



**Universidad**®  
**de Medellín**  
Ciencia y Libertad

**Maestría en Modelación y Ciencia Computacional**  
**Facultad de Ciencias Básicas**

**Machine learning aplicado a la predicción y clasificación de la  
depresión, un enfoque hacia la gestión de la salud mental.**

**Trabajo de grado de maestría:**  
**Tipo artículo científico**

**Para Optar por el Título de**  
**Magister en Modelación y Ciencia Computacional**

**Presenta**

Sebastián Osorio Castrillón

**Directora**

Lillyana Maria Giraldo Marin. Phd. ()

**Codirector**

Herman Horacio Jaramillo Villegas. Phd. ()

**Medellín, junio 2022**

## CONTENIDO

<b>1. INTRODUCCIÓN</b> .....	<b>5</b>
<b>2. PLANTEAMIENTO DEL PROBLEMA</b> .....	<b>8</b>
<b>3. ESTADO DEL ARTE</b> .....	<b>9</b>
3.1 DEFINICIÓN DEL TEMA Y PREGUNTAS DE INVESTIGACIÓN .....	10
3.2 DEFINICIÓN TÉRMINOS DE BÚSQUEDA Y BASE DE DATOS .....	10
3.3 SELECCIÓN DE ARTÍCULOS .....	11
3.4 RESULTADOS .....	14
<b>4. CASO PRÁCTICO</b> .....	<b>19</b>
4.1 DEFINICIÓN BASE DE DATOS .....	20
4.2 RESUMEN BASE DE DATOS .....	21
4.4 ANÁLISIS DESCRIPTIVO DE LOS DATOS .....	24
4.5 IMPLEMENTACIÓN DEL MODELO .....	27
<b>5. DISCUSIÓN</b> .....	<b>31</b>
<b>6. CONCLUSIONES</b> .....	<b>33</b>
<b>7. REFERENCIAS</b> .....	<b>35</b>
<b>8. APORTES O PRODUCTOS DE CONOCIMIENTO</b> .....	<b>41</b>
<b>ANEXOS</b> .....	<b>43</b>

## Índice de figuras

FIGURA 1 - NÚMERO DE PUBLICACIONES POR AÑO.....	12
FIGURA 2 - “ESPACIO LITERARIO RELEVANTE” .....	13
FIGURA 3 - METODOLOGÍAS ESTADÍSTICAS UTILIZADAS PARA PREDECIR LA DEPRESIÓN U OTRAS ENFERMEDADES MENTALES.....	17
FIGURA 4 - VARIABLES PREDICTORAS DE LA DEPRESIÓN.....	18
FIGURA 5 - PROCESO MODELACIÓN PYCARET .....	20
FIGURA 6 – DEPRESIÓN POR EDAD.....	25
FIGURA 7- DEPRESIÓN POR GÉNERO.....	26
FIGURA 8 - DEPRESIÓN POR COMORBILIDADES.....	27
FIGURA 9 – INDICADORES EFECTIVIDAD DEL MODELO.....	28
FIGURA 10 - CURVA ROC .....	29
FIGURA 11 - VARIABLES MÁS SIGNIFICATIVAS.....	30
FIGURA 12 - MATRIZ DE CONFUSIÓN.....	31

## **Anexos**

<b>ANEXO A - CÓDIGO PYTHON</b> .....	43
<b>ANEXO B - PUBLICACIÓN DE ARTÍCULO 1</b> .....	46
<b>ANEXO C - PUBLICACIÓN ARTÍCULO 2</b> .....	59
<b>ANEXO D - PONENCIA</b> .....	69

## 1. Introducción

Según los últimos hallazgos de la organización mundial de la salud, casi mil millones de personas –entre ellas un 14% de los adolescentes de todo el mundo– son afectadas por un trastorno mental. Los suicidios representan más de una de cada 100 muertes y el 58% de ellos ocurren antes de los 50 años. Los trastornos mentales son la principal causa de discapacidad y son responsables de uno de cada seis años vividos con discapacidad. Las personas con trastornos mentales graves mueren en promedio de 10 a 20 años antes que la población general, la mayoría de las veces por enfermedades físicas prevenibles. Los abusos sexuales en la infancia y el acoso por intimidación son importantes causas de depresión. Las desigualdades sociales y económicas, las emergencias de salud pública, las guerras y las crisis climáticas se encuentran entre las amenazas estructurales para la salud mental presentes en todo el mundo. (OMS, 2019)

El rol de las aseguradoras en salud es determinante a la hora de mitigar el aumento observado en los últimos años de la prevalencia en desórdenes mentales, Colombia específicamente ha venido transformando los procesos de gestión de sus afiliados, pasando de una gestión reactiva a una gestión proactiva de los mismos, es decir, priorizando la prevención e implementación de acciones que favorezcan y prioricen la salud en sus dimensiones físicas, mentales y sociales, y no solo que mitiguen la enfermedad (OMS, 2016).

Sin embargo, estos procesos de gestión no solamente son complejos desde la parte conceptual, sino que por sus múltiples fuentes de información generan grandes volúmenes de datos, y el procesamiento de estos a través de técnicas de aprendizaje automático o *machine learning* resulta determinante a la hora de garantizar resultados efectivos, pues estas técnicas permiten la implementación de modelos con alta precisión y es por esto que se ha convertido en

una de las vías más utilizadas a la hora de apoyar el sistema de salud en la predicción, detección y prevención de enfermedades mentales (Tran & Kavuluru, 2017), lo cual garantiza que el uso de modelos estadísticos es un método apropiado para el fin descrito en este artículo acerca de la predicción de enfermedades mentales, específicamente la depresión que es una enfermedad frecuente en todo el mundo, y que se calcula que afecta a más de 300 millones de personas, siendo la causa del suicidio de cerca de 800.000 personas al año, y a su vez la segunda causa de muerte en el grupo etario de 15 a 29 años (OMS, 2021).

Este trabajo de investigación tiene como finalidad realizar un estado del arte sobre las técnicas estadísticas de clasificación y predicción de la depresión, y cómo éstas apalancan la gestión de las personas afiliadas a las diferentes aseguradoras en salud de Colombia, adicionalmente contrastar a través de la implementación de un caso real, la hipótesis de cuáles son los modelos que darían respuesta de manera más adecuada a la predicción de la depresión. Para dicho fin se realizó la lectura detallada de diferentes artículos seleccionados bajo la metodología de revisión sistemática de literatura (RSL) propuesta por Jorge Iván Pérez Rave (Pérez Rave, J. 2019), la cual plantea que, en un mundo inundado por océanos de datos e información, es cada vez más retador afrontar de forma eficaz, eficiente y reproducible la búsqueda, la evaluación, la selección y el análisis del espacio literario relevante (ELR). Este representa lo poco que es vital localizar y comprender, con el fin de inducir condiciones actuales y desafíos de estudio que permitan dar mayor originalidad y valor a los proyectos por emprender.

Para realizar la evaluación, selección y análisis efectivo del material que permitiría dar respuesta a la problemática planteada sobre la transformación de la gestión de los afiliados por parte de las aseguradoras en salud, y el apoyo que brinda la estadística a través de diferentes métodos analíticos para la toma estratégica de decisiones ante qué y cómo abordar las enfermedades mentales, se definieron las siguientes preguntas:

- ¿Cuáles son los principales métodos de machine learning utilizados para la predicción de la depresión?
- ¿De los principales métodos utilizados para la predicción de la depresión cuáles tienen mayor precisión?
- ¿Qué variables son indispensables a la hora de predecir la depresión?
- ¿Existen criterios estadísticos para la clasificación de la depresión?
- ¿Cuál es el estado actual y los desafíos investigativos de los modelos estadísticos aplicados a la predicción de la depresión?

Entre los resultados obtenidos de la RSL se encontró que las principales metodologías para la predicción de sucesos clínicos, específicamente las enfermedades mentales, son los modelos de Support Vector Machine (SVM), la regresión lineal y logística, los bosques aleatorios; y que los diferentes indicadores de neuroimágenes, los síntomas depresivos, la edad y el género se convierten en variables predictoras fundamentales a la hora de anticipar la depresión. En cuanto a las metodologías de clasificación, se identificó que el método Montgomery Asberg Depression Rating Scale (MADRS) basado en preguntas relacionadas con estados de tristeza, pérdida de sueño, disminución del apetito, dificultades de concentración, pensamientos pesimistas e ideación suicida (Inieta et al., 2016), es de los más utilizadas según la literatura.

Desde estos hallazgos se procedió a ilustrar un caso práctico utilizando PyCaret, la cual es una herramienta integral de gestión de Machine Learning de código abierto en Python, que automatiza los flujos de trabajo y acelera potencialmente el ciclo de experimentación volviéndolo más productivo (Moez Ali, 2020).

En el desarrollo de este informe se detalla la metodología de selección y análisis de los artículos a revisar según la técnica de RSL descrita anteriormente, así mismo las respuestas a

cada una de las preguntas planteadas que abren un camino de posibilidades al desarrollo de las técnicas identificadas para realizar la predicción de enfermedades mentales. Por último, se ilustra el caso práctico donde se implementan diferentes modelos para contrastar con datos reales la información obtenida, y finalmente los productos de conocimiento derivados del trabajo realizado.

## **2. Planteamiento del problema**

En los últimos años, se ha destacado de manera significativa el rol que desempeña la salud mental en el logro de los objetivos de desarrollo mundial, como lo ilustra la inclusión de la salud mental en los Objetivos de Desarrollo Sostenible (ODS, 2021). La depresión es una de las principales causas de discapacidad y el suicidio es la segunda causa principal de muerte entre los jóvenes de 15 a 29 años. Las personas con afecciones mentales graves mueren prematuramente, hasta dos décadas antes, debido a afecciones físicas prevenibles. (OMS, 2019).

Los sistemas de salud todavía no han dado una respuesta adecuada a la carga de trastornos mentales; en consecuencia, la divergencia entre la necesidad de tratamiento y su prestación es grande en todo el mundo. En los países de ingresos bajos y medios, entre un 76% y un 85% de las personas con trastornos mentales graves no reciben tratamiento; la cifra es alta también en los países de ingresos elevados: entre un 35% y un 50%. El problema se complica aún más por la escasa calidad de la atención que reciben los casos tratados (OMS, 2012).

Aunque hay tratamientos conocidos y eficaces contra los trastornos mentales, más del 75% de las personas afectadas en los países de ingresos bajos y medianos no recibe tratamiento alguno. Entre los obstáculos a una atención eficaz se encuentran la falta de recursos y de

proveedores de atención de salud capacitados, además de la estigmatización asociada a los trastornos mentales (OMS, 2021).

Otra barrera para la atención eficaz es la evaluación errónea. Por lo cual se hace indispensable encontrar características biológicas que sean informativas en términos de diagnóstico, pronóstico y tratamiento a través de herramientas estadísticas (O'Halloran et al., 2016). En países de todo tipo de ingresos, las personas con depresión a menudo no son correctamente diagnosticadas, mientras que otras, que en realidad no la padecen, son a menudo diagnosticadas erróneamente y tratadas con antidepresivos (OMS, 2020). Por lo cual se hace indispensable el conocimiento y validación de las diferentes técnicas para la clasificación de la depresión las cuales permitirían realizar una gestión adecuada de las personas, pues las condiciones de salud mental pueden tener un efecto sustancial en todas las áreas de la vida, como el desempeño escolar o laboral, las relaciones con la familia y los amigos y la capacidad de participar en la comunidad. Dos de las afecciones de salud mental más comunes, la depresión y la ansiedad, cuestan a la economía mundial cerca un billón de dólares cada año, sin embargo, el gasto público en salud que se destina a la salud mental es aproximadamente inferior al 2% (OMS, 2020).

### **3. Estado del arte**

La respuesta a la pregunta planteada acerca del tema de interés "Machine learning aplicada a la predicción y clasificación de enfermedades mentales" se abordó a través de la metodología planteada por Jorge Ivan Pérez Rave la cual incluye conceptos como (ELR) lo cual representa lo poco que es vital de localizar y comprender para inducir condiciones actuales y desafíos de estudio que permitan dar mayor originalidad y valor a los proyectos por emprender (Pérez Rave, J. 2019). Para seguir dicha metodología se implementaron los siguientes pasos:

- Definición del tema
- Definición preguntas de investigación
- Definición términos de búsqueda y base de datos
- Selección de artículos
- Resultados

### **3.1 Definición del tema y preguntas de investigación**

Como se expuso anteriormente, el tema de interés son los métodos de machine learning aplicados a la predicción y clasificación de las enfermedades mentales. Para dar respuesta a dicha pregunta se formularon las siguientes 5 preguntas:

- **P1.** ¿Cuáles son los principales métodos de machine learning utilizados para la predicción de la depresión?
- **P2.** ¿De los principales métodos utilizados para la predicción de la depresión cuáles tienen mayor precisión?
- **P3.** ¿Qué variables son indispensables a la hora de predecir la depresión?
- **P4.** ¿Existen criterios estadísticos para la clasificación de la depresión?
- **P5.** ¿Cuál es el estado actual y los desafíos investigativos de los modelos estadísticos aplicados a la predicción de la depresión?

### **3.2 Definición términos de búsqueda y base de datos**

La búsqueda se realizó en la base de datos SCOPUS, principalmente por la facilidad con la que permite analizar y visualizar diferentes indicadores bibliométricos como la cantidad de citas de los artículos, el año de publicación, los autores, el tipo de artículo, etc. Así mismo, por la completitud y sustento científico del contenido que ofrece. La búsqueda se realizó en Agosto de 2021.

Para la definición de la ecuación de búsqueda se garantizó que contuviera los principales términos relacionados con el tema de interés, como: Machine learning – depression, prediction y que cumpliera con los siguientes criterios de inclusión:

- Artículos científicos
- Estado finalizado
- Últimos 6 años (incluyendo 2021)
- Mayor relevancia (número de citas) - Artículos con mínimo una citación
- Idioma inglés
- Áreas de ciencia computacional y medicina

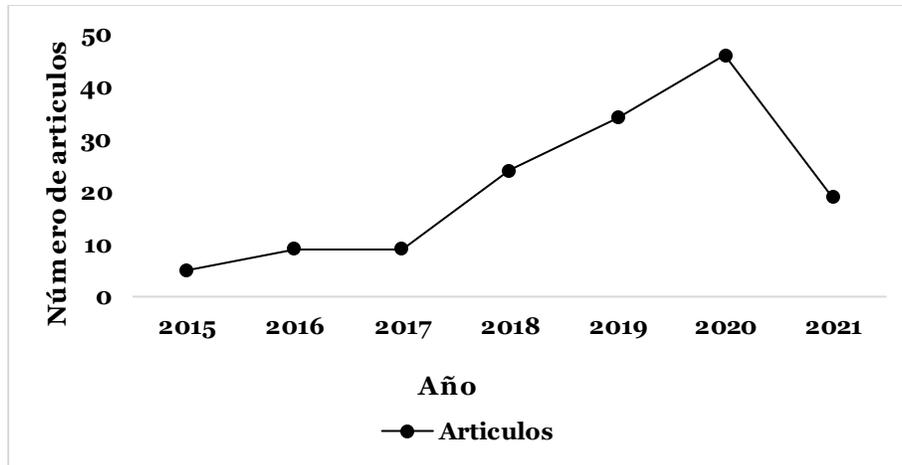
Con lo cual resulta la siguiente ecuación de búsqueda:

**( TITLE-ABS-KEY ( depression AND prediction ) AND TITLE-ABS-KEY ( machine AND learning ) ) AND ( LIMIT-TO ( OA , "all" ) ) AND ( LIMIT-TO ( PUBSTAGE , "final" ) ) AND ( LIMIT-TO ( PUBYEAR , 2021 ) OR LIMIT-TO ( PUBYEAR , 2020 ) OR LIMIT-TO ( PUBYEAR , 2019 ) OR LIMIT-TO ( PUBYEAR , 2018 ) OR LIMIT-TO ( PUBYEAR , 2017 ) OR LIMIT-TO ( PUBYEAR , 2016 ) OR LIMIT-TO ( PUBYEAR , 2015 ) ) AND ( LIMIT-TO ( SUBJAREA , "MEDI" ) OR LIMIT-TO ( SUBJAREA , "COMP" ) ) AND ( LIMIT-TO ( DOCTYPE , "ar" ) ) AND ( LIMIT-TO ( LANGUAGE , "English" ) )**

Implementando dicha ecuación en la base de datos definido (SCOPUS), se obtuvieron como resultado un total de 146 artículos. De estos, cerca del 50% tenía 7 o más citas, quedando así con 73 artículos por revisar.

### **3.3 Selección de artículos**

Antes de realizar la selección de los artículos finales a revisar sobre los 72 posibles, se revisó la vigencia del tema, con la cual se pretendía identificar gráficamente el crecimiento en el tiempo del número de artículos relacionados con el tema de interés, y por ende la relevancia que ha venido tomando el tema. En la figura 1.



*Figura 1 - Número de publicaciones por año.  
Fuente: (Scopus 2021)*

Se observa que la cantidad de artículos sobre el tema de interés ha crecido significativamente desde el año 2015, (periodo inicial definido para búsqueda de los artículos) hasta la fecha, teniendo en cuenta que el descenso que se observa en el año 2021 es debido a que de este año se tuvieron en cuenta solo 8 meses.

Finalmente se realizó un análisis de relevancia de los artículos “Espacio literario relevante” (Pérez Rave, J. 2019), con el cual se pretendía identificar el número de artículos que representarían la mayor proporción de citas totales. Concluyendo que, de los **72 artículos posibles a revisar**, el 50.7% (**aproximadamente 36**) representan el 80% de las citas, como se observa en la figura 2.

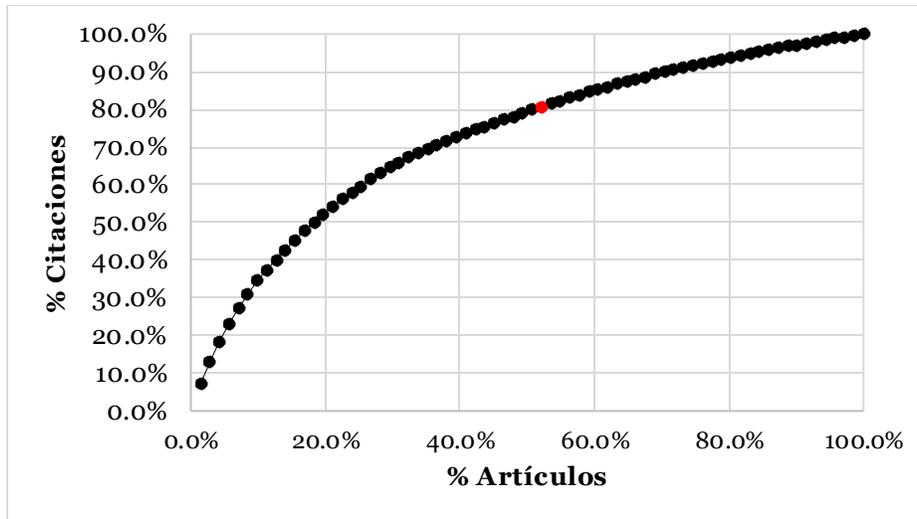


Figura 2 - "Espacio literario relevante".

Fuente: Elaboración propia a partir de la metodología de revisión sistemática de literatura del autor PEREZ-RAVE.

Finalmente, se hizo una revisión detallada de los resúmenes de los 36 artículos concluyendo que eran objeto de revisión y aportarían valor al desarrollo de la revisión sistemática de literatura 24 artículos. Ver tabla 1

Tabla 1 - Artículos seleccionados. Fuente: Elaboración propia

#	Título	Autor	Citas	Año
1	Prediction of individual response to electroconvulsive therapy via machine learning on structural magnetic resonance imaging data	(Redlich et al., 2016)	141	2016
#	Título	Autor	Citas	Año
2	Prediction Models of Functional Outcomes for Individuals in the Clinical High-Risk State for Psychosis or with Recent-Onset Depression: A Multimodal, multisite Machine Learning Analysis	(Koutsouleris et al., 2018)	114	2018
3	Testing a machine-learning algorithm to predict the persistence and severity of major depressive disorder from baseline self-reports	(Kessler et al., 2016)	109	2016
4	Mobile sensing and support for people with depression: A pilot trial in the wild	(Wahle et al., 2016)	91	2016
5	Identifying a clinical signature of suicidality among patients with mood disorders: A pilot study using a machine learning approach	(Passos et al., 2016)	83	2016
6	Machine learning approaches for integrating clinical and imaging features in late-life depression classification and response prediction	(Patel et al., 2015)	74	2015

7	Combining clinical variables to optimize prediction of antidepressant treatment outcomes	(Iniesta et al., 2016)	73	2016
8	Utilization of machine learning for prediction of post-traumatic stress: A re-examination of cortisol in the prediction and pathways to non-remitting PTSD	(Galatzer-Levy et al., 2017)	53	2017
9	Scaling tree-based automated machine learning to biomedical big data with a feature set selector	(Le et al., 2020)	47	2020
10	Smart Home-Based Prediction of Multidomain Symptoms Related to Alzheimer's Disease	(Alberdi et al., 2018)	41	2018
11	Design and implementation of a standardized framework to generate and evaluate patient-level prediction models using observational healthcare data	(Reps et al., 2018)	36	2018
12	Predicting the naturalistic course of depression from a wide range of clinical, psychological, and biological data: a machine learning approach	(Dinga et al., 2018)	34	2018
13	Classification of Suicide Attempts through a Machine Learning Algorithm Based on Multiple Systemic Psychiatric Scales	(Oh et al., 2017)	33	2017
14	Artificial Intelligent System for Automatic Depression Level Analysis Through Visual and Vocal Expressions	(Jan et al., 2018)	32	2018
15	Predicting mental conditions based on "history of present illness" in psychiatric notes with deep neural networks	(Tran & Kavuluru, 2017)	31	2017
16	Detecting suicidal ideation on forums: Proof-of-concept study	(Aladag et al., 2018)	26	2018
17	Evaluating the diagnostic utility of applying a machine learning algorithm to diffusion tensor MRI measures in individuals with major depressive disorder	(Schnyer et al., 2017)	25	2017
18	Association Between Negative Cognitive Bias and Depression: A Symptom-Level Approach	(Beevers et al., 2019)	20	2019
19	Correlation analysis to identify the effective data in machine learning: Prediction of depressive disorder and emotion states	(Kumar & Chong, 2018)	18	2018
20	Development of a clinical forecasting model to predict comorbid depression among diabetes patients and an application in depression screening policy making	(Jin et al., 2015)	18	2015
21	Prediction of pediatric unipolar depression using multiple neuromorphometric measurements: A pattern classification approach	(Wu et al., 2015)	18	2015
22	Suicide detection in Chile: Proposing a predictive model for suicide risk in a clinical sample of patients with mood disorders	(Barros et al., 2017)	18	2017
<b>#</b>	<b>Título</b>	<b>Autor</b>	<b>Citas</b>	<b>Año</b>
23	Use of a machine learning algorithm to predict individuals with suicide ideation in the general population	(Ryu et al., 2018)	18	2018
24	Multimodal neuroimaging-informed clinical applications in neuropsychiatric disorders	(O'Halloran et al., 2016)	17	2016

### 3.4 Resultados

Para dar respuesta a las preguntas de investigación planteadas, se realizó la lectura completa de los 24 artículos seleccionados con la metodología descrita anteriormente, a cada

uno de éstos se les construyó una ficha técnica en la que se incluyeron los componentes más relevantes, tales como el propósito general del artículo, cómo daba respuesta a la(s) pregunta(s) de investigación, qué preguntas quedaban sin responder y el resumen. Adicionalmente se construyó una tabla de características matriciales en la cual se relacionaba cada artículo con las 5 preguntas planteadas con el fin de sintetizar, resumir e interpretar de manera más clara las respuestas a las preguntas de investigación y poder identificar patrones entre estas.

**P1.** ¿Cuáles son los principales métodos de machine learning utilizados para la predicción de la depresión?

Por la naturaleza y complejidad de la depresión, se vuelve indispensable validar, probar y mezclar diferentes metodologías que ayuden a integrar variables de diferente índole para poder obtener los resultados más precisos posibles a la hora de apoyar al sector salud en el diagnóstico/gestión de la salud mental (Kumar & Chong, 2018).

Desde esta perspectiva se puede observar que, en los hallazgos, 6 de los artículos analizados utilizaron la metodología de random forest [16,10,24,15,18,23] como metodología para la predicción de la depresión, representado un 25 % de los artículos revisados, alcanzando precisiones de hasta el 78% con este tipo de metodologías por su capacidad de categorizar y representar las diferentes condiciones de los individuos a analizar (Ryu et al., 2018).

Adicionalmente se observa que la metodología SVM con sus siglas en inglés o Máquina de Soporte Vectorial también hace parte de las más utilizadas según la literatura, a la hora de predecir la depresión como lo evidencian los [24,15,3,2,8,18], representado el 25 % de los artículos revisados. Sin embargo, es importante aclarar que la inclusión de variables biológicas y de neuroimágenes a este tipo de modelos podría mejorar significativamente su precisión (O'Halloran et al., 2016).

La regresión, con sus diferentes adaptaciones, principalmente la lineal y la logística hacen parte también de las más utilizadas a la hora de clasificar o predecir individuos con alguna condición específica, en este caso la depresión, se observa que en los artículos [18,24,11,12,14,7,8] las utilizan para perfilar a las personas según sus condiciones mentales, representando 29 % del total de los artículos revisados.

Es importante tener en cuenta que la regresión requiere una representación suficiente de las colas en la escala objetivo para aprender un patrón predictivo que explique el rango completo de la escala (Koutsouleris et al., 2018).

Las redes neuronales, árboles de decisión, los procesos gaussianos, y los clústeres son a su vez metodologías que también han sido utilizadas según la literatura. Para este tipo de metodologías la recopilación de más datos es útil, con el fin de tener un conjunto de datos completo con casos confirmados de transición de un estado saludable a un deterioro cognitivo, lo cual es necesario para construir modelos de predicción precisos (Alberdi et al., 2018).

En la figura 3 se puede observar de manera gráfica, cuáles son los principales modelos estadísticos utilizados para la predicción de la depresión.

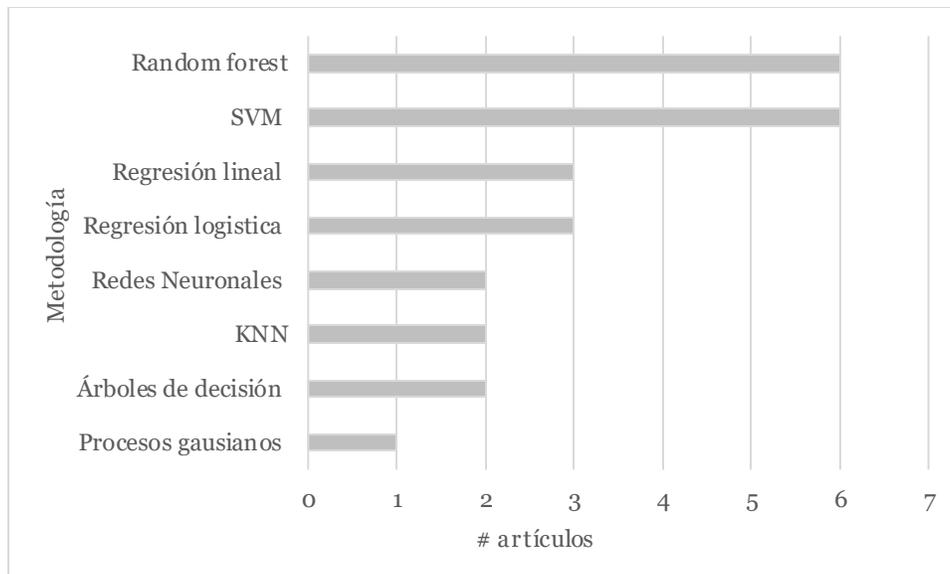


Figura 3 – Métodos de machine learning utilizados para predecir la depresión u otras enfermedades mentales.

Fuente: Elaboración propia

**P2.** ¿De los principales métodos utilizados para la predicción de la depresión cuáles tienen mayor precisión?

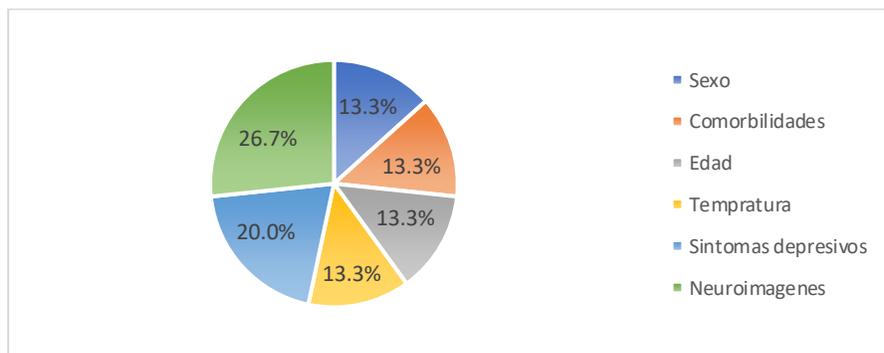
Según la literatura, los modelos estadísticos con mayor precisión a la hora de predecir la depresión son: el SVM [Artículos 2,18]) principalmente por su sensibilidad a mediciones neuromorfométricas (Wu et al., 2015). Así mismo la Red neuronal convolucional hace parte de los modelos más precisos pues admite y procesa de manera efectiva una breve descripción textual de la historia del paciente de la enfermedad actual (Tran & Kavuluru, 2017).

Si bien es importante hacer validaciones para determinar cuál es el mejor modelo, existen herramientas *Auto Machine Learning (AutoML)* que automáticamente determinan cuáles son los mejores modelos de acuerdo con las variables de entrada, y cuya implementación se detallará más adelante. En el artículo 13 relacionan la herramienta de optimización de tuberías basada en árboles y selección de conjuntos de características (TPOT-FSS), definida como la primera herramienta de AutoML que ofrece la opción de selección de funciones a nivel de grupo. Los

TPOT-FSS pueden identificar el grupo de características más significativo para incluir en la tubería de predicción. Aplicamos TPOT-FSS a datos de RNA-Seq (técnica que puede examinar la cantidad y las secuencias de ARN en una muestra) del mundo real para demostrar la identificación de grupos de genes biológicamente relevantes (Galatzer-Levy et al., 2017).

**P3. ¿Qué variables son indispensables a la hora de predecir la depresión?**

Entre las principales variables utilizadas para la predicción de la depresión se encuentran las neuroimágenes con su mayor frecuencia, relacionadas en los artículos [19,3,7,2] seguido de los síntomas depresivos relacionados en los artículos [16,14,23]. La temperatura y comportamientos atmosféricos aparece también entre las variables utilizadas para predecir la depresión, los autores también definen que [artículo 5] el sexo, la edad y las diferentes comorbilidades presentes en los individuos hacen parte de las variables a tener en cuenta para la predicción de la depresión. Ver Figura 4.



*Figura 4 - Variables predictoras de la depresión  
Fuente: Elaboración propia*

**P4. ¿Existen criterios estadísticos para la clasificación de la depresión?**

En términos generales no existe un patrón a la hora de clasificar estadísticamente la depresión según la literatura revisada, sin embargo, sí hay clasificaciones basadas en información

cualitativa y cuestionarios que permiten determinar la complejidad de cada caso y establecer criterios de complejidad a las predicciones.

En el artículo [12], los autores relacionan la escala de clasificación de depresión de asberg (MADRS) la cual se basa en preguntas relacionadas con estados de tristeza, pérdida de sueño, disminución del apetito, dificultades de concentración, pensamientos pesimistas e ideación suicida (Inieta et al., 2016). Adicionalmente, en el artículo [17] los autores relacionan la escala de depresión de Beck el cual es un cuestionario de 21 items con escala de tipo *Likert*, la cual es una escala psicométrica utilizada principalmente en investigaciones sociales (Jan et al., 2018).

**P5.** ¿Cuál es el estado actual y los desafíos investigativos de los modelos estadísticos aplicados a la predicción de la depresión?

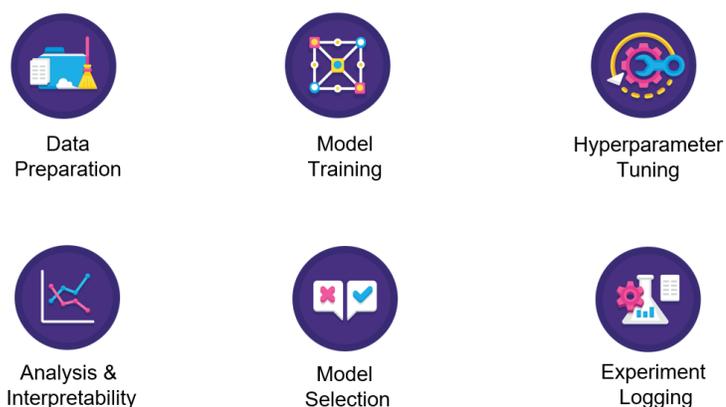
Se evidencia un uso demostrativo de las metodologías para la predicción de la depresión, sin embargo, existen retos a la hora de precisar los diagnósticos sobre depresión, sobre todo en la inclusión de neuroimágenes, pues la organización del cerebro es la causa más próxima de los trastornos psiquiátricos y la neuroimagen proporciona una herramienta invaluable para identificar y caracterizar características clínicamente informativas (O'Halloran et al., 2016).

Una vez analizados los hallazgos expuestos, se procede a realizar el caso práctico, con el objetivo de dar respuesta a una de las hipótesis planteadas por algunos de los autores de los artículos de la RSL.

#### **4. Caso práctico**

Como se demostró anteriormente, la literatura sugiere algunos modelos específicos de Machine Learning para abordar la predicción de la depresión, tales como SVM (Support Vector

Machine), regresión logística, entre otros; también se evidenció que existen herramientas de auto machine learning que permiten la validación simultánea y eficiente de diferentes modelos, entre éstas: PyCaret, la cual es una herramienta integral de gestión de Machine Learning de código abierto en Python, que automatiza los flujos de trabajo y acelera potencialmente el ciclo de experimentación volviéndolo más productivo. (Moez Ali, 2020). A continuación, se enuncian los pasos que utiliza la herramienta para llegar a la modelación.



*Figura 5 - Proceso modelación PyCaret*  
*Fuente: Herramienta PyCaret – (Moez Ali, 2020)*

#### **4.1 Definición Base de datos**

La base de datos se obtuvo de información real de una aseguradora en salud de Colombia, la cual se encuentra bajo las normas de protección de datos, pues no expone información sensible a nivel de persona, que permita identificarla o conocer su historial médico, y es utilizada con fines netamente académicos.

La variable respuesta está dada en términos de la presencia de depresión, la cual se identificó por medio de los diagnósticos debidamente codificados según la “Clasificación Internacional de Enfermedades” CIE 10, que puede definirse como un sistema de categorías mutuamente excluyentes a las cuales se asignan enfermedades, lesiones y motivos de consulta de acuerdo con criterios previamente establecidos. La clasificación abarca todo el rango de enfermedades existentes en la terminología médica (nomenclatura internacional de enfermedades) (OMS, 2015).

Para el caso en estudio se garantizó que las personas tuvieran el siguiente diagnóstico, en los últimos 6 meses:

**Diagnóstico:** TRASTORNO MIXTO DE ANSIEDAD Y DEPRESIÓN

**Subcategoría Diagnóstica** OTROS TRASTORNOS DE ANSIEDAD

**Categoría Diagnóstica** TRASTORNOS NEUROTICOS, TRASTORNOS RELACIONADOS CON EL ESTRÉS Y TRASTORNOS SOMATOMORFOS

#### **4.2 Resumen base de datos**

En total se trabajó con una muestra de 81.601 personas (este número de personas fueron elegidas por la disponibilidad de la información, la veracidad y la consistencia) de ellas, el 5.21% cumplían con la condición de haber tenido alguna prestación en salud asociada a un diagnóstico de depresión en los últimos 6 meses, definición acogida para la clasificación de las personas que permitirían el entrenamiento del modelo y el ajuste de la predicción. La variable por predecir sería binaria y correspondería a si la persona tiene o no depresión: Depresión (Si/No). En total se cuenta con 16 variables de las cuales 8 son numéricas y 8 categóricas. A continuación, se resume la BD y se definen cada una de las variables.

- Número de registros: 81,601
- Target Ind: Depresión
- Tipo Target: Binaria
- Variables numéricas: 8
- Variables categóricas: 8

### Definición de variables

- **Ind\_afiliado:** Identificador que permite identificar de manera única a la persona sin revelar su número de identificación, dada la confidencialidad de la información.
- **Ind\_Depresion:** Target (Variable respuesta) Indica si la persona presentó algún diagnóstico de depresión en los últimos 6 meses
- **Nivel\_ingresos:** Ingresos económicos de la persona, siendo A el más bajo y C el más alto
- **Utilizaciones:** Número de servicios en salud utilizados por la persona
- **Edad\_Actual:** Edad de la persona al momento de la consulta
- **Indice\_masa:** Relación matemática entre peso y talla, dada por la siguiente fórmula

$$x = \frac{\text{Peso}}{\text{Estatura}^2}$$

- **Rango\_IMC:** Clasificación de la relación Peso-Talla descrita en la variable anterior dado por las siguientes categorías:
  - Normal

- Obesidad grado 1
  - Obesidad grado 3
  - Sobrepeso
  - Obesidad grado 2
  - Delgadez
- **Concatenación:** Concatenación de las diferentes comorbilidades de la persona
- **Numero\_Marca\_Afiliado:** Número de comorbilidades de la persona
- **Clasificacion\_salud:** Estado de salud de la persona, de acuerdo con las siguientes categorías:
- Enfermo Presuntivo: Personas con presencia de una o tres enfermedades
  - Sano Presuntivo: Personas sin ninguna enfermedad
  - Enfermo: Personas con más de 3 enfermedades
  - Condición de riesgo: Personas con condiciones de riesgo que no los condicionan a una enfermedad específicamente (Ejemplo: Embarazo)
- **Regimen\_txt:** Si la persona pertenece al régimen subsidiado o contributivo
- **Sexo\_Cd:** Sexo
- **Regional:** Ubicación geográfica de la persona, clasificadas así:
- Pereira
  - Bogotá
  - Medellín
  - Santa Marta
  - Cali
  - Barranquilla
  - Cartagena

- Armenia
  - Manizales
  - Bucaramanga
  - Popayán
  - Tunja
- **Ind\_PAC:** Determina si la persona tiene acceso a planes complementarios en salud
  - **Antigüedad:** Número de años afiliado al sistema de salud
  - **Costo:** Costo del uso de servicio de las utilidades

#### **4.4 Análisis descriptivo de los datos**

A continuación, se relaciona una descripción general de las principales variables tenidas en cuenta para la modelación. Es importante resaltar que en gran medida, dichas variables fueron seleccionadas partiendo de los resultados de la revisión sistemática de la literatura donde se sugería que el sexo, la edad y la presencia de enfermedades eran posibles variables explicativas de la presencia de la depresión.

##### **Análisis por edad**

Se analizó la variable edad desagregándola por la variable explicativa; depresión, se observó que el 80% de personas con presencia de ésta se encuentran entre 18 y 66 años, mientras que en las edades extremas (Menores de 18 y mayores de 66 años) los porcentajes disminuyen.

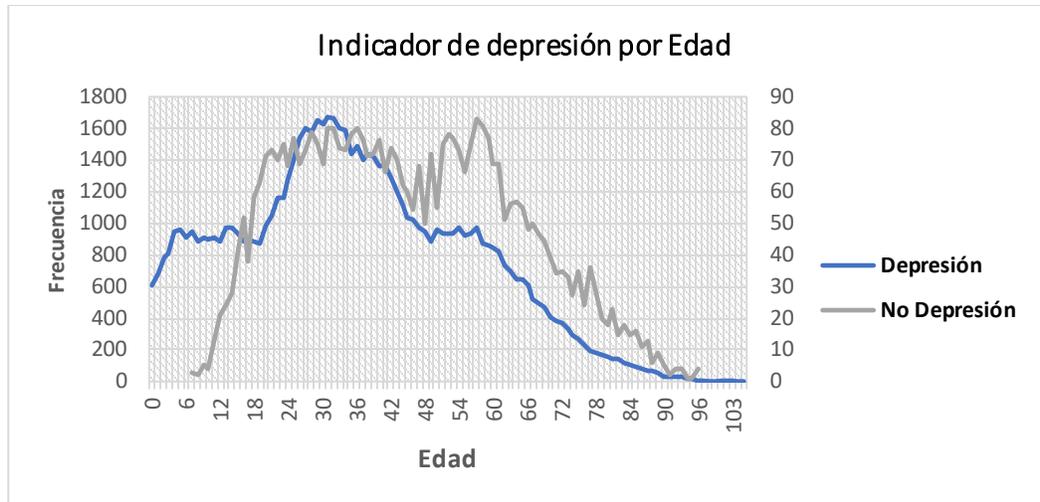


Figura 6 – Depresión por Edad  
Fuente: Elaboración Propia

La edad promedio de quienes tienen indicios de padecer la enfermedad es: 44 años, mientras que la edad promedio de aquellos que no la presentan es de 35 años.

### Análisis por género

Según la revisión sistemática de la literatura, el sexo es una variable importante a la hora de hablar de depresión, se observa en los datos reales, que ésta se da en mayor proporción en mujeres, con un 73.92% de participación VS un 26% de participación en hombres.

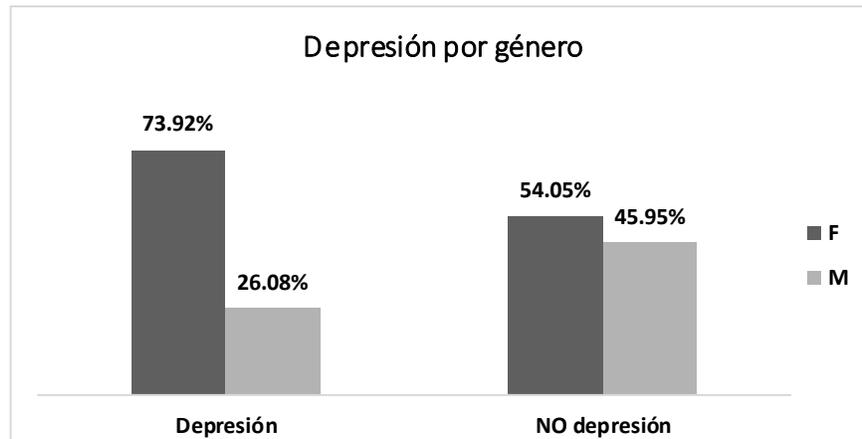
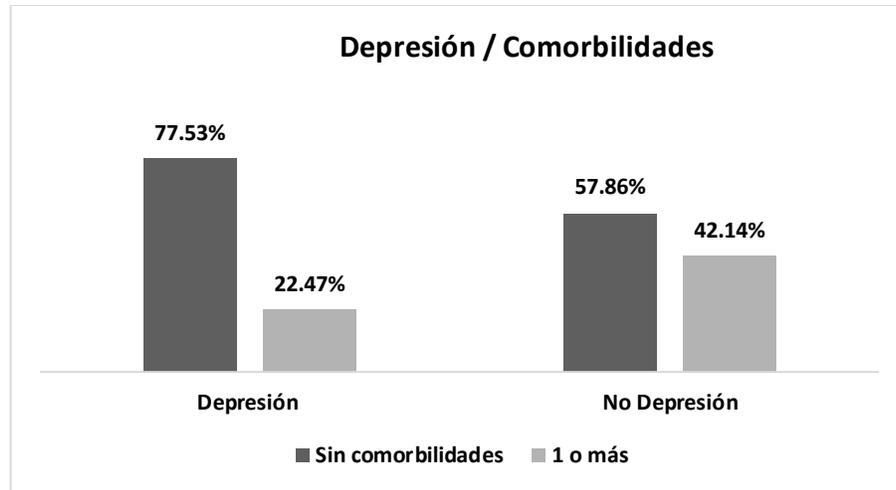


Figura 7- Depresión por género  
Fuente: Elaboración propia

### Análisis por comorbilidades

Al igual que el género la variable de comorbilidades, resulta significativa a la hora de predecir la depresión y según la información recolectada, de las personas que presentan depresión, el 77.5% tienen al menos una comorbilidad, definida como la presencia de por lo menos una enfermedad entre las siguientes:

- Hipertensión
- Diabetes
- Dislipidemia
- Epoc
- Enfermedad Cardiovascular
- Insuficiencia Cardíaca
- Cáncer
- Enfermedades Huérfanas
- Artritis
- Enfermedad Autoinmune
- Enfermedad Cerebrovascular
- Enfermedad hereditaria de la coagulación
- Epilepsia
- Enfermedad Renal Crónica
- VIH
- Trasplante



*Figura 8 - Depresión por Comorbilidades*  
Fuente: Elaboración Propia

#### 4.5 Implementación del modelo

Previo a la implementación del modelo bajo la herramienta de PyCaret descrita inicialmente, es importante determinar el tipo de análisis que se realizará, pues esto determina el flujo de trabajo. Para el problema en cuestión: Predicción de la depresión, se realizará un análisis de clasificación, que se refiere a un problema de modelado predictivo en el que la variable respuesta puede ser de tipo binaria (Si – No).

##### - Selección del mejor modelo

Según el conjunto de datos de entrada, la herramienta presenta cuál sería el modelo que mejor se ajusta, y esto lo realiza bajo la medición de diferentes indicadores tales como Accuracy, AUC, Recall, entre otros. La comparación se realiza entre múltiples modelos, como se muestra en la figura 9 y se concluye que el mejor modelo según el comportamiento de los datos es el

**Gradient Boosting Clasifier.** Para la implementación de los modelos, se tomó un set de entrenamiento de 64.627 registros que corresponden al 80% del total de datos, y un set de prueba de 16.321 registros que corresponden al 20%.

	Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)
<b>gbc</b>	Gradient Boosting Classifier	0.7526	0.8197	0.7399	0.1386	0.2334	0.1615	0.2437	47.5095
<b>ada</b>	Ada Boost Classifier	0.7380	0.8168	0.7551	0.1334	0.2268	0.1536	0.2389	11.6460
<b>lightgbm</b>	Light Gradient Boosting Machine	0.8688	0.8127	0.3625	0.1576	0.2195	0.1599	0.1767	5.6725
<b>lr</b>	Logistic Regression	0.6639	0.8111	0.8558	0.1170	0.2058	0.1278	0.2317	8.2040
<b>ridge</b>	Ridge Classifier	0.6402	0.0000	0.8780	0.1122	0.1989	0.1195	0.2269	1.5005
<b>lda</b>	Linear Discriminant Analysis	0.6404	0.8090	0.8777	0.1122	0.1989	0.1195	0.2269	4.6580
<b>nb</b>	Naive Bayes	0.6825	0.7693	0.7500	0.1113	0.1938	0.1154	0.1986	1.4015
<b>knn</b>	K Neighbors Classifier	0.8099	0.6875	0.4404	0.1218	0.1908	0.1207	0.1532	23.5870
<b>rf</b>	Random Forest Classifier	0.9057	0.7896	0.1944	0.1562	0.1730	0.1237	0.1246	20.4485
<b>dt</b>	Decision Tree Classifier	0.8809	0.5798	0.2445	0.1334	0.1724	0.1142	0.1205	3.8730
<b>et</b>	Extra Trees Classifier	0.9034	0.7785	0.1959	0.1517	0.1709	0.1205	0.1216	31.0795

*Figura 9 – Indicadores efectividad del modelo  
Fuente: Python*

Para determinar cuál es el mejor modelo se hace uso de las diferentes métricas de efectividad. Las que se tuvieron en cuenta fueron, al AUC y al F1, ya que estos permiten identificar los casos que se clasifican de manera correcta y así mismo, una combinación entre la precisión y la exactitud las cuales reflejan el porcentaje de casos positivos detectados, y la cantidad de predicciones positivas detectadas respectivamente.

Representado matemáticamente así:

$$R = \frac{TP}{TP + FN} \qquad P = \frac{TP}{TP + FP}$$

Donde TP: Verdaderos positivos, FN: Falsos negativos, FP: Falsos positivos.

Dicho modelo, arroja un Accuracy de 0.75 lo cual indica que el modelo ha acertado en clasificar de manera correcta el 75% de los casos, así mismo, presenta un AUC, o área bajo la curva de 0.81, la cual se especifica en la Figura 10. Y adicionalmente el F1 más alto de los modelos analizados (0.23) el cual, como se describió anteriormente da muestra de la exactitud y precisión del modelo.

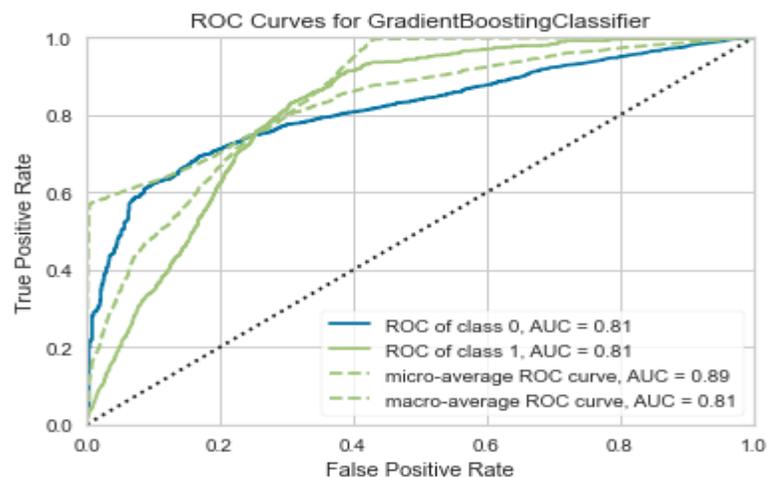


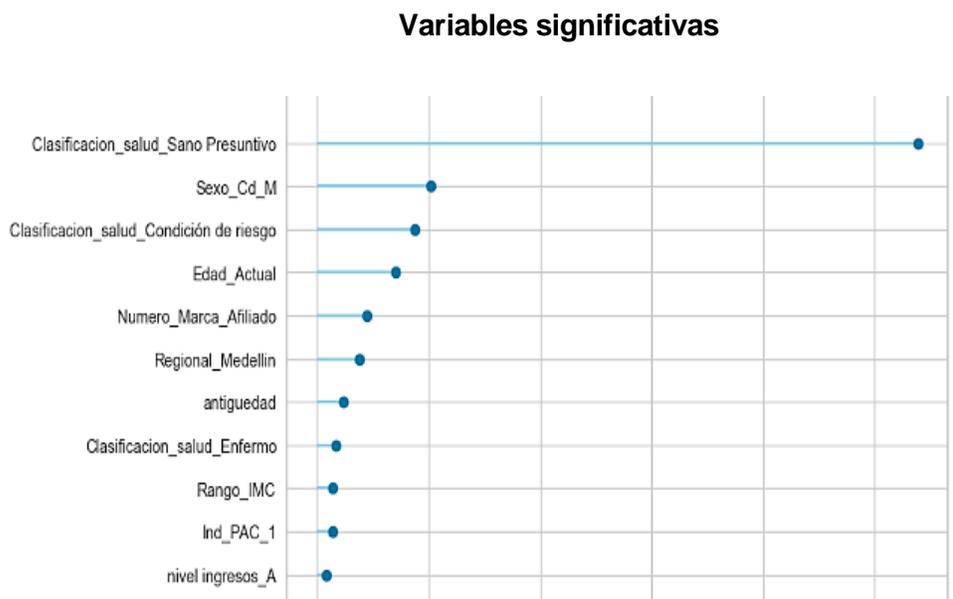
Figura 10 - Curva ROC  
Fuente: Python

**Gradient Boosting, Gradient Tree Boosting o Gradient Boosted Regression Trees (GBRT)**, es una familia de algoritmos usados tanto en clasificación como en regresión basados en la combinación de modelos predictivos débiles (weak learners) -normalmente árboles de decisión- para crear un modelo predictivo fuerte. La generación de los árboles de decisión débiles se realiza de forma secuencial, creándose cada árbol de forma que corrija los errores del árbol anterior. Los aprendices suelen ser árboles "poco profundos" (shallow trees), de apenas uno, dos o tres niveles de profundidad normalmente (Interactivechao).

- **Análisis de resultados**

○ **Variables más significativas**

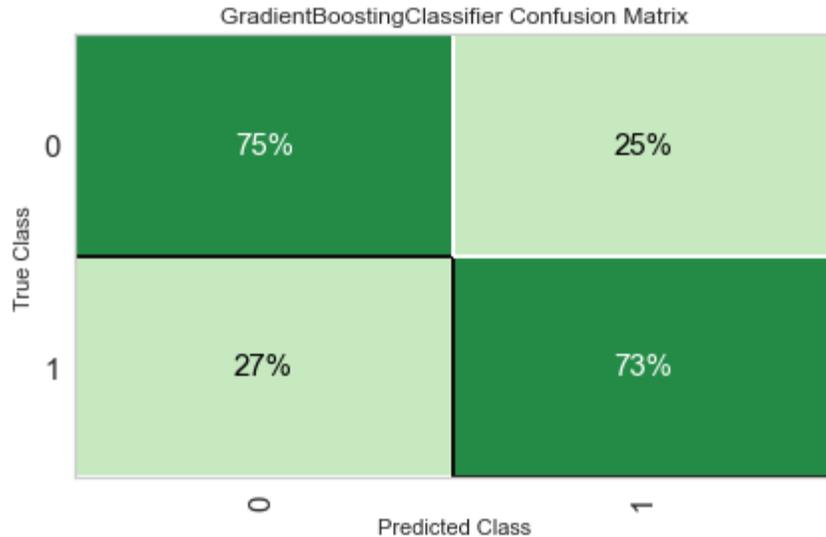
Entre las variables más significativas para el modelo, conforme se analizó en la revisión sistemática de la literatura, están el sexo, las comorbilidades, y el estado de salud de la persona, tal y como se muestra en la figura 11.



*Figura 11 - Variables más significativas*  
*Fuente: Python*

○ **Matriz de confusión**

El modelo clasifica de manera adecuada las personas sin depresión en un 75% y las personas con depresión en un 73% como se observa en la Figura 12



*Figura 12 - Matriz de confusión  
Fuente: Python*

En términos generales, la metodología utilizada permite un buen ajuste de los datos y unos resultados coherentes, es una herramienta que facilita la implementación del modelo y concentrarse en el ajuste y definición de parámetros, permitiendo la optimización del tiempo y garantizando que las herramientas utilizadas son adecuadas dadas las múltiples comparaciones entre diferentes modelos que se realizan. Una posible oportunidad, sería la implementación independiente del modelo que según esta técnica tiene los mejores indicadores, y hacer un análisis de los resultados obtenidos desde allí.

## 5. Discusión

En el desarrollo de este artículo se han abordado 2 temas principales; la predicción de las enfermedades mentales a través de machine learning y la clasificación de estas a través de escalas que utilicen análisis numéricos de acuerdo con variables previamente definidas, lo cual es determinante ya que la inclusión de diferentes tipos de variables, tales como información

biológica y de neuroimágenes, a este tipo de modelos, podría mejorar significativamente su precisión (O'Halloran et al., 2016). Para un futuro se plantea la posibilidad de detallar el tipo de indicadores neurológicos que deberían tenerse en cuenta en los modelos, dependiendo de la relación directa que se haya identificado médicamente entre estos y el deterioro de las funciones mentales.

Si bien existen modelos predeterminados que se ajustan muy bien a la realidad, existen herramientas *Auto Machine Learning (AutoML)* que automáticamente determinan cuáles son los mejores modelos de acuerdo con las variables de entrada (Galatzer-Levy et al., 2017). Esto facilita la identificación de dichos modelos, y permite plantearse la inquietud de cuál es el costo beneficio computacionalmente, dado que se podría implementar un modelo de buen ajuste conocido, como se mencionó anteriormente el *Random Forest* y no tantear con diferentes modelos y tal vez perder la posibilidad de refinar y alcanzar mejores resultados. Sin embargo, es claro que dichas metodologías de *AutoML* facilitan la modelación, aunque exigen también que la definición de las variables sea precisa ya que de esto depende el buen ajuste de los resultados (O'Halloran et al., 2016).

En cuanto a la clasificación de la depresión, actualmente se utilizan diferentes metodologías. Uno de los principales retos que exponen los autores en la literatura estudiada según la RSL aplicada, es la implementación de un modelo de validación de las metodologías de clasificación, dado que la mayoría se basan en información cualitativa lo cual dificulta la precisión estadística ante los resultados y dicha escala de la depresión puede verse limitada por las preguntas formuladas, ya que es posible que las respuestas no reflejen su verdadero nivel de depresión (Jan et al., 2018). La pregunta que surge con el planteamiento anterior es ¿Existe la

posibilidad de plantear un modelo tipo *AutoML* que permita definir cuáles de los modelos de clasificación, según las variables de entrada tiene un mayor ajuste? teniendo en cuenta que identificar el estado de salud mental de un paciente mediante el análisis de datos es un tema de investigación muy complicado ya que involucra varios aspectos: como el trabajo y la presión de los compañeros, la soledad y el aislamiento social, el conflicto en las relaciones sociales, el nivel socioeconómico, los medicamentos, el deterioro físico y la discapacidad, el efecto ambiental, ubicación, trauma basado en incidentes, etc. Esta investigación lleva el supuesto principal que no considera estas situaciones (Kumar & Chong, 2018).

En el futuro, el análisis de los impactos de estos factores relacionados en nuestros resultados y también basados en casos de entornos de prueba reales se considerará el punto focal de la investigación. Además, períodos de observación más prolongados proporcionarán resultados estables y más destacados en el análisis de correlaciones y tendencias (Kumar & Chong, 2018).

De esta manera, la estadística juega un papel indispensable a la hora de facilitar la estandarización, interpretabilidad y confiabilidad en los resultados que se obtengan en modelos donde se usa información no estructurada como la descrita anteriormente.

## **6. Conclusiones**

Los resultados más importantes de la RSL indican que entre las metodologías de *machine learning* con mayor uso para la predicción de la depresión, son los bosques aleatorios, que permiten alcanzar precisiones de hasta el 78% por su capacidad de categorizar y representar las diferentes condiciones de los individuos a analizar (Ryu et al., 2018), las regresiones logísticas y el SVM, metodología que sugiere a la hora de ser utilizada para la predicción de las enfermedades mentales, como la depresión, la inclusión de variables biológicas y de

neuroimágenes para mejorar significativamente su precisión (O'Halloran et al., 2016), así mismo como las redes neuronales y los árboles de decisión. Dichas metodologías permiten asignar a cada individuo una clasificación de riesgo de padecer depresión lo cual permitiría gestionar la enfermedad de manera diferente, pues se priorizaría la gestión y se realizaría un enfoque de prevención diferenciador.

Las principales variables que deben tenerse en cuenta a la hora de desarrollar dichos modelos, según lo señala la revisión, son los indicadores de neuroimágenes, los síntomas depresivos como la tristeza o percepciones individuales pesimistas, la temperatura del ambiente, cuya variable resulta significativa a la hora de interpretar estados emocionales depresivos en las personas (Kumar & Chong, 2018) y las variables sociodemográficas como edad y género así mismo como el estado de salud.

Si bien existen escalas de clasificación de la depresión, en su mayoría están basados en preguntas cualitativas las cuales pueden verse sesgadas por la interpretación de cada persona. No hay evidencia de metodologías estadísticas rigurosas, las cuáles permitan clasificar con un alto grado de precisión los diferentes estadios de la depresión.

La metodología utilizada en el caso práctico permite ajustar de manera adecuada los datos, Pycaret es una herramienta que facilita la implementación del modelo y concentrarse en el ajuste y definición de parámetros, permitiendo la optimización del tiempo y garantizando que las herramientas utilizadas son adecuadas dadas las múltiples comparaciones entre diferentes modelos que se realizan.

## 7. Referencias

- Aladag, A. E., Muderrisoglu, S., Akbas, N. B., Zahmacioglu, O., & Bingol, H. O. (2018). Detecting suicidal ideation on forums: Proof-of-concept study. *Journal of Medical Internet Research*, 20(6). <https://doi.org/10.2196/jmir.9840>
- Alberdi, A., Weakley, A., Schmitter-Edgecombe, M., Cook, D. J., Aztiria, A., Basarab, A., & Barrenechea, M. (2018). Smart Home-Based Prediction of Multidomain Symptoms Related to Alzheimer's Disease. *IEEE Journal of Biomedical and Health Informatics*, 22(6), 1720–1731. <https://doi.org/10.1109/JBHI.2018.2798062>
- Barros, J., Morales, S., Echávarri, O., García, A., Ortega, J., Asahi, T., Moya, C., Fischman, R., Maino, M. P., & Núñez, C. (2017). Suicide detection in Chile: Proposing a predictive model for suicide risk in a clinical sample of patients with mood disorders. *Revista Brasileira de Psiquiatria*, 39(1), 1–11. <https://doi.org/10.1590/1516-4446-2015-1877>
- Beevers, C. G., Mullarkey, M. C., Dainer-Best, J., Stewart, R. A., Labrada, J., Allen, J. J. B., McGeary, J. E., & Shumake, J. (2019). Association between negative cognitive bias and depression: A symptom-level approach. *Journal of Abnormal Psychology*, 128(3), 212–227. <https://doi.org/10.1037/abn0000405>
- Castro, H. M. L. (2005). Revista de psiquiatria y salud mental hermilio valdizan estigma y enfermedad mental: un punto de vista historico-social.
- Dinga, R., Marquand, A. F., Veltman, D. J., Beekman, A. T. F., Schoevers, R. A., van Hemert, A. M., Penninx, B. W. J. H., & Schmaal, L. (2018). Predicting the naturalistic course of depression from a wide range of clinical, psychological, and

biological data: a machine learning approach. *Translational Psychiatry*, 8(1).

<https://doi.org/10.1038/s41398-018-0289-1>

Galatzer-Levy, I. R., Ma, S., Statnikov, A., Yehuda, R., & Shalev, A. Y. (2017). Utilization of machine learning for prediction of post-traumatic stress: A re-examination of cortisol in the prediction and pathways to non-remitting PTSD. *Translational Psychiatry*, 7(3). <https://doi.org/10.1038/tp.2017.38>

Iniesta, R., Malki, K., Maier, W., Rietschel, M., Mors, O., Hauser, J., Henigsberg, N., Dernovsek, M. Z., Souery, D., Stahl, D., Dobson, R., Aitchison, K. J., Farmer, A., Lewis, C. M., McGuffin, P., & Uher, R. (2016). Combining clinical variables to optimize prediction of antidepressant treatment outcomes. *Journal of Psychiatric Research*, 78, 94–102. <https://doi.org/10.1016/j.jpsychires.2016.03.016>

Interactivechao, <https://interactivechaos.com/es/manual/tutorial-de-machine-learning/gradient-boosting>

Jan, A., Meng, H., Gaus, Y. F. B. A., & Zhang, F. (2018). Artificial Intelligent System for Automatic Depression Level Analysis Through Visual and Vocal Expressions. *IEEE Transactions on Cognitive and Developmental Systems*, 10(3), 668–680. <https://doi.org/10.1109/TCDS.2017.2721552>

Jin, H., Wu, S., & di Capua, P. (2015). Development of a clinical forecasting model to predict comorbid depression among diabetes patients and an application in depression screening policy making. *Preventing Chronic Disease*, 12(9). <https://doi.org/10.5888/pcd12.150047>

- Kessler, R. C., van Loo, H. M., Wardenaar, K. J., Bossarte, R. M., Brenner, L. A., Cai, T., Ebert, D. D., Hwang, I., Li, J., de Jonge, P., Nierenberg, A. A., Petukhova, M. v., Rosellini, A. J., Sampson, N. A., Schoevers, R. A., Wilcox, M. A., & Zaslavsky, A. M. (2016). Testing a machine-learning algorithm to predict the persistence and severity of major depressive disorder from baseline self-reports. *Molecular Psychiatry*, *21*(10), 1366–1371. <https://doi.org/10.1038/mp.2015.198>
- Koutsouleris, N., Kambeitz-Ilankovic, L., Ruhrmann, S., Rosen, M., Ruef, A., Dwyer, D. B., Paolini, M., Chisholm, K., Kambeitz, J., Haidl, T., Schmidt, A., Gillam, J., Schultze-Lutter, F., Falkai, P., Reiser, M., Riecher-Rössler, A., Upthegrove, R., Hietala, J., Salokangas, R. K. R., ... Borgwardt, S. (2018). Prediction Models of Functional Outcomes for Individuals in the Clinical High-Risk State for Psychosis or with Recent-Onset Depression: A Multimodal, Multisite Machine Learning Analysis. *JAMA Psychiatry*, *75*(11), 1156–1172. <https://doi.org/10.1001/jamapsychiatry.2018.2165>
- Kumar, S., & Chong, I. (2018). Correlation analysis to identify the effective data in machine learning: Prediction of depressive disorder and emotion states. *International Journal of Environmental Research and Public Health*, *15*(12). <https://doi.org/10.3390/ijerph15122907>
- Le, T. T., Fu, W., & Moore, J. H. (2020). Scaling tree-based automated machine learning to biomedical big data with a feature set selector. *Bioinformatics*, *36*(1), 250–256. <https://doi.org/10.1093/bioinformatics/btz470>

- Oh, J., Yun, K., Hwang, J. H., & Chae, J. H. (2017). Classification of Suicide Attempts through a Machine Learning Algorithm Based on Multiple Systemic Psychiatric Scales. *Frontiers in Psychiatry*, 8. <https://doi.org/10.3389/fpsy.2017.00192>
- O'Halloran, R., Kopell, B. H., Sprooten, E., Goodman, W. K., & Frangou, S. (2016). Multimodal neuroimaging-informed clinical applications in neuropsychiatric disorders. *Frontiers in Psychiatry*, 7(APR). <https://doi.org/10.3389/fpsy.2016.00063>
- OMS. (2012). Plan de acción sobre salud mental 2013-2020. Organización Mundial de la Salud. [https://www.who.int/mental\\_health/publications/action\\_plan/es](https://www.who.int/mental_health/publications/action_plan/es)
- OMS. (2016). ¿Qué es la promoción de la salud? Organización Mundial de la Salud. <https://www.who.int/features/qa/health-promotion/es/>
- OMS. (2019). La OMS subraya la urgencia de transformar la salud mental y los cuidados conexos. <https://www.who.int/es/news/item/17-06-2022-who-highlights-urgent-need-to-transform-mental-health-and-mental-health-care>
- OMS. (2020). INVERTIR EN SALUD MENTAL Día Mundial de la Salud Mental 2020
- OMS. (2021). Depresión. <https://www.who.int/es/news-room/fact-sheets/detail/depression>
- Passos, I. C., Mwangi, B., Cao, B., Hamilton, J. E., Wu, M. J., Zhang, X. Y., Zunta-Soares, G. B., Quevedo, J., Kauer-Sant'Anna, M., Kapczinski, F., & Soares, J. C. (2016). Identifying a clinical signature of suicidality among patients with mood disorders: A

pilot study using a machine learning approach. *Journal of Affective Disorders*, 193, 109–116. <https://doi.org/10.1016/j.jad.2015.12.066>

Patel, M. J., Andreescu, C., Price, J. C., Edelman, K. L., Reynolds, C. F., & Aizenstein, H. J. (2015). Machine learning approaches for integrating clinical and imaging features in late-life depression classification and response prediction. *International Journal of Geriatric Psychiatry*, 30(10), 1056–1067. <https://doi.org/10.1002/gps.4262>

Pérez Rave, J. (2019). Revisión Sistemática de Literatura en Ingeniería, ampliada y actualizada (Sello Editorial IDINNOV, Dic. 2019, ISBN: 978-958-58897-6-7).

Redlich, R., Opel, N., Grotegerd, D., Dohm, K., Zaremba, D., Burger, C., Munker, S., Muhlmann, L., Wahl, P., Heindel, W., Arolt, V., Alferink, J., Zwanzger, P., Zavorotnyy, M., Kugel, H., & Dannlowski, U. (2016). Prediction of individual response to electroconvulsive therapy via machine learning on structural magnetic resonance imaging data. *JAMA Psychiatry*, 73(6), 557–564. <https://doi.org/10.1001/jamapsychiatry.2016.0316>

Reps, J. M., Schuemie, M. J., Suchard, M. A., Ryan, P. B., & Rijnbeek, P. R. (2018). Design and implementation of a standardized framework to generate and evaluate patient-level prediction models using observational healthcare data. *Journal of the American Medical Informatics Association*, 25(8), 969–975. <https://doi.org/10.1093/jamia/ocy032>

- Ryu, S., Lee, H., Lee, D. K., & Park, K. (2018). Use of a machine learning algorithm to predict individuals with suicide ideation in the general population. *Psychiatry Investigation*, *15*(11), 1030–1036. <https://doi.org/10.30773/pi.2018.08.27>
- Schnyer, D. M., Clasen, P. C., Gonzalez, C., & Beevers, C. G. (2017). Evaluating the diagnostic utility of applying a machine learning algorithm to diffusion tensor MRI measures in individuals with major depressive disorder. *Psychiatry Research - Neuroimaging*, *264*, 1–9. <https://doi.org/10.1016/j.psychresns.2017.03.003>
- Tran, T., & Kavuluru, R. (2017). Predicting mental conditions based on “history of present illness” in psychiatric notes with deep neural networks. *Journal of Biomedical Informatics*, *75*, S138–S148. <https://doi.org/10.1016/j.jbi.2017.06.010>
- Wahle, F., Kowatsch, T., Fleisch, E., Rufer, M., & Weidt, S. (2016). Mobile sensing and support for people with depression: A pilot trial in the wild. *JMIR MHealth and UHealth*, *4*(3). <https://doi.org/10.2196/mhealth.5960>
- Wu, M. J., Wu, H. E., Mwangi, B., Sanches, M., Selvaraj, S., Zunta-Soares, G. B., & Soares, J. C. (2015). Prediction of pediatric unipolar depression using multiple neuromorphometric measurements: A pattern classification approach. *Journal of Psychiatric Research*, *62*, 84–91. <https://doi.org/10.1016/j.jpsychires.2015.01.015>

## 8. Aportes o productos de conocimiento

Frente a los resultados de conocimiento obtenidos a lo largo de este proceso de investigación documental y la exposición del caso práctico, se pueden citar:

- La escritura y publicación en revista SCOPUS de dos artículos científicos
- La participación en evento internacional, con ponencia sobre la temática investigada

### • Publicación de artículo 1

**Revista:** RISTI (Revista Ibérica de Sistemas y Tecnologías de la Información)

**Nombre del Artículo:** Machine learning aplicado en la clasificación y predicción de la depresión: Una revisión sistemática

**ISSN:** 1646-9895

**Cuartil:** Q4

**Acceso:** <http://www.risti.xyz/issues/ristie47.pdf>

**Fecha de publicación:** Enero de 2022

Ver anexo B

### • Publicación de artículo 2

**Revista:** RISTI (Revista Ibérica de Sistemas y Tecnologías de la Información)

**Nombre del Artículo:** Estadística aplicada a la predicción de enfermedades mentales: Una revisión sistemática

**ISSN:** 1646-9895

**Cuartil:** Q4

**Acceso:** <http://www.risti.xyz/issues/ristie43.pdf>

**Fecha de publicación:** julio de 2021

Ver anexo C

• **Ponencia en evento internacional**

**Evento:** MICRADS - Multidisciplinary International Conference of Research Applied to Defense and Security (Virtual) – Cartagena 2021

**Título de la presentación:** Estadística aplicada a la predicción de enfermedades mentales: Una revisión sistemática

**Fecha:** agosto 18-20 de 2021

Ver anexo D

## **Anexos**

### **Anexo A - Código Python**

```

##Instalación de Librerías
#!pip install --user dataprep
#!pip install --user pycaret [full]
#!pip install --user explainerdashboard

import pandas as pd
##import teradataql

###!pip install --user shap
###!pip install interpret-community
from pycaret.classification import

extraccion=pd.read_excel('Libro1.xlsx') extraccion

#!pip install --user -U pycaret #Actualizar#!pip
uninstall --user pycaret #Desinstalar
#!pip install --upgrade imbalanced-Learn==0.7.0 # Actualizar a una versión#!pip
install --user --upgrade numba==0.54
!pip install --user --upgrade scikit-learn==0.23.2
#!pip install --user --upgrade scipy==1.5.4#!pip

install --user imbalanced-Learn

import imblearn as imblearn
from pycaret.classification import *
from pycaret.classification import load_config

model_setup=setup(data=extraccion
, target='Ind_Depresion'

##### Data Preparation #####
#Para conocer el detalle de Los parámetros, dirigirse a https://pycaret.gitbook.i

# Missing Values
#, numeric_imputation='mean'
#, categorical_imputation='constant'
, numeric_iterative_imputer='et'
#, categorical_iterative_imputer='et'

# Data Types
, numeric_features=['Edad_Actual'
, 'Numero_Marca_Afiliado'
, 'Utilizaciones'
, 'antiguedad'
, 'quejas'
, 'costo ']

, categorical_features=['Clasificacion_salud'
, 'Regimen_txt'
, 'indice_masa'
, 'Sexo_Cd'
, 'Regional'
, 'Ind_PAC'
, 'nivel ingresos'

```

```

'concatenación']
,ignore_features=[]

# One-Hot Encoding, Ordinal Encoding, Cardinal Encoding and Handle Unknown Levels
#,ordinal_features= {'DECENIO' : ['0-9', '60-69', '40-49', '20-29', '10-19', '50-
#
# , 'NIVEL_INGRESO' : ['NIVEL 1 DEL SISBEN', 'NIVEL 2 DEL SISBE
,high_cardinality_features=[]
,high_cardinality_method='frequency'
,handle_unknown_categorical=True
,unknown_categorical_method='most_frequent'

#Target Imbalance
,fix_imbalance = True # Default SMOTE-Tomek
#,fix_imbalance_method=imblearn.over_sampling.RandomOverSampler()
#,fix_imbalance_method=imblearn.under_sampling.RandomUnderSampler()
#Remove Outliers
,remove_outliers=True
,outliers_threshold=0.01

##### Scale and Transform #####
#Para conocer el detalle de los parámetros, dirigirse a https://pycaret.gitbook.i

#Normalize
,normalize=True
,normalize_method= 'robust'

#Feature Transform
#yeo-johnson and quantile

#Target Transform
#box-cox and yeo-johnson (Target is continuous)

##### Feature Engineering #####
#Para conocer el detalle de los parámetros, dirigirse a https://pycaret.gitbook.i

#Feature Interaction
#This feature is not scalable and may not work as expected on datasets with large
# feature_interaction (*), feature_ratio(/) or interaction_threshold for numeric

#Polynomial Features

#Trigonometry Features

#Group Features

#Bin Numeric Features

#Combine Rare Levels
#Similar al high_cardinality_features
#,combine_rare_levels=True
#,rare_level_threshold=0.2 #Percentil por debajo del cual se combinan los niveles

#Create Clusters

##### Feature Selection #####
#Para conocer el detalle de los parámetros, dirigirse a https://pycaret.gitbook.i

#Feature Selection - Importance

```

```

,feature_selection = False

#Remove Multicollinearity
,remove_multicollinearity = True
,multicollinearity_threshold=0.7

#Principal Component Analysis (PCA)

#Ignore Low Variance
,ignore_low_variance = True

##### Other setup parameters #####
#Para conocer el detalle de Los parámetros, dirigirse a https://pycaret.gitbook.i

#Experiment Logging

#Model Selection
,train_size=0.80
,fold=20

#Other Miscellaneous
,n_jobs=-1 #-1 all processors and 1 spark
,use_gpu=True #use GPU and CPU
,session_id=123 #Controls the randomness of the experiment
#,profile=True #EDA report
,log_experiment = True
)

#models() modelos disponibles en PyCaret
best = compare_models(
    sort = 'F1'
    #,parallel = FugueBackend('dask') #probar trabajo en paralelo, se requiere paráme
    ,fold=20
    #,include = ['rf']
)

print(best)

dt = create_model('gbc')
dt_results = pull() # access the scoring grid

# AUC
plot_model(dt, plot = 'auc')

# Matriz de confusión
plot_model(dt, plot = 'confusion_matrix', plot_kwargs = {'percent' : True})

# Feature IImportance (all)
plot_model(dt, plot = 'feature_all')

# check Leaderboard
get_leaderboard()

# finalize a model
finalize_model(dt) #Re entrena el modelo con todos Los dat
os, sin cambiar parámetros

```

## Anexo B - Publicación de artículo 1

# Machine learning aplicado en la clasificación y predicción de la depresión: Una revisión sistemática

Sebastián Osorio Castrillon<sup>1</sup>, Liliana Maria Giraldo Marín<sup>2</sup>,

Herman Horacio Jaramillo Villegas<sup>3</sup>, Carlos César Piedrahita Escobar<sup>4</sup>

osoriocastrillon1@gmail.com; lmgiraldo@udem.edu.co; hjaramillo@udem.edu.co;  
[cpiedrahita@udem.edu.co](mailto:cpiedrahita@udem.edu.co)

<sup>1</sup> Maestría en modelación y ciencia computacional, Universidad de Medellín, 055450, Sabaneta, Colombia.

<sup>2</sup> Profesora titular Facultad de ingenierías, carrera 74 # 41 – 16, 050032, Medellín, Colombia.

<sup>3</sup> Universidad de Medellín, grupo Modelación y Computación Científica, 050026, Medellín, Colombia. <sup>4</sup> Universidad de Medellín; grupo Modelación y Computación Científica, 050026, Medellín, Colombia. Pages: 363-375

**Resumen:** El principal reto de las aseguradoras de la salud es gestionar de manera adecuada y proactiva tanto la enfermedad como la salud de sus afiliados, enfatizando en la prevención e implementación de acciones que permitan la anticipación y predicción de la enfermedad. Este artículo presenta una revisión sistemática de la literatura sobre las principales metodologías de aprendizaje automático que permiten a través de la predicción de la depresión realizar una intervención temprana. Se encontró que las principales metodologías para dicho fin son los modelos estadísticos como la regresión logística el SVM y los bosques aleatorios; y que los diferentes indicadores de las neuroimágenes y el uso de celulares se convierten en variables predictoras fundamentales a la hora de predecir la depresión.

Palabras clave: Revisión sistemática, depresión, machine learning.

Statistics applied in the classification and prediction of depression: A systematic review

**Abstract:** The main challenge for health insurers is to properly manage the disease as well as the health of its members, emphasizing the prevention and implementation of actions that allow the anticipation and prediction of the disease. This article presents a systematic review of the literature on the main machine learning methodologies that allow, through the prediction of mental illnesses, to carry out an early intervention. It was found that the main methodologies for this purpose are statistical models such as logistic regression, Vector support machine and random forest; and that the different indicators of neuroimaging use of cell phones become fundamental predictor variables when it comes to predicting mental illnesses

Keywords: systematic review, Machine learning, depression.

## 1. Introducción

La depresión es una enfermedad frecuente en todo el mundo, y se calcula que afecta a más de 300 millones de personas. Cada año se suicidan cerca de 800 000 personas, y el suicidio es la segunda causa de muerte en el grupo etario de 15 a 29 años. (OMS, 2021).

Los sistemas de salud todavía no han dado una respuesta adecuada a la carga de trastornos mentales; en consecuencia, la divergencia entre la necesidad de tratamiento y su prestación es grande en todo el mundo. Aunque hay tratamientos eficaces para la depresión, más de la mitad de los afectados en todo el mundo (y más del 90% en muchos países) no recibe esos tratamientos. Entre los obstáculos a una atención eficaz se encuentran la falta de recursos y de personal sanitario capacitados, además de la estigmatización de los trastornos mentales y la evaluación clínica inexacta.

Otra barrera para la atención eficaz es la evaluación errónea. Por lo cual se hace indispensable encontrar características biológicas que sean informativas en términos de diagnóstico, pronóstico y tratamiento. (O'Halloran et al., 2016) En países de todo tipo de ingresos, las personas con depresión a menudo no son correctamente diagnosticadas, mientras que otras que en realidad no la padecen son a menudo diagnosticadas erróneamente y tratadas con antidepresivos (OMS, 2020).

Uno de los grandes desafíos a los que se ven enfrentadas las aseguradoras, es a la prevención de enfermedades mentales debido a su aumento significativo en los últimos años, (Ministerio de salud, 2020) pues los desórdenes mentales y los trastornos psíquicos, incluidas las manifestaciones depresivas, la esquizofrenia, el Alzheimer, la epilepsia y el retraso mental, representan el 11% del total de las enfermedades en el mundo (Castro, 2005)

El machine learning por su capacidad de procesar grandes volúmenes de información e implementar modelos con alta precisión, se ha convertido en una de las herramientas más utilizadas a la hora de apoyar el sistema de salud en la predicción, detección y prevención de enfermedades mentales (Tran & Kavuluru, 2017).

Este artículo presenta una revisión sistemática de la literatura que permita entender cuáles son las principales utilizadas para la predicción de enfermedades mentales, específicamente la depresión. Adicionalmente, cuáles son las variables que aportan mayor significancia a la precisión de los modelos utilizados.

## **2. Metodología**

La revisión sistemática de la literatura se basó e realizó bajo los siguientes ...

- Definición del tema
- Definición preguntas de investigación
- Definición términos de búsqueda y base de datos
- Selección de artículos

Y siguiendo la metodología de revisión sistemática de literatura propuesta inicialmente por el autor Jorge Iván Pérez Rave en su publicación (Pérez, 2012) y mejorada posteriormente en su publicación (Pérez, 2019).

## 2.1 Definición del tema y preguntas de investigación

Como se expuso anteriormente, el tema de interés son los modelos estadísticos aplicados a la predicción y clasificación de las enfermedades mentales. Para dar respuesta a dicha pregunta se formularon las siguientes 5 preguntas:

**P1.** ¿Cuáles son los principales modelos estadísticos utilizados para la predicción de la depresión?

**P2.** ¿De los principales modelos estadísticos utilizados para la predicción de la depresión, cuáles tienen mayor precisión?

**P3.** ¿Qué variables son indispensables a la hora de predecir la depresión?

**P4.** ¿Existen criterios estadísticos para la clasificación de la depresión?

**P5.** ¿Cuál es el estado actual y los desafíos investigativos de los modelos estadísticos aplicados a la predicción de la depresión?

## 2.2 Definición términos de búsqueda y base de datos

La búsqueda se realizó en la base de datos SCOPUS, principalmente por la facilidad con la que permite analizar y visualizar diferentes indicadores bibliométricos como la cantidad de citaciones de los artículos, el año de publicación, los autores, el tipo de artículo, etc. Así mismo, por la completitud y sustento científico del contenido que ofrece. La búsqueda se realizó en Agosto de 2021.

Para la definición de la ecuación de búsqueda se garantizó que contuviera los principales términos relacionados con el tema de interés, como: Machine learning - depresión prediction y que cumpliera las siguientes condiciones:

- Artículos
- Estado finalizado
- Últimos 6 años (incluyendo 2021)
- Mayor relevancia (número de citaciones) - Artículos con mínimo una citación
- Idioma inglés
- Áreas de ciencia computacional y medicina

Con lo cual resulta la siguiente ecuación:

**( TITLE-ABS-KEY ( depression AND prediction ) AND TITLE-ABS-KEY ( machine AND learning ) ) AND ( LIMIT-TO ( OA , “all” ) ) AND ( LIMIT-TO ( PUBSTAGE , “final” ) ) AND ( LIMIT-TO ( PUBYEAR , 2021 ) OR LIMIT- TO ( PUBYEAR , 2020 ) OR LIMIT-TO ( PUBYEAR , 2019 ) OR LIMIT- TO ( PUBYEAR , 2018 ) OR LIMIT-TO ( PUBYEAR , 2017 ) OR LIMIT-TO ( PUBYEAR , 2016 ) OR LIMIT-TO ( PUBYEAR , 2015 ) ) AND ( LIMIT-TO ( SUBJAREA , “MEDI” ) OR LIMIT-TO ( SUBJAREA , “COMP” ) ) AND ( LIMIT-TO ( DOCTYPE , “ar” ) ) AND ( LIMIT-TO ( LANGUAGE , “English” ) )**

Implementando dicha ecuación en la BD definido (SCOPUS), se obtuvieron como resultado un total de 146 artículos. De estos, el 50% tenía 7 o más citaciones, quedando así con 72 artículos por revisar.

### 2.3 Selección de artículos

Antes de realizar la selección de los artículos finales a revisar sobre los 72 posibles, se revisó la vigencia del tema, con la cual se pretendía identificar gráficamente el crecimiento en el tiempo del número de artículos relacionados con el tema de interés, y por ende la relevancia que ha venido tomando. En la figura 1.

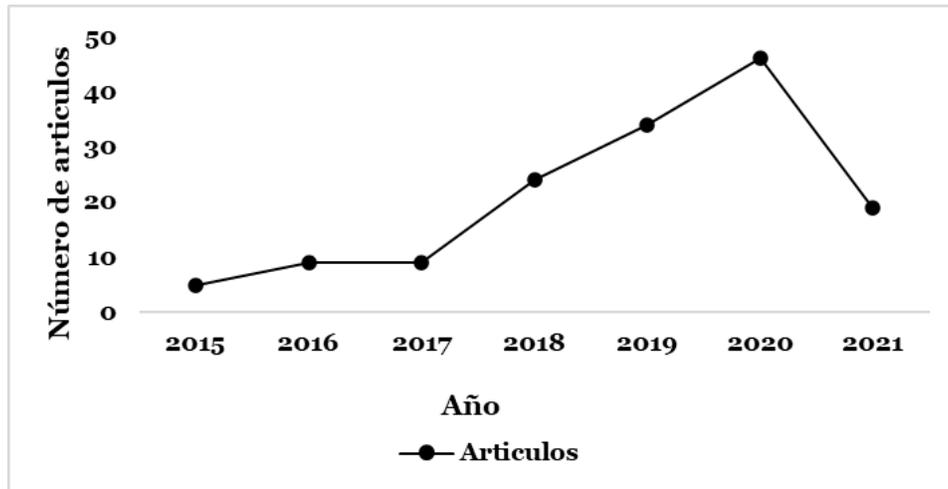


Figura 1 – Número de publicaciones por año. Fuente: (Scopus, 2021).

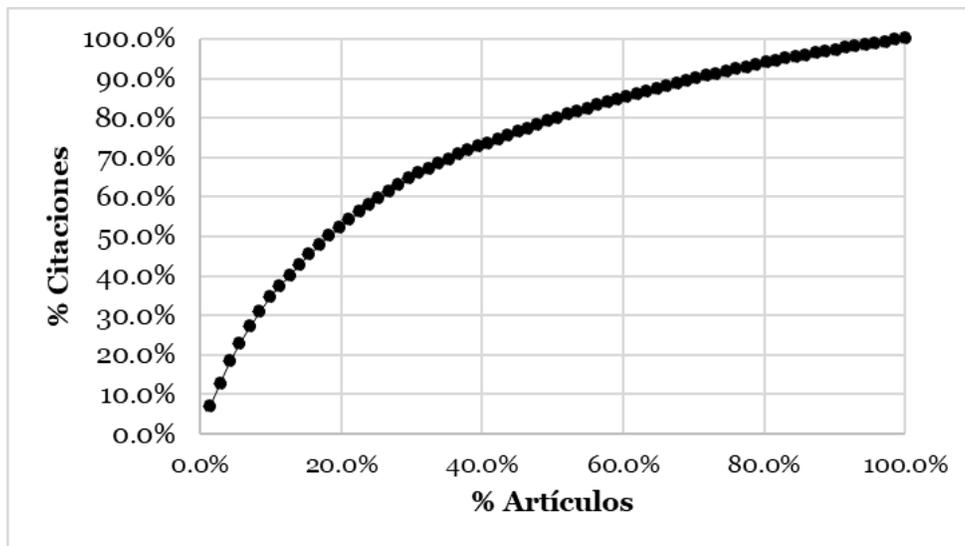


Figura 2 – “Espacio literario relevante”. Fuente: Elaboración propia basado en la metodología de Pérez-Rave

Se observa que la cantidad de artículos ha crecido significativamente desde el año 2015 (periodo inicial definido para búsqueda de material) hasta la fecha, teniendo en cuenta que el descenso que se observa en el año 2021 es debido a que de este año se tuvieron en cuenta solo 8 meses.

Finalmente se realizó un análisis de relevancia de los artículos (Espacio literario relevante) con el cual se pretendía identificar el número de artículos que representarían la mayor proporción de citas totales. Concluyendo que, de los 72 artículos posibles a revisar, el 50.7% (36) representan el 80% de las citas, como se observa en la figura 3.

Finalmente, se hizo una revisión detallada de los resúmenes de los 36 artículos concluyendo que eran objeto de revisión y aportarían valor al desarrollo de la revisión sistemática de literatura 24 artículos. Ver tabla 1

#	ID	Título	Citas	Año
1	10.1109/TCDS.2017.2721552	Artificial Intelligent System for Automatic Depression Level Analysis Through Visual and Vocal Expressions	32	2018
2	<a href="https://doi.org/10.1037/abn0000405">10.1037/abn0000405</a>	Association Between Negative Cognitive Bias and Depression: A Symptom-Level Approach	20	2019
3	10.3389/fpsy.2017.00192	Classification of Suicide Attempts through a Machine Learning Algorithm Based on Multiple Systemic Psychiatric Scales	33	2017
4	0.1016/j.jpsychires.2016.03.016	Combining clinical variables to optimize prediction of antidepressant treatment outcomes	73	2016
5	yujg	Correlation analysis to identify the effective data in machine learning: Prediction of depressive disorder and emotion states	18	2018
6	10.1093/jamia/ocy032	Design and implementation of a standardized framework to generate and evaluate patient-level prediction models using observational healthcare data	36	2018
7	10.2196/jmir.9840	Detecting suicidal ideation on forums: Proof-of-concept study	26	2018
8	10.5888/pcd12.150047.	Development of a clinical forecasting model to predict comorbid depression among diabetes patients and an		

		application in depression screening policy making	18	2015
9	10.1016/j. psychresns.2017.03 .003	Evaluating the diagnostic utility of applying a machine learning algorithm to diffusion tensor MRI measures in individuals with major depressive disorder	25	2017
10	10.1016/j.jad.2015.12 .066	Identifying a clinical signature of suicidality among patients with mood disorders: A pilot study using a machine learning approach	83	2016
11	<a href="https://doi.org/10.1002/gps.4262">10.1002/gps.4262</a>	Machine learning approaches for integrating clinical and imaging features in late-life depression classification and response prediction	74	2015
12	10.2196/mhealth.596 0	Mobile sensing and support for people with depression: A pilot trial in the wild	91	2016
13	10.3389/fpsy.2016.0 0063	Multimodal neuroimaging-informed clinical applications in neuropsychiatric disorders	17	2016
14	10.1016/j.jbi.2017.06. 010	Predicting mental conditions based on "history of present illness" in psychiatric notes with deep neural networks	31	2017
15	doi.org/10.1038/s413 98-018-0289-1	Predicting the naturalistic course of depression from a wide range of clinical, psychological, and biological data: a machine learning approach	34	2018
16	10.1001/ jamapsychiatry.2018. 2165	Prediction Models of Functional Outcomes for Individuals in the Clinical High-Risk State for Psychosis or with Recent-Onset Depression: A Multimodal, Multisite Machine Learning Analysis	114	2018
17	:10.1001/ jamapsychiatry.2016. 0316	Prediction of individual response to electroconvulsive therapy via machine learning on structural magnetic resonance imaging data	141	2016
18	10.1016/j. jpsychires.2015.01.0 15	Prediction of pediatric unipolar depression using multiple neuromorphometric measurements: A pattern classification approach	18	2015
19	10.1093/bioinformatic s/ btz470	Scaling tree-based automated machine learning	47	2020

		to biomedical big data with a feature set selector		
20	<a href="#">10.1109/JBHI.2018.2798062</a>	Smart Home-Based Prediction of Multidomain Symptoms Related to Alzheimer's Disease	41	2018
21	10.1590/1516-4446-2015-1877	Suicide detection in Chile: Proposing a predictive model for suicide risk in a clinical sample of patients with mood disorders	18	2017
22	<a href="#">10.1038/mp.2015.198</a>	Testing a machine-learning algorithm to predict the persistence and severity of major depressive disorder from baseline self-reports	109	2016
23	10.30773/pi.2018.08.27	Use of a machine learning algorithm to predict individuals with suicide ideation in the general population		2018
24	<a href="#">10.1038/tp.2017.38</a>	Utilization of machine learning for prediction of post-traumatic stress: A re-examination of cortisol in the prediction and pathways to non-remitting PTSD		2017

Tabla1 – Artículos seleccionados. Fuente: Elaboración propia.

### 3. Resultados de la revisión sistemática de la literatura

Para dar respuesta a las preguntas de investigación planteadas, se realizó la lectura completa de los 24 artículos seleccionados con la metodología descrita anteriormente, a cada uno de éstos se les construyó una ficha técnica en la que se incluyeron los componentes más relevantes, tales como el propósito general del artículo, cómo daba respuesta a la(s) pregunta(s) de investigación, qué preguntas quedaban sin responder y el resumen. Adicional se construyó una tabla de características matricial en la cual se

relacionaba cada artículo con las 5 preguntas planteadas con el fin de sintetizar, resumir e interpretar de manera más clara las respuestas a las preguntas de investigación.

**P1.** ¿Cuáles son los principales modelos estadísticos utilizados para la predicción de la depresión?

Por la naturaleza y complejidad de la depresión, se vuelve indispensable validar, probar y mezclar diferentes metodologías que ayuden a integrar variables de diferente índole para poder obtener

los resultados más precisos posibles a la hora de apoyar al sector salud en el diagnóstico/gestión de la salud mental. (Kumar & Chong, 2018a).

Se observa que en 6 de los artículos analizados utilizaron la metodología de random forest (Artículos 2,5,8,12,21,23 descritos en la tabla 1) como metodología para la predicción de la depresión. Alcanzando precisiones de hasta el 78% con este tipo de metodologías por su capacidad de categorizar y representar las diferentes condiciones de los individuos a analizar (Ryu et al., 2018).

Adicionalmente se observa que la metodología SVM o Máquina de soporte vectorial también hace parte de las más utilizadas según la literatura, a la hora de predecir la depresión como lo evidencian los artículos (8,12,13,18,20,21). Sin embargo, es importante aclarar que la inclusión de variables biológicas y de neuroimágenes a este

tipo de modelos podría mejorar significativamente su precisión (O'Halloran et al., 2016)

La regresión, con sus diferentes adaptaciones, principalmente la lineal y la logística hacen parte también de las más utilizadas a la hora de clasificar o predecir individuos con alguna conficción específica en este caso la depresión, se observa que en los artículo2 1,8,6,4,15,16,20 las utilizan para perfilar a las personas según sus condiciones mentales.

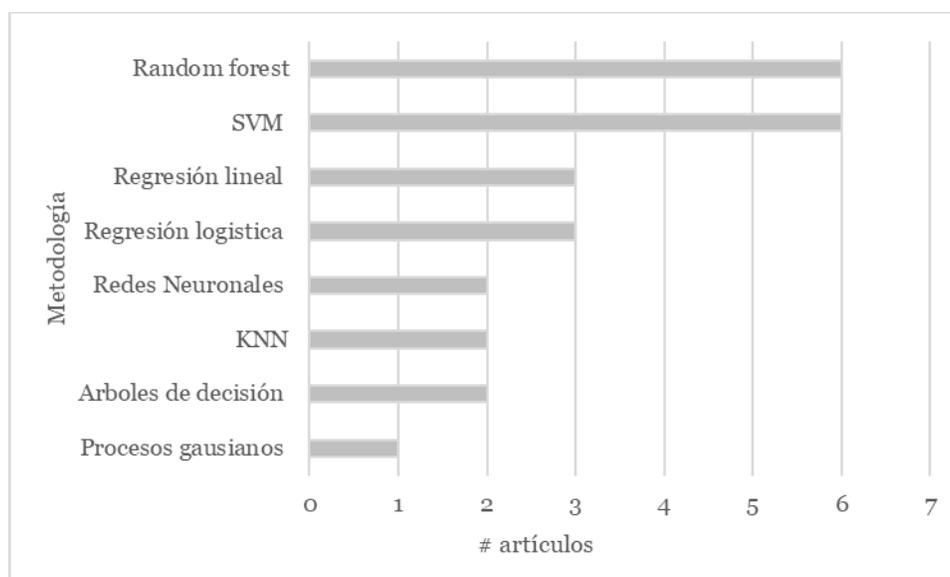


Figura 3 – Metodologías estadísticas. Fuente: Elaboración propia

Es importante tener en cuenta que La regresión requiere una representación suficiente de las colas en la escala objetivo para aprender un patrón predictivo que explique el rango completo de la escala. (Koutsouleris et al., 2018).

Las redes neuronales, árboles de decisión y los procesos gaussianos, y los clústeres son a su vez metodologías que también han sido utilizadas según la literatura, para este tipo de metodologías la recopilación de más datos es útil para tener un conjunto de datos completo con

casos con firmados de transición de un estado saludable a un deterioro cognitivo, lo cual es necesario para construir modelos de predicción precisos.(Alberdi et al., 2018)

**P2.** ¿De los principales modelos estadísticos utilizados para la predicción de la depresión, cuáles tienen mayor precisión?

Según la literatura los modelos estadísticos con mayor precisión a la hora de predecir la depresión son: el SVM (Support vector machine) (Artículos 18,21) principalmente por su sensibilidad a mediciones neuromorfométricas. (Wu et al., 2015)Así mismo la Red

neuronal convolucional hace parte de los modelos más precisos pues admite y procesa de manera efectiva una breve descripción textual de la historia del paciente de la enfermedad actual (Tran & Kavuluru, 2017)

Si bien es importante hacer validaciones para determinar cuál es el mejor modelo, existen herramientas Auto Machine Learning que automáticamente determinan cuáles son los mejores modelos de acuerdo a las variables de entrada. En el artículo 24 relacionan TPOT-FSS que es la primera herramienta de AutoML que ofrece la opción de selección de funciones a nivel de grupo. TPOT-FSS puede identificar el grupo de características más significativo para incluir en la tubería de predicción. Aplicamos TPOT-FSS a datos de RNA-Seq del mundo real para demostrar la identificación de grupos de genes biológicamente relevantes (Galatzer-Levy et al., 2017)

**P3.** ¿Qué variables son indispensables a la hora de predecir la depresión?

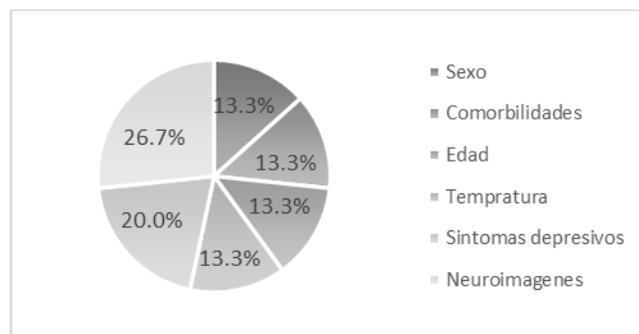


Figura 4 – Variables predictoras. Fuente: Elaboración propia

Entre las principales variables utilizadas para la predicción de la depresión se encuentran las neuroimágenes con su mayor frecuencia, relacionadas en los artículos

9,13,16,18 seguido de los síntomas depresivos relacionados en los artículos 2,15,23. La temperatura y comportamientos atmosféricos aparece también entre las variables utilizadas para predecir la depresión, (artículo 5) adicionalmente el sexo, la edad y las diferentes comorbilidades presentes en los individuos hacen parte de las variables a tener en cuenta.

**P4.** ¿Existen criterios estadísticos para la clasificación de la depresión?

En términos generales no existe un patrón a la hora de clasificar estadísticamente la depresión según la literatura revisada, sin embargo, si hay clasificaciones basadas en información cualitativa y cuestionarios que permiten determinar la complejidad de cada caso y establecer criterios de complejidad a las predicciones.

En el artículo 4, relacionan la escala de clasificación de depresión de asberg (MADRS) la cual se basa en preguntas relacionadas con estados de tristeza, pérdida de sueño, disminución del apetito, dificultades de concentración, pensamientos pesimistas e ideación suicida. (Iniesta et al., 2016a) Adicionalmente en el artículo 1 relacionan la escala de depresión de Beck el cual es un cuestionario de 21 items con escala de tipo Likert, la cual es una escala psicométrica utilizada principalmente en investigaciones sociales. (Jan et al., 2018).

**P5.** ¿Cuál es el estado actual y los desafíos investigativos de los modelos estadísticos aplicados a la predicción de la depresión?

Se evidencia un uso demostrativo de las metodologías para la predicción de la depresión, sin embargo, existen retos a la hora de precisar los diagnósticos sobre depresión, sobre todo en la inclusión de neuroimágenes, pues la organización del cerebro es la causa más próxima de los trastornos psiquiátricos y la neuroimagen proporciona una herramienta invaluable para identificar y caracterizar características clínicamente informativas. (O'Halloran et al., 2016).

#### **4. Conclusiones**

Los resultados más importantes de la revisión sistemática de la literatura indican que entre las metodologías de machine learning con mayor uso para la predicción de la depresión, son los bosques aleatorios, las regresiones logísticas y el vector support machine, así mismo como las redes neuronales y los árboles de decisión, dichas metodología permiten asignar a cada individuo una clasificación de riesgo de padecer depresión lo cual permitiría gestionar a enfermedad de manera diferente, pues se priorizaría la gestión y se realizaría un enfoque de prevención diferenciador.

Las principales variables que deben tenerse en cuenta a la hora de desarrollar dichos modelos, según lo señala la revisión, son los indicadores de neuroimágenes, los síntomas depresivos como la tristeza o percepciones individuales pesimistas, la temperatura del ambiente, cuya variable resulta significativa a la hora de interpretar estados emocionales depresivos en las personas (Kumar & Chong, 2018a) Y las variables sociodemográficas como edad y género así mismo como el estado de salud.

Si bien existen escalas de clasificación de la depresión, en su mayoría están basados en preguntas cualitativas las cuales pueden verse sesgadas por la interpretación de cada persona. No hay evidencia de metodologías estadísticas rigurosas las cuáles permitan clasificar con un alto grado de precisión los diferentes estadios de la depresión.

## Referencias

- Aladag, A. E., Muderrisoglu, S., Akbas, N. B., Zahmacioglu, O., & Bingol, H. O. (2018). Detecting suicidal ideation on forums: Proof-of-concept study. *Journal of Medical Internet Research*, 20(6). <https://doi.org/10.2196/jmir.9840>
- Alberdi, A., Weakley, A., Schmitter-Edgecombe, M., Cook, D. J., Aztiria, A., Basarab, A., & Barrenechea, M. (2018). Smart Home-Based Prediction of Multidomain Symptoms Related to Alzheimer's Disease. *IEEE Journal of Biomedical and Health Informatics*, 22(6), 1720–1731. <https://doi.org/10.1109/JBHI.2018.2798062>
- Barros, J., Morales, S., Echávarri, O., García, A., Ortega, J., Asahi, T., Moya, C., Fischman, R., Maino, M. P., & Núñez, C. (2017a). Suicide detection in Chile: Proposing a predictive model for suicide risk in a clinical sample of patients with mood disorders. *Revista Brasileira de Psiquiatria*, 39(1), 1–11. <https://doi.org/10.1590/1516-4446-2015-1877>
- Barros, J., Morales, S., Echávarri, O., García, A., Ortega, J., Asahi, T., Moya, C., Fischman, R., Maino, M. P., & Núñez, C. (2017b). Suicide detection in Chile: Proposing a predictive model for suicide risk in a clinical sample of patients with mood disorders. *Revista Brasileira de Psiquiatria*, 39(1), 1–11. <https://doi.org/10.1590/1516-4446-2015-1877>
- Castro, H. M. L. (2005). REVISTA DE PSIQUIATRIA Y SALUD MENTAL HERMILIO VALDIZAN ESTIGMA Y ENFERMEDAD MENTAL: UN PUNTO DE VISTA HISTORICO-SOCIAL.
- Dinga, R., Marquand, A. F., Veltman, D. J., Beekman, A. T. F., Schoevers, R. A., van Hemert, A. M., Penninx, B. W. J. H., & Schmaal, L. (2018). Predicting the naturalistic course of depression from a wide range of clinical, psychological, and biological data: a machine learning approach. *Translational Psychiatry*, 8(1). <https://doi.org/10.1038/s41398-018-0289-1>
- Galatzer-Levy, I. R., Ma, S., Statnikov, A., Yehuda, R., & Shalev, A. Y. (2017). Utilization of machine learning for prediction of post-traumatic stress: A re-examination of cortisol in the prediction and pathways to non-remitting PTSD. *Translational Psychiatry*, 7(3). <https://doi.org/10.1038/tp.2017.38>
- Iniesta, R., Malki, K., Maier, W., Rietschel, M., Mors, O., Hauser, J., Henigsberg, N., Dernovsek, M. Z., Souery, D., Stahl, D., Dobson, R., Aitchison, K. J., Farmer, A., Lewis, C. M., McGuffin, P., & Uher, R. (2016a). Combining clinical variables to optimize prediction of antidepressant treatment outcomes. *Journal of Psychiatric Research*, 78, 94–102. <https://doi.org/10.1016/j.jpsychires.2016.03.016>
- Iniesta, R., Malki, K., Maier, W., Rietschel, M., Mors, O., Hauser, J., Henigsberg, N., Dernovsek, M. Z., Souery, D., Stahl, D., Dobson, R., Aitchison, K. J., Farmer, A., Lewis, C. M., McGuffin, P., & Uher, R. (2016b). Combining clinical variables to optimize prediction of antidepressant treatment outcomes. *Journal of Psychiatric Research*, 78, 94–102. <https://doi.org/10.1016/j.jpsychires.2016.03.016>
- Jan, A., Meng, H., Gaus, Y. F. B. A., & Zhang, F. (2018). Artificial Intelligent System for Automatic Depression Level Analysis Through Visual and Vocal Expressions. *IEEE Transactions on*

- Jin, H., Wu, S., & di Capua, P. (2015). Development of a clinical forecasting model to predict comorbid depression among diabetes patients and an application in depression screening policy making. *Preventing Chronic Disease*, 12(9). <https://doi.org/10.5888/pcd12.150047>
- Koutsouleris, N., Kambeitz-Ilankovic, L., Ruhrmann, S., Rosen, M., Ruef, A., Dwyer, D. B., Paolini, M., Chisholm, K., Kambeitz, J., Haidl, T., Schmidt, A., Gillam, J., Schultze-Lutter, F., Falkai, P., Reiser, M., Riecher-Rössler, A., Upthegrove, R., Hietala, J., Salokangas, R. K. R., ... Borgwardt, S. (2018). Prediction Models of Functional Outcomes for Individuals in the Clinical High-Risk State for Psychosis or with Recent-Onset Depression: A Multimodal, Multisite Machine Learning Analysis. *JAMA Psychiatry*, 75(11), 1156–1172. <https://doi.org/10.1001/jamapsychiatry.2018.2165>
- Kumar, S., & Chong, I. (2018a). Correlation analysis to identify the effective data in machine learning: Prediction of depressive disorder and emotion states. *International Journal of Environmental Research and Public Health*, 15(12). <https://doi.org/10.3390/ijerph15122907>
- Kumar, S., & Chong, I. (2018b). Correlation analysis to identify the effective data in machine learning: Prediction of depressive disorder and emotion states. *International Journal of Environmental Research and Public Health*, 15(12). <https://doi.org/10.3390/ijerph15122907>
- Le, T. T., Fu, W., & Moore, J. H. (2020). Scaling tree-based automated machine learning to biomedical big data with a feature set selector. *Bioinformatics*, 36(1), 250–256. <https://doi.org/10.1093/bioinformatics/btz470>
- Oh, J., Yun, K., Hwang, J. H., & Chae, J. H. (2017). Classification of Suicide Attempts through a Machine Learning Algorithm Based on Multiple Systemic Psychiatric Scales. *Frontiers in Psychiatry*, 8. <https://doi.org/10.3389/fpsy.2017.00192>
- O'Halloran, R., Kopell, B. H., Sprooten, E., Goodman, W. K., & Frangou, S. (2016). Multimodal neuroimaging-informed clinical applications in neuropsychiatric disorders. *Frontiers in Psychiatry*, 7(APR). <https://doi.org/10.3389/fpsy.2016.00063>
- Passos, I. C., Mwangi, B., Cao, B., Hamilton, J. E., Wu, M. J., Zhang, X. Y., Zunta-Soares, G. B., Quevedo, J., Kauer-Sant'Anna, M., Kapczinski, F., & Soares, J. C. (2016). Identifying a clinical signature of suicidality among patients with mood disorders: A pilot study using a machine learning approach. *Journal of Affective Disorders*, 193, 109–116. <https://doi.org/10.1016/j.jad.2015.12.066>
- Patel, M. J., Andreescu, C., Price, J. C., Edelman, K. L., Reynolds, C. F., & Aizenstein, H. J. (2015). Machine learning approaches for integrating clinical and imaging features in late-life depression classification and response prediction. *International Journal of Geriatric Psychiatry*, 30(10), 1056–1067. <https://doi.org/10.1002/gps.4262>

- Pérez Rave, J. (2012). *Revisión Sistemática de Literatura en Ingeniería* (Sello Editorial Universidad de Antioquia, Dic. 2012, ISBN: 978-958-714-543-4).
- Pérez Rave, J. (2019). *Revisión Sistemática de Literatura en Ingeniería, ampliada y actualizada* (Sello Editorial IDINNOV, Dic. 2019, ISBN: 978-958-58897-6-7).
- Redlich, R., Opel, N., Grotegerd, D., Dohm, K., Zaremba, D., Burger, C., Munker, S., Muhlmann, L., Wahl, P., Heindel, W., Arolt, V., Alferink, J., Zwanzger, P., Zavorotnyy, M., Kugel, H., & Dannlowski, U. (2016). Prediction of individual response to electroconvulsive therapy via machine learning on structural magnetic resonance imaging data. *JAMA Psychiatry*, 73(6), 557–564. <https://doi.org/10.1001/jamapsychiatry.2016.0316>
- Reps, J. M., Schuemie, M. J., Suchard, M. A., Ryan, P. B., & Rijnbeek, P. R. (2018a). Design and implementation of a standardized framework to generate and evaluate patient-level prediction models using observational healthcare data. *Journal of the American Medical Informatics Association*, 25(8), 969–975. <https://doi.org/10.1093/jamia/ocy032>
- Reps, J. M., Schuemie, M. J., Suchard, M. A., Ryan, P. B., & Rijnbeek, P. R. (2018b). Design and implementation of a standardized framework to generate and evaluate patient-level prediction models using observational healthcare data. *Journal of the American Medical Informatics Association*, 25(8), 969–975. <https://doi.org/10.1093/jamia/ocy032>
- Ryu, S., Lee, H., Lee, D. K., & Park, K. (2018). Use of a machine learning algorithm to predict individuals with suicide ideation in the general population. *Psychiatry Investigation*, 15(11), 1030–1036. <https://doi.org/10.30773/pi.2018.08.27>
- Schnyer, D. M., Clasen, P. C., Gonzalez, C., & Beevers, C. G. (2017). Evaluating the diagnostic utility of applying a machine learning algorithm to diffusion tensor MRI measures in individuals with major depressive disorder. *Psychiatry Research - Neuroimaging*, 264, 1–9. <https://doi.org/10.1016/j.pscychresns.2017.03.003>
- Tran, T., & Kavuluru, R. (2017). Predicting mental conditions based on “history of present illness” in psychiatric notes with deep neural networks. *Journal of Biomedical Informatics*, 75, S138–S148. <https://doi.org/10.1016/j.jbi.2017.06.010>

## **Anexo C - Publicación artículo 2**

### **Estadística aplicada a la predicción de enfermedades mentales: Una revisión sistemática**

Sebastian Osorio Castrillon<sup>1</sup> , Lillyana María Giraldo Marín<sup>2</sup> , Herman Horacio Jaramillo Villegas<sup>3</sup> , Carlos César Piedrahita Escobar<sup>4</sup>

osoriocastrillon1@gmail.com; lmgiraldo@udem.edu.co; hjaramillo@udem.edu.co; cpiedrahita@udem.edu.co

1 Estudiante Maestría en Modelación y Ciencia Computacional, Universidad de Medellín, Antioquia, Colombia

2 Profesor titular, Facultad de Ingenierías, Universidad de Medellín, Antioquia, Colombia

3 Profesor, Facultad de Ciencias Básicas, Universidad de Medellín, Antioquia, Colombia

4 Profesor, Facultad de Ciencias Básicas, Universidad de Medellín, Antioquia, Colombia Pages: 266-275

**Resumen:** El principal reto de las aseguradoras de la salud es pasar de una gestión reactiva a una gestión proactiva de sus afiliados, es decir, priorizar la prevención e implementación de acciones que favorezcan la salud en sus dimensiones tanto físicas como mentales y sociales, y no solo que mitiguen la enfermedad. Este artículo presenta una revisión sistemática de la literatura sobre las principales metodologías de aprendizaje automático que permiten a través de la predicción de enfermedades mentales, realizar una intervención temprana. Se encontró que las principales metodologías para dicho fin son los modelos estadísticos como la regresión logística y las redes neuronales; y que los diferentes indicadores de las neuroimágenes y el comportamiento en redes sociales se convierten en variables predictoras fundamentales a la hora de predecir las enfermedades mentales.

Palabras-clave: Aprendizaje automático, minería de datos, predicción enfermedades mentales.

### **Statistics applied to the prediction of mental illness: A systematic review**

**Abstract:** The main challenge for health insurers is to move from reactive to proactive management of their clients, that is, prioritize prevention and implementation of actions that favor health in its physical, mental, and social dimensions, and not only that mitigate the disease. This article presents a systematic review of the literature on the main machine learning methodologies that allow, through the prediction of mental illnesses, to carry out an early intervention. It was found that the main methodologies for this purpose are statistical models such as logistic regression and neural networks; and that the different indicators of neuroimaging and behavior in social networks become fundamental predictor variables when it comes to predicting mental illnesses.

Keywords: Machine learning – data mining - Mental Illness – prediction

## **1. Introducción**

Los sistemas de salud todavía no han dado una respuesta adecuada a la carga de trastornos mentales; en consecuencia, la divergencia entre la necesidad de tratamiento y su prestación es grande en todo el mundo. En los países de ingresos bajos y medios, entre un 76% y un 85% de las personas con trastornos mentales graves no reciben tratamiento; la cifra es alta también en los países de ingresos elevados: entre un 35% y un 50%. El problema se complica aún más por la escasa calidad de la atención que reciben los casos tratados (OMS, 2012).

Según la OMS son 400 millones de personas afectadas esta podría convertirse en la segunda causa de discapacidad en el mundo después de las enfermedades coronarias y cerebrovasculares (Castro, 2005). Hoy en día los sistemas de salud en Colombia han venido transformando los enfoques de gestión de sus afiliados; pasando de una gestión reactiva a una gestión proactiva de los mismos, es decir, priorizando la prevención e implementación de acciones que favorezcan y prioricen la salud en sus dimensiones tanto físicas como mentales y sociales, y no solo que mitiguen la enfermedad (OMS, 2016).

Uno de los grandes desafíos a los que se ven enfrentadas las aseguradoras, es a la prevención de enfermedades mentales debido a su aumento significativo en los últimos años, (Ministerio de salud, 2020) pues los desórdenes mentales y los trastornos psíquicos, incluidas las manifestaciones depresivas, la esquizofrenia, el alzheimer, la epilepsia y el retraso mental, representan el 11% del total de las enfermedades en el mundo (Castro, 2005). Los trastornos mentales influyen a menudo en otras enfermedades tales como el cáncer, las enfermedades cardiovasculares o la infección por el VIH/sida, y se ven influidos por ellas, por lo que requieren servicios y medidas de movilización de recursos comunes. Por ejemplo, hay pruebas de que la depresión predispone al infarto de miocardio y a la diabetes, que a su vez aumentan la probabilidad de sufrir depresión (OMS, 2012).

En consecuencia, el machine learning es una rama de la ciencia computacional cuyo uso ha tomado fuerza a la hora de predecir enfermedades mentales bajo el uso de diferentes metodologías, como lo son los cálculos del índice de estado de enfermedad (DSI) cuya técnica funciona bien a la hora de identificar perfiles integrales para predecir el desarrollo de la demencia, con el fin de generar intervenciones tempranas (Pekkala et al., 2016). Así mismo como la regresión lineal y las redes neuronales que son útiles no solo para la predicción de enfermedades mentales sino también de enfermedades cardiovasculares.

Este artículo presenta una revisión sistemática de la literatura que permita dar cuenta de las metodologías más utilizadas para predicción de enfermedades, haciendo énfasis en aquellas que permitan predecir un estado de salud mental desfavorable de las personas, así mismo, identificar cuáles son los principales factores de riesgo asociados a estas.

## **2. Metodología**

El desarrollo de la revisión sistemática de la literatura se realizó bajo los siguientes parámetros:

- Definición de preguntas de investigación
- Definición de base de datos, ecuación de búsqueda y selección de artículos

### **2.1. Definición de preguntas de investigación**

Se plantearon 4 preguntas de investigación como guía de la revisión sistemática:

- **P1.** ¿Cuáles son las principales metodologías estadísticas utilizadas para la predicción de las enfermedades mentales?
- **P2.** ¿Cuáles son las principales variables utilizadas para predecir enfermedades mentales?
- **P3.** ¿Cuáles son los factores de riesgo relacionados con enfermedades mentales?

– P4. ¿Cuál es el estado actual y los desafíos investigativos de los modelos estadísticos aplicados a la predicción de enfermedades mentales?

## 2.2. Selección de artículos

La búsqueda se realizó en la base de datos SCOPUS, principalmente por la facilidad que brinda a la hora de analizar y visualizar diferentes indicadores bibliométricos, así mismo, como la completitud rapidez y facilidad de encontrar información científica; dicha búsqueda se realizó en enero de 2021. Una vez ejecutada la ecuación de búsqueda (figura 1), en la que se garantizó que estuvieran los principales términos relacionados con el tema de interés, tales como: machine learning, data mining y predicción de enfermedades mentales e incluyendo filtros como: solo artículos, idioma inglés y publicados solo hasta el año 2020, se obtuvo un resultado de 92 artículos.

The image shows a search query builder interface with three rows of search criteria. Each row consists of a 'Search within' dropdown menu and a 'Search documents' text input field. The first row has 'All fields' selected in the dropdown and 'machine learning' in the input field. The second row has 'All fields' selected and 'data mining' in the input field. The third row has 'Article title, Abstract, Keywords' selected and 'mental illness prediction' in the input field. The rows are connected by 'OR' and 'AND' operators, with 'OR' between the first and second rows, and 'AND' between the second and third rows. Each operator has a dropdown arrow next to it.

Figura 1 – Ecuación de búsqueda. Fuente: Elaboración propia.

## 2.3 Vigencia del tema

En la figura 2 se indican el número de publicaciones por año acerca del uso del tema machine learning para la predicción de enfermedades mentales; se observa que fue en el año 2012 cuando se presentó el primer artículo relacionado (de acuerdo con los filtros aplicados), a partir de este momento hay un incremento significativo de artículos sobre todo a partir del año 2016.

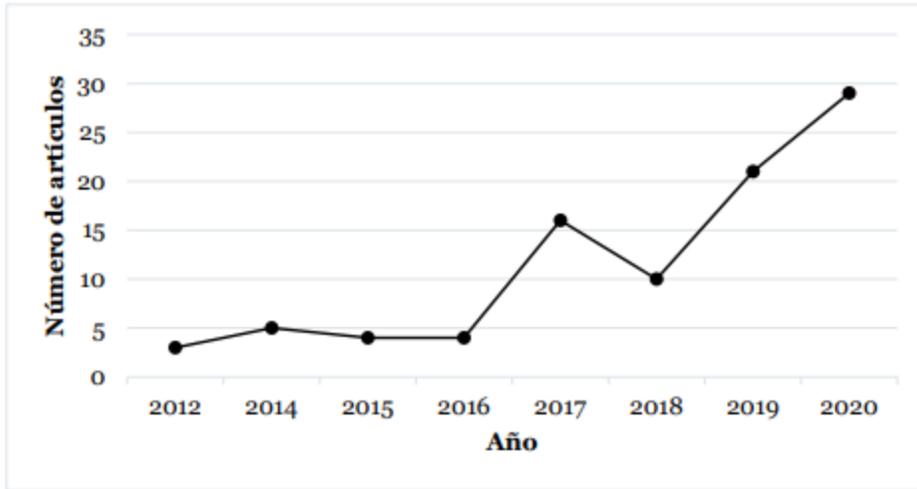


Figura 2 – Número de publicaciones por año. Fuente: (Scopus, 2021).

Dada la vigencia del tema se tuvieron en cuenta solo aquellos artículos publicados en los últimos 6 años, llegando así a un total de 80 artículos. El espacio literario relevante (figura 3) de estos 80 artículos, permite concluir que el 22% (18) representan el 80% de las citas

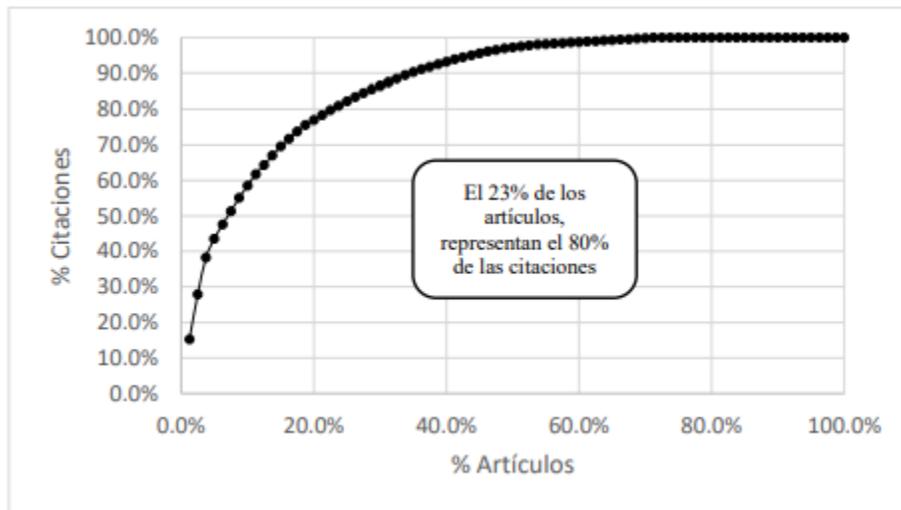


Figura 3 – Espacio literario relevante. Fuente: Elaboración propia.

Finalmente se hizo una revisión detallada de los resúmenes de estos 18 artículos para garantizar su relación con el tema y se excluyeron 2, quedando así con un total de 16 artículos para revisar. Ver tabla 1.

#	ID	Título	Citas	Año
1	10.1016/j.jbi.2017.04.001	<i>Predicting healthcare trajectories from medical records: A deep learning approach</i>	110	2017
2	10.1038/mp.2015.198	<i>Testing a machine-learning algorithm to predict the persistence and severity of major depressive disorder from baseline self-reports</i>	91	2016
3	10.1073/pnas.1802331115	<i>Facebook language predicts depression in medical records</i>	75	2018
4	10.1007/s11277-016-3923-3	<i>Depression Index Service Using Knowledge Based Crowdsourcing in Smart Health</i>	29	2017
5	10.1016/j.jbi.2017.06.010	<i>Predicting mental conditions based on "history of present illness" in psychiatric notes with deep neural networks</i>	27	2017
6	10.1007/s00406-018-0943-x	<i>Neurobiology of the major psychoses: a translational perspective on brain structure and function—the FOR2107 consortium</i>	27	2019
7	10.2196/jmir.9268	<i>Prediction of incident hypertension within the next year: Prospective study using statewide electronic health records and machine learning</i>	25	2018
8	10.1186/s12888-018-1801-0	<i>Youth at-risk for serious mental illness: Methods of the PROCAN study</i>	19	2018
9	10.1016/j.jbi.2017.04.017	<i>Symptom severity prediction from neuropsychiatric clinical records: Overview of 2016 CEGS N-GRID shared tasks Track 2</i>	19	2017
10	10.1016/j.neuroimage.2017.08.006	<i>Task modulations and clinical manifestations in the brain functional connectome in 1615 fMRI datasets</i>	19	2017
11	10.1016/j.neuroimage.2015.12.050	<i>Decoding negative affect personality trait from patterns of brain activation to threat stimuli</i>	15	2017
12	10.3233/JAD-160560	<i>Development of a late-life dementia prediction index with supervised machine learning in the population-based CAIDE study</i>	15	2017
13	10.7717/peerj-cs.177	<i>SNARE-CNN: A 2D convolutional neural network architecture to identify SNARE proteins from high-throughput sequencing data</i>	13	2019
14	10.1016/j.jbi.2017.05.015	<i>Symptom severity classification with gradient tree boosting</i>	10	2017
15	10.1016/j.eurpsy.2016.06.004	<i>Cognitive behavioral therapy for compulsive buying behavior: Predictors of treatment outcome</i>	10	2017
16	10.1016/j.jns.2016.04.030	<i>Prediction of individual clinical scores in patients with Parkinson's disease using resting-state functional magnetic resonance imaging</i>	10	2016

Tabla 1 – Artículos seleccionados. Fuente: Elaboración propia.

### 3. Resultados de la revisión sistemática de la literatura

Para dar respuesta a las preguntas de investigación planteadas, se realizó la lectura completa de los 16 artículos seleccionados con la metodología descrita anteriormente, a cada uno de éstos se les construyó una ficha técnica en la que se incluyeron los componentes más relevantes, tales como el propósito general del artículo, cómo daba respuesta a la(s) pregunta(s) de investigación,

qué preguntas quedaban sin responder y el resumen. Con base en esto se dio respuesta a las preguntas como se describe a continuación:

**P1.** ¿Cuáles son las principales metodologías estadísticas utilizadas para la predicción de las enfermedades mentales?

En 6 de los artículos (2,3,7,10,11,15 descritos en la tabla 1), los cuales representan el 37.5% del total revisados, se implementaron regresiones logísticas para predecir enfermedades mentales, las cuales contribuyen a un mejor ajuste de las predicciones aun teniendo un número considerable de variables predictoras (Granero et al., 2017).

En 3 de los artículos (18.8%) utilizaron redes neuronales (1,5,13 descritos en la tabla 1), es importante aclarar que, si bien en el artículo número 1 la implementación de la red neuronal es para predecir las trayectorias de atención médica a partir de registros médicos, y no las enfermedades mentales, dicha metodología es extrapolable dado que los parámetros utilizados son homologables aun teniendo una función objetivo diferente. Estas 2 metodologías son las más representativas (56.3% del total de los artículos). En los demás, utilizaron metodologías como árboles de decisión (artículo número 9), regresión de cox (artículo número 8) y de más metodologías mostradas en la figura 4.

Entre estas metodologías se encuentra el índice de estado de enfermedad con sus siglas en inglés (DSI) el cual es un método de aprendizaje automático supervisado diseñado para su implementación práctica como un sistema de apoyo a la toma de decisiones clínicas. El DSI se ha probado ampliamente y se ha demostrado que funciona bien en el contexto de la mejora del diagnóstico precoz de la enfermedad de Alzheimer y el diagnóstico diferencial de enfermedades neurodegenerativas (Pekkala et al., 2016).

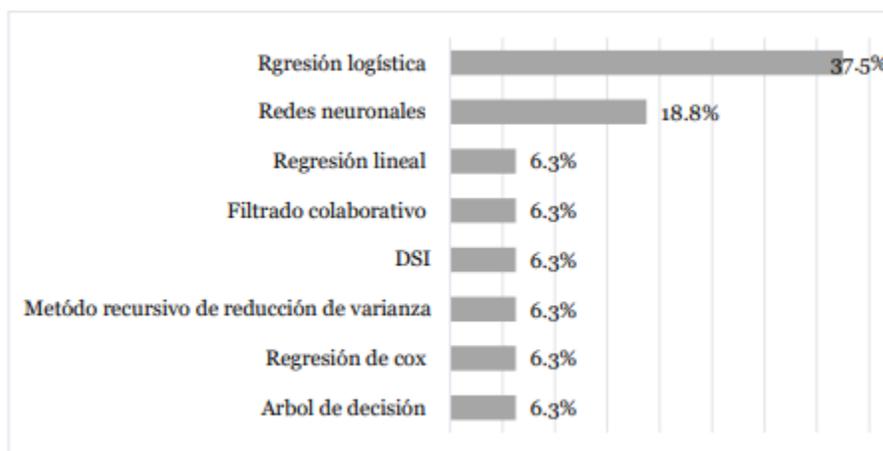


Figura 4 – Metodologías Estadísticas. Fuente: Elaboración propia.

**P2.** ¿Cuáles son las principales variables utilizadas para predecir enfermedades mentales?

En términos generales, los artículos plantean que los datos sociodemográficos tales como el sexo, la edad y el nivel educativo son importantes a la hora de predecir las enfermedades mentales, sin embargo, las neuroimágenes se convierten en variables indispensables a la hora de realizar las predicciones. Como se muestra en la figura 5, el 37% de los artículos que describen de manera detallada las variables utilizadas para la predicción, relacionan las neuroimágenes y adicional lo plantean como una posibilidad de mejorar la precisión de dichos modelos (Addington et al., 2018), así mismo como el comportamiento de publicaciones en Facebook. (Eichstaedt et al., 2018).

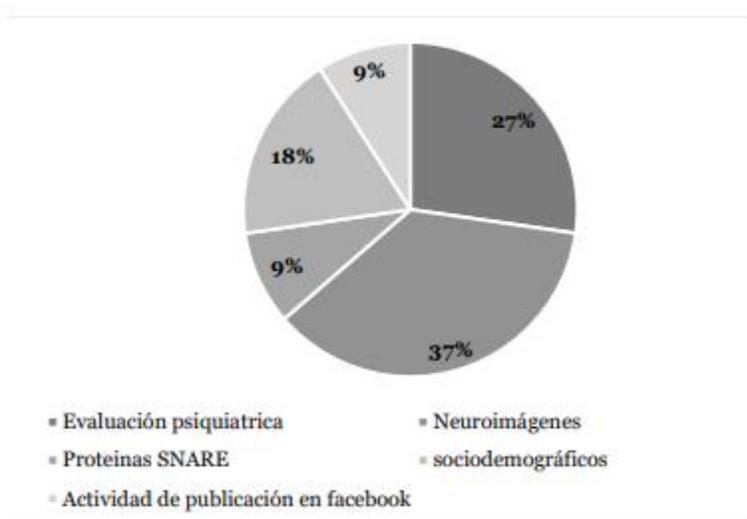


Figura 5 – Variables predictoras Fuente: Elaboración propia.

**P3.** ¿Cuáles son los factores de riesgo relacionados con enfermedades mentales?

Los principales factores de riesgo asociados con las enfermedades mentales según la revisión sistemática son los comportamientos depresivos, el sexo (hombre) y el consumo de sustancias psicoactivas. Como se muestra en la tabla 2:

Factor de Riesgo	Artículos que lo relacionan
Comportamientos depresivos	2, 14, 12, 15, 9
Ortografía	3
Enfermedad mental como factor de riesgo de la hipertensión	1
Sexo - hombre	15
Consumo sustancias psicoactivas	9

Tabla 2 – Factores de riesgo asociados a enfermedades mentales. Fuente: Elaboración propia.

Es importante aclarar que, si bien se describen factores de riesgo relacionados de manera directa con las enfermedades mentales, existen evidencias de que la enfermedad mental como tal puede

convertirse en un factor de riesgo para el desarrollo de otras enfermedades como la hipertensión, es por esto que toma relevancia la identificación de dichos factores de riesgo ya que si logran combatirse y llegar a una gestión proactiva de afiliados a las diferentes aseguradoras de la salud se mitigan a su vez enfermedades de diferentes tipos.

**P4.** ¿Cuál es el estado actual y los desafíos investigativos de los modelos estadísticos aplicados a la predicción de enfermedades mentales?

En términos generales, se muestra un uso significativo de las metodologías para la predicción de enfermedades mentales, sin embargo, no se han realizado intentos para investigar el rol de los neurobiológicos y marcadores genéticos en modelos de predicción para los servicios médicos integrales (Addington et al., 2018), adicionalmente es importante profundizar en investigaciones que incorporen una gama más amplia de tareas cognitivas que involucren diferentes modalidades sensoriales (auditivas, somatosensoriales, motoras) y métodos de aprendizaje que puedan mejorar la precisión en los diferentes modelos. (Gonzalez-Castillo & Bandettini, 2018).

En cuanto al uso de las notas psiquiátricas es un desafío para los programadores neurolingüísticos el uso e interpretación de notas en formato incorrecto (Filannino et al., 2017) que a su vez abren posibilidades no solo de predecir las enfermedades sino los medicamentos que aplican para cada una de ella (Pham et al., 2017).

#### **4. Conclusiones**

Los resultados más importantes de la revisión sistemática de la literatura sugieren que entre las principales metodologías de machine learning utilizadas para la predicción de enfermedades mentales, se encuentran las redes neuronales y las regresiones logísticas, las cuales agregan valor en la medida que permiten clasificar a las personas de acuerdo con las probabilidades de presentar una enfermedad mental lo que permitiría una gestión anticipada por parte de las aseguradoras en salud.

Las principales variables que deben tenerse en cuenta a la hora de desarrollar dichos modelos, según lo señala la revisión, son las sociodemográficas específicamente el sexo y la edad, así mismo las notas psiquiátricas que dan cuenta del estado mental previo de las personas que se incluirían en los estudios, y no menos importante y en concordancia con la dinámica social actual el comportamiento de publicaciones en redes sociales, haciendo énfasis en el contenido de las publicaciones, la ortografía y el número de interacciones.

Partiendo de la dinámica mundial enfocada en promoción de la salud y prevención de la enfermedad, es importante la identificación de los factores de riesgo asociados a las enfermedades mentales, ya que su anticipación apunta a la calidad de vida de las personas y a la disminución de costos en el sector salud, y a su vez la prevención de las enfermedades disminuye la probabilidad de presentar comorbilidades adicionales como la hipertensión y la diabetes. Dichos factores de riesgo están principalmente relacionados con las variables sociodemográficas específicamente el sexo y la edad, y los antecedentes de depresión y de más síntomas mentales relacionados.

- Referencias Addington, J., Goldstein, B. I., Wang, J. L., Kennedy, S. H., Bray, S., Lebel, C., Hassel, S., Marshall, C., & MacQueen, G. (2018). Youth at-risk for serious mental illness: Methods of the PROCAN study. *BMC Psychiatry*, 18(1). <https://doi.org/10.1186/s12888-018-1801-0>
- Castro, H. M. L. (2005). REVISTA DE PSIQUIATRIA Y SALUD MENTAL HERMILIO VALDIZAN ESTIGMA Y ENFERMEDAD MENTAL: UN PUNTO DE VISTA HISTORICO-SOCIAL.
- Eichstaedt, J. C., Smith, R. J., Merchant, R. M., Ungar, L. H., Crutchley, P., PreoțiuPietro, D., Asch, D. A., & Schwartz, H. A. (2018). Facebook language predicts depression in medical records. *Proceedings of the National Academy of Sciences of the United States of America*, 115(44), 11203–11208. <https://doi.org/10.1073/pnas.1802331115>
- Filannino, M., Stubbs, A., & Uzuner, Ö. (2017). Symptom severity prediction from neuropsychiatric clinical records: Overview of 2016 CEGS N-GRID shared tasks Track 2. *Journal of Biomedical Informatics*, 75, S62–S70. <https://doi.org/10.1016/j.jbi.2017.04.017>
- Gonzalez-Castillo, J., & Bandettini, P. A. (2018). Task-based dynamic functional connectivity: Recent findings and open questions. *NeuroImage*, 180. <https://doi.org/10.1016/j.neuroimage.2017.08.006>
- Granero, R., Fernández-Aranda, F., Mestre-Bach, G., Steward, T., Baño, M., Agüera, Z., Mallorquí-Bagué, N., Aymamí, N., Gómez-Peña, M., Sancho, M., Sánchez, I., Menchón, J. M., Martín-Romera, V., & Jiménez - Murcia, S. (2017). Cognitive behavioral therapy for compulsive buying behavior: Predictors of treatment outcome. *European Psychiatry*, 39. <https://doi.org/10.1016/j.eurpsy.2016.06.004>
- Kessler, R. C., van Loo, H. M., Wardenaar, K. J., Bossarte, R. M., Brenner, L. A., Cai, T., Ebert, D. D., Hwang, I., Li, J., de Jonge, P., Nierenberg, A. A., Petukhova, M. v., Rosellini, A. J., Sampson, N. A., Schoevers, R. A., Wilcox, M. A., & Zaslavsky, A. M. (2016). Testing a machine-learning algorithm to predict the persistence and severity of major depressive disorder from baseline self-reports. *Molecular Psychiatry*, 21(10), 1366–1371. <https://doi.org/10.1038/mp.2015.198>
- Le, N. Q. K., & Nguyen, V. N. (2019). SNARE-CNN: A 2D convolