. ej., métodos de extracción de características, procesamiento de datos y clasificadores) y resultados.

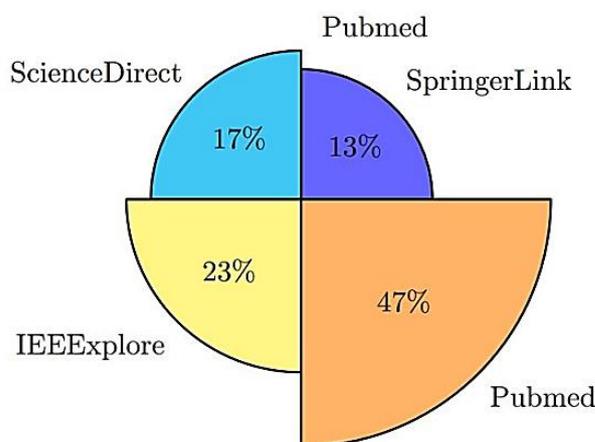


Figura 3. Porcentajes según las fuentes de información de donde se extrajeron los trabajos.

La extracción de datos en una revisión sistemática de la literatura es un proceso crítico para identificar y recopilar información relevante sobre un tema específico. En el caso de las tendencias y perspectivas en la detección de depresión mediante el análisis de señales Electroencefalográficas, la extracción de datos permitió recopilar y analizar información sobre los métodos y técnicas actualmente utilizados en la investigación y los resultados obtenidos. Además, también permitió identificar las limitaciones y desafíos existentes en este campo y las áreas que requieren más investigación en el futuro. En resumen, la extracción de datos es esencial para obtener una visión completa y actualizada sobre el estado del arte en la detección de la depresión mediante el análisis de señales Electroencefalográficas. La información más relevante de cada trabajo analizado se presenta en la Tabla 1.

Tabla.1: Resultados de la Revisión Sistemática de la Literatura.

Referencia	Propósito de estudio	Diseño Experimental	Métodos y técnicas	Resultados principales
[Thoduparambil et al., 2020]	Diagnóstico de depresión basado en aprendizaje profundo	En el modelo de aprendizaje profundo, los filtros en la capa de convolución se convolucionan con la señal de entrada para generar mapas de características. Las características extraídas se entregan al LSTM, después se realiza la clasificación utilizando capas conectadas. Se dispuso de diferentes funciones para actualizar los pesos durante el entrenamiento. La prueba del modelo se realizó mediante la técnica de división aleatoria.	CNN	Precisión del 99,07 % con CNN.
[Uyulan et al., 2021]	Diagnóstico de depresión basado en EEG	Las grabaciones del EEG se analizan mediante el modelado de 3 estructuras CNN profundas diferentes: ResNet-50, MobileNet, Inception-v3, para dividir a los pacientes con depresión y sanos. Los datos del EEG se recopilan de 4 bandas de frecuencia principales delta, theta, alfa y beta, mediante la recopilación de datos de 19 electrodos. Después del preprocesamiento, se emplean las arquitecturas de Aprendizaje Profundo para saber el rendimiento de discriminación comparando precisiones de clasificación.	CNN	Precisión del 89,33 % con arquitectura MobileNet.
[Jang et al., 2021a]	Detección de depresión con EEG y Aprendizaje Automático	Se trabajó con una muestra de 30 sujetos sanos y 34 diagnosticados con depresión. Se realizó una tarea auditiva P300 (AP300) y se extrajeron los componentes N1 y P3. La clasificación de dos grupos se realizó utilizando clasificadores de análisis discriminante lineal (LDA) y Máquina Soporte Vectorial.	SVM	Precisión del 59.71 %
[Avots et al., 2022]	Diagnóstico de depresión analizando señales EEG	Muestra balanceada de 20 sujetos, donde todos los modelos se evaluaron mediante una validación cruzada de 10 veces. Los clasificadores binarios fueron entrenados usando potencia de banda relativa, variabilidad de potencia alfa, índice de asimetría espectral, dimensión fractal de Higuchi, complejidad Lempel-Ziv, y análisis de fluctuación sin tendencia.	Naive Bayes	Precisión del 93.30 % con Naive Bayes.

Tabla. 1: Resultados de la Revisión Sistemática de la Literatura. Continuación.

Referencia	Propósito de estudio	Diseño Experimental	Métodos y técnicas	Resultados principales
[Mahato et al., 2020]	Detección y escala de la gravedad de la depresión	Uso de señales EEG con una muestra balanceada de 34 sujetos, utilizando una validación cruzada de 10 veces proporcionando métricas de precisión, sensibilidad, especificidad, F1 score y tasa de descubrimiento falso.	SVM	Precisión del 96.02% con SVM.
[Li et al., 2022]	Detección automática de depresión a través del análisis de señales EEG	Análisis de señales EEG con una muestra de 154 sujetos. La selección de características se realiza a través de la combinación secuencial del coeficiente de correlación de Pearson y eliminación recursiva de características.	SVM.	Precisión del 98% con SVM.
[Duan et al., 2020]	Detección automática de depresión a través de aprendizaje auto-mático	Muestra balanceada con 32 pacientes. Los criterios de inclusión y exclusión se basan del DSM-V. Se utiliza un filtro de impulso finito para las señales y las frecuencias de 0,5 a 47 Hz. Posteriormente se aplica un análisis de componentes independientes para eliminar artefactos. Se extraen como características la asimetría interhemisférica y la correlación cruzada.	CNN	Precisión del 93.31% con CNN.
[Čukić et al., 2020b]	Aclarar la eficiencia de dos medidas no lineales en la detección de la depresión	Se analizan señales del EEG de una muestra de 23 sujetos con depresión y 20 sujetos sanos. Se calculó la dimensión fractal de Higuchi y la entropía de la muestra de las series temporales del EEG. Para determinar la dependencia lineal de las características del EEG, se utilizó un análisis de correlación y se aplicó PCA para determinar la influencia de la extracción de características lineales.	Perceptrón Multicapa	Precisión del 95.12 % con Perceptrón Multicapa.
[Saeedi et al., 2021]	Diagnóstico de depresión sin extracción y selección de características.	Análisis de cinco bandas de frecuencia (delta, theta, alfa, beta y gamma) de EEG con una muestra de 34 sujetos con depresión y 30 sanos.	K-vecino más cercano	Precisión del 98.44 % con K-vecino cercano.

Tabla.1: Resultados de la Revisión Sistemática de la Literatura. Continuación.

Referencia	Propósito de estudio	Diseño Experimental	Métodos y técnicas	Resultados principales
[Uyulan et al., 2022]	Diagnóstico de depresión mediante EEG	Se desarrolló un método híbrido que comprende una muestra balanceada de 30 sujetos, un ResNet-50 pre-entrenado y una memoria a corto plazo (LSTM) para capturar información específica de la depresión, y se comparó con un marco de aprendizaje automático. Las medidas de causalidad que interpretaron los mecanismos de interacción entre oscilaciones espectralmente descompuestas, se usaron para extraer características de series de tiempo de EEG multivariado: coherencia dirigida (DC), función de transferencia dirigida (DTF), DC parcial (PDC), PDC generalizada (gPDC), PDC extendida (ePDC) y PDC retardada (dPDC).	CNN	Precisión del 95.9 % con CNN.
[Movahed et al., 2021]	Detección de depresión a través de aprendizaje automático y señales EEG	Muestra con 34 sujetos con depresión y 30 sanos, utilizando una validación cruzada de 10 veces. Se utilizaron métodos de análisis estadístico espectral, wavelet, conectividad funcional y no lineal para la extracción de características y selección secuencial de características hacia atrás (SBFS) para seleccionar características.	SVM	Precisión del 99 % con SVM
[Saeedi et al., 2020]	Detección de depresión basado en Aprendizaje Profundo	Muestra con 30 sujetos sanos y 34 con depresión utilizando redes neuronales convolucionales de una y dos dimensiones (1DCNN-2-DCNN), un modelo de memoria a corto plazo (LSTM), una combinación de CNN con el modelo LSTM (1DCNN LSTM y 2DCNN-LSTM).	CNN	Precisión del 99.24 % con CNN.
[Xin et al., 2022]	Detección de depresión con EEG	Muestra con 154 sujetos donde el modelo se entrenó mediante una validación cruzada de división de sujetos.	CNN Sparnet.	Precisión del 94.3 % con CNN
[Liu et al., 2022a]	Diagnóstico de depresión basado en EGG y Aprendizaje Profundo	Muestra con 29 sujetos sanos y 24 con depresión severa. Se trabajó en cuatro bloques: convolución, convolución en profundidad, convolución separable y clasificación.	CNN	Precisión del 90.98 % con CNN.
[Liu et al., 2022b]	Predicción de depresión basado en EEG.	La estrategia se validó con un conjunto de datos público. Se eliminó el ruido de las señales del electroencefalograma para obtener los espectros de potencia de tres bandas (theta, beta y alpha).	CNN	Precisión del 89.63 % con CNN

Tabla.1: Resultados de la Revisión Sistemática de la Literatura. Continuación.

Referencia	Propósito de estudio	Diseño Experimental	Métodos y técnicas	Resultados principales
[Jang et al., 2021b]	Se realizó una clasificación basada en aprendizaje automático de la depresión mediante el uso de EEG.	Muestra de 30 sujetos sanos y 33 con depresión, Se realizó una tarea auditiva P300 (AP300) y se extrajeron los componentes N1 y P3. La clasificación de dos grupos se realizó utilizando clasificadores de análisis discriminante lineal (LDA) y Máquina de Soporte Vectorial	SVM y análisis discriminante lineal	Precisión del 70.95 % SVM y 74.5 % con LDA.
[Sadat Shahabi et al., 2021]	Se desarrolló un método de Aprendizaje profundo para la clasificación de respondedores y no respondedores a los utilizando EEG.	Se obtuvieron múltiples imágenes de tiempo-frecuencia de cada canal de EEG mediante la Transformación continua de ondículas para alimentar modelos de CNN preentrenados que son VGG16, Xception, Den seNet121, MobileNetV2 e Inception- ResNetV2.	CNN	Precisión del 95.74 %
[Zhu et al., 2020]	Detección de depresión con EEG y Aprendizaje Automático	Con una muestra de 34 sujetos se desarrolló un método de Aprendizaje Automático para detectar depresión. Se aplicó un método de selección de características, GreedyStepwise (GSW, por sus siglas en inglés) basado en la selección de características de correlación para la selección de características del EEG.	Bosque Aleatorio	Precisión del 78.24 %
[Wang et al., 2022]	Detección automática de depresión con EEG y Aprendizaje Profundo	Los datos del EEG multicanal se transformaron en imágenes 2D después de la fusión multicanal (MCF) y el aumento de recorte multiescala (MSC). El entrenamiento se realizó mediante una Red Neuronal Convolutiva multicanal. El modelo entrenado se cargó en el dispositivo de detección para clasificar las señales EEG de entrada.	Red Neuronal Multicanal	Precisión del 94.01 %
[Kaur et al., 2021]	Desarrollo de una fase de preprocesamiento de EEG para eliminar el ruido en las señales de EEG de pacientes con depresión	Muestra de 34 pacientes con depresión y 30 sujetos sanos. Se realizó un análisis de fluctuación sin tendencia como criterio de selección y se aplicó una evaluación basada en la descomposición de paquetes de ondículas para extraer la señal más limpia.	Bosque Aleatorio	Precisión del 98.51 % con Bosque Aleatorio.

Resultados

De los trabajos seleccionados, la gran mayoría se enfocan en aumentar la precisión en la identificación de pacientes con depresión. Solo un estudio se enfocó en la detección y el escalamiento de la gravedad de la depresión a partir de las características que se extraen de la región temporal del cerebro utilizando seis canales (FT7, FT, T7, T8, TP7 Y TP8), además se empleó la técnica de selección de características ReliefF y el algoritmo de clasificación Máquina Soporte Vectorial (SVM, por sus siglas en inglés), obteniendo una precisión del 90,26% para la detección de la depresión y el 75.31% para la escala de gravedad [Mahato et al., 2020]. Un trabajo relacionado con la detección de la depresión mediante el algoritmo SVM, se desarrolló con un conjunto de 154 sujetos, del cual la selección de características se realizó a través de la combinación secuencial del coeficiente de correlación de Pearson y eliminación recursiva de características obteniendo una precisión del 98% [Li et al., 2022]. En otro estudio también se utilizó SVM con kernel RBF (del inglés, Radial Basis Function) obteniendo el 99% de precisión con una muestra de 34 sujetos con depresión y 30 sanos, realizando una validación cruzada de 10 veces y utilizando métodos de análisis estadístico espectral, wavelet, conectividad funcional y no lineal para la extracción de características y selección secuencial de características hacia atrás para seleccionar características [Movahed et al., 2021]. La contaminación por artefactos reduce la precisión en los sistemas de procesamiento de señales, por lo que uno de los trabajos seleccionados [Kaur et al., 2021] tuvo el objetivo de desarrollar una fase de procesamiento de EEG para eliminar el ruido en las señales realizando una descomposición de la señal en funciones de modo intrínseco mediante el uso de criterios de parada basados en análisis de fluctuación sin tendencia. Luego, estas funciones de modo intrínseco se analizan mediante la descomposición de paquetes wavelet. La clasificación basada en Bosque Aleatorio (RF, por sus siglas en inglés), obtuvo una precisión del 98,51% con la técnica de eliminación de ruido propuesta con una muestra de 34 pacientes con depresión y 30 sujetos sanos. Relacionado al Aprendizaje Profundo y diagnóstico de depresión, se encontró un estudio en el cual las señales del EEG se obtuvieron del "Repositorio de pacientes para datos de EEG + Herramientas computacionales" de la Universidad de Nuevo México. En el modelo de Aprendizaje Profundo, los filtros en la capa de convolución se convolucionan con la señal de entrada para generar mapas de características. Todas las características extraídas se entregan al LSTM (por sus siglas del inglés, Long Short-Term Memory) para que aprenda los diferentes patrones, después se realiza la clasificación utilizando capas conectadas. LSTM tiene

celdas de memoria para recordar las características esenciales y se dispuso de diferentes funciones para actualizar los pesos durante el entrenamiento, obteniendo una precisión del 99,07% [Thoduparambil et al., 2020]. Por otro lado, un estudio trabajó con una muestra balanceada de 32 sujetos basándose de los criterios de exclusión de depresión del DSM-V. Para el procesamiento de las señales se utilizó un filtro de impulso con frecuencias de 0.5 Hz a 57 Hz y se aplicó un Análisis de Componentes Independientes para eliminar artefactos y se extrajeron como características la asimetría interhemiférica y la correlación cruzada, obteniendo una precisión del 93.31% con Redes Neuronales Convolucionales [Duan et al., 2020]. A diferencia del estudio anterior, mencionaremos un estudio en el cual las grabaciones del EEG se analizaron mediante el modelado de 3 estructuras de Redes Neuronales Convolucionales diferentes: ResNet-50, MobileNet e Inception-v3, para dividir a los pacientes con depresión de los sanos. Los datos de EEG se recopilaron de 4 bandas de frecuencia principales delta, theta, alfa y beta, mediante la recopilación de datos de 19 electrodos. Después del preprocesamiento, se emplearon las arquitecturas de Aprendizaje Profundo para subrayar el rendimiento de discriminación comparando precisiones de clasificación de lo cual se obtuvo una precisión del 89,33% y 92,66% con arquitectura MobileNet para el hemisferio izquierdo y derecho, respectivamente [Uyulan et al., 2021]. Las Redes Neuronales han destacado por ser muy utilizadas para detectar depresión mediante señales EEG, por ejemplo, un estudio con una muestra con 30 sujetos sanos y 34 con depresión, utilizó Redes Neuronales Convolucionales de una y dos dimensiones (1DCNN-2-DCNN), LSTM, una combinación de CNN (del inglés, Convolutional Neural Networks) con el modelo LSTM (1DCNN LSTM y 2DCNN-LSTM) obteniendo una precisión del 99.24% [Saeedi et al., 2020], otro estudio obtuvo el 94.3% con una muestra de 154 sujetos donde el modelo se entrenó mediante una validación cruzada de división de sujetos [Xin et al., 2022]. También se encontró otro estudio basado en Redes Neuronales Convolucionales compuestas por 4 bloques: convolución, convolución en profundidad, convolución separable y clasificación. En dicho estudio se usó una muestra de 29 sujetos sanos y 24 con depresión severa, obteniendo una precisión del 90.98% con CNN [Li et al., 2022]. También se encontró un trabajo enfocado en la predicción de depresión basado en EEG, en el cual la estrategia se validó con un conjunto de datos público eliminando el ruido de las señales del EEG para obtener los espectros de potencia de tres bandas (theta, beta y alpha) y se obtuvo una precisión del 89.63% con CNN [Liu et al., 2022b]. Otro estudio se enfocó en aclarar la eficiencia de dos medidas no lineales para la detección de la depresión en el cual se analizan señales EEG de una muestra con 23 sujetos con

depresión y 30 sanos, de lo cual se determinó la dependencia lineal de las características aplicando PCA y un análisis de correlación para determinar la influencia de la extracción de características; utilizando Perceptrón Multicapa se obtuvo una precisión del 95.12% comparado con diferentes técnicas como SVM con núcleo lineal y polinómico, Regresión Logística, Árbol de Decisión, Bosque Aleatorio y Naive Bayes [Čukić et al., 2020]. Seguidamente, se encontró un estudio en el que para el diagnóstico de la depresión sin extracción y selección de características se analizaron 5 bandas de frecuencias (delta, theta, alfa, beta y gamma) del EEG con una muestra de 34 sujetos con depresión y 30 sanos, donde el clasificador K-vecino más cercano obtuvo una precisión del 98.44% [Saedi et al., 2021]. El algoritmo Naive Bayes obtuvo una precisión del 93.30% con una muestra balanceada de 20 sujetos, donde todos los modelos se evaluaron mediante una validación cruzada de 10 veces. Los clasificadores binarios se entrenaron usando potencia de banda relativa, variabilidad de potencia alfa, índice de asimetría espectral, dimensión fractal de Higuchi, complejidad Lempel-Ziv, y análisis de fluctuación sin tendencia. Los clasificadores utilizados fueron SVM, Naive Bayes, K-vecino más cercano y análisis discriminante lineal, de los cuales Naive Bayes fue el de mayor precisión [Avots et al., 2022]. Un estudio con una muestra balanceada de 30 sujetos, desarrolló un método híbrido utilizando la arquitectura ResNet-50 preentrenado y una memoria a corto plazo (LSTM) para capturar información específica de la depresión y posteriormente se compara con un marco de Aprendizaje Automático convencional que tiene características de conectividad eMVAR la cual descompone las señales del EEG en patrones espaciales, que se extraen de 2 clases, se construye un vector de características y se usa como entrada para el clasificador para ambos marcos obteniendo una precisión del 95.9% [Uyulan et al., 2022].

Discusión

Esta Revisión Sistemática de la Literatura nos da como resultado una síntesis de la evidencia disponible sobre el uso de diferentes métodos de clasificación para la detección de depresión a través de señales electroencefalográficas, incluyendo algunos aspectos cuantitativos y cualitativos de los 20 estudios seleccionados bajo las buenas prácticas establecidas por PRISMA. Dichos trabajos se analizaron, compararon y seleccionaron según la evidencia que aportan a la investigación de las tendencias sobre la detección de depresión a través de EEG y métodos de Aprendizaje Automático. Uno de los objetivos en este trabajo fue realizar una puesta al día sobre las tendencias en el uso de diferentes métodos de clasificación de características,

así como sus fortalezas y debilidades. Se obtuvo como resultado el uso de SVM y CNN como métodos de clasificación mayormente utilizados con una precisión del 99% y 99.24% de una clasificación binaria respectivamente, y en su mayoría, los trabajos se enfocan en el lóbulo frontal y temporal del cerebro para analizar las bandas theta, betha y alpha. Actualmente todos los artículos examinados denotan pocos datos relacionados en medir los niveles de depresión, dando solamente un resultado con propiedades binarias, lo que nos proporciona una referencia para interpretar las tendencias actuales relacionadas a la detección de la depresión y proponer nuevos métodos para analizar dicho padecimiento. Los resultados obtenidos dan una justificación razonable para una mayor recopilación de datos de EEG.

Referencias

- [1] Avots, E., Jermakovs, K., Bachmann, M., Päeske, L., Ozcinar, C., and Anbarjafari (2022). Ensemble approach for detection of depression using EEG features. *Entropy*, 24.
- [2] Berger, H. (1929). Über das elektroencephalogramm des menschen. *Archiv für psychiatrie und nervenkrankheiten*, 87(1):527–570.
- [3] Cahn, B. (2006). Meditation states and traits: EEG, ERP, and neuroimaging studies. *Psychological Bulletin*.
- [4] Collell, G. (2015). Brain activity and cognition: a connection from thermodynamics and information theory. *frontiers in psychology*.
- [5] Camacho, M., Katherine, M., Rani, P., James, C., and James, J. (2018). Next generation machine learning for biological networks. *Cell*, 173:1581–1592.
- [6] Čukić, M., López, V., and Pavón, J. (2020a). Classification of depression through resting-state electroencephalogram as a novel practice in psychiatry: Review.
- [7] Duan, L., Duan, H., Qiao, Y., Sha, S., Qi, S., Zhang, X., Huang, J., Huang, X., and Wang, C. (2020). Machine learning approaches for mdd detection and emotion decoding using EEG signals. *Frontiers in Human Neuroscience*, 14.
- [8] Friston, K. (2009). Causal modelling and brain connectivity in functional magnetic resonance imaging.
- [9] Friston, K. (2002). Bayesian estimation of dynamical systems: an application to fmri. *Neuroimage*.
- [10] Gilson, M., Deco, G., Friston, J., Hagmann, P., Mantini, D., Betti, V., Romani, G., and Corbetta, M. (2018). Effective connectivity inferred from fmri transition dynamics during movie viewing points to a balanced reconfiguration of cortical interactions. *neuroimage*.
- [11] Gilson, M., Moreno-Bote, R., Ponce-Alvarez, A., Ritter, P., and Deco, G. (2016). Estimation of directed effective connectivity from fmri functional connectivity hints at asymmetries of cortical connectome. *PLOS Computational Biology*, 12:1–30.

- [12] Hughes, J. R. (2008). Gamma, fast, and ultrafast waves of the brain: Their relationships with epilepsy and behavior. *Epilepsy Behavior*, 13(1):25–31.
- [13] Hobson, J. (2002). The cognitive neuroscience of sleep: neuronal systems, consciousness and learning.
- [14] Jaworska, N., Blier, P., Fusee, W., and Knott, V. (2012). Alpha power, alpha asymmetry and anterior cingulate cortex activity in depressed males and females.
- [15] Jang, K., Kim, S., Lee, C., and Chae, J. (2021a). Machine learning-based electroencephalographic phenotypes of schizophrenia and major depressive disorder. *Frontiers in Psychiatry*, 12.
- [16] Jang, K., Kim, S., Lee, C., and Chae, J. (2021b). Machine learning-based electroencephalographic phenotypes of schizophrenia and major depressive disorder.
- [17] Kaur, C., Singh, P., and Sahni, S. (2021). Eeg artifact removal system for depression using a hybrid denoising approach. *Basic and Clinical Neuroscience*, 12.
- [18] Li, Y., Shen, Y., Fan, X., Huang, X., Yu, H., Zhao, G., and Ma, W. (2022). A novel EEG-based major depressive disorder detection framework with two-stage feature selection. *BMC Medical Informatics and Decision Making*, 22.
- [19] Liu, W., Jia, K., Wang, Z., and Ma, Z. (2022b). A depression prediction algorithm based on spatiotemporal feature of EEG signal. *Brain Sciences*, 12.
- [20] Liu, B., Chang, H., Peng, K., and Wang, X. (2022a). An end-to-end depression recognition method based on eegnet. *Frontiers in Psychiatry*, 13.
- [21] Mahato, S., Goyal, N., Ram, D. et al., Detection of Depression and Scaling of Severity Using Six Channel EEG Data., *J Med Syst* 44, 118 (2020). <https://doi.org/10.1007/s10916-020-01573-y>.
- [22] Movahed, R. A., Jahromi, G. P., Shahyad, S., and Meftahi, G. H. (2021). A major depressive disorder classification framework based on EEG signals using statistical, spectral, wavelet, functional connectivity, and nonlinear analysis. *Journal of Neuroscience Methods*, 358.
- [23] Marreiros, A., Kiebel, S., and Friston, K. (2008). Dynamic causal modelling for fmri: A two-state model. *NeuroImage*, 39(1):269–278.
- [24] Nyström, C., Matousek, M., and Hällström, T. (1986). Relationships between EEG and clinical characteristics in major depressive disorder.
- [25] Pfurtscheller, G., Stancák, A., and Neuper, C. (1996). Event-related synchronization (ers) in the alpha band — an electrophysiological correlate of cortical idling: A review. *International Journal of Psychophysiology*, 24(1):39–46. *New Advances in EEG and cognition*.
- [26] Ramsey N., M. R. (2020). *Handbook of clinical neurology*, vol. 168 (3rd series) brain-computer interfaces.
- [27] Saeedi, M., Saeedi, A., and Maghsoudi, A. (2020). Major depressive disorder assessment via enhanced k-nearest neighbor method and EEG signals. *Physical and Engineering Sciences in Medicine*, 43:1007–1018.
- [28] Sadat Shahabi, M., Shalhaf, A., and Maghsoudi, A. (2021). Prediction of drug response in major depressive disorder using ensemble of transfer learning with convolutional neural network based on eeg. *Biocybernetics and Biomedical Engineering*, 41(3):946–959.
- [29] Saeedi, A., Saeedi, M., Maghsoudi, A., and Shalhaf, A. (2021). Major depressive disorder diagnosis based on effective connectivity in EEG signals: a convolutional neural network and long short-term memory approach. *Cognitive Neurodynamics*, 15:239–252.
- [30] Thoduparambil, P. P., Dominic, A., and Varghese, S. M. (2020). EEG based deep learning model for the automatic detection of clinical depression. *Physical and Engineering Sciences in Medicine*, 43:1349–1360.
- [31] Uyulan, C., Ergüzel, T. T., Unubol, H., Cebi, M., Sayar, G. H., Asad, M. N., and Tarhan, N. (2021). Major depressive disorder classification based on different convolutional neural network models: Deep learning approach. *Clinical EEG and Neuroscience*, 52:38–51.
- [32] Uyulan, C., de la Salle, S., Erguzel, T. T., Lynn, E., Blier, P., Knott, V., Adamson, M. M., Zelka, M., and Tarhan, N. (2022). Depression diagnosis modeling with advanced computational methods: Frequency-domain emvar and deep learning. *Clinical EEG and Neuroscience*, 53:24–36.
- [33] World Health Organization, *Depression and Other Common Mental Disorders: Global Health Estimates.*, Geneva: (2017). Licence: CC BY-NC-SA 3.0 IGO.
- [34] Wang, B., Kang, Y., Huo, D., Feng, G., Zhang, J., and Li, J. (2022). Eeg diagnosis of depression based on multi-channel data fusion and clipping augmentation and convolutional neural network. *Frontiers in Physiology*, 13.
- [35] Xin, D., Xufeng, F., Xiangwei, L., and Kaiwei, S. (2022). Sparnet: A convolutional neural network for EEG space-frequency feature learning and depression discrimination. *Frontiers in Neuroinformatics*, 16.
- [36] Zhu, J., Wang, Z., Gong, T., Zeng, S., and Li, X. (2020). An improved classification model for depression detection using eeg and eye tracking data. *IEEE Trans Nanobioscience*.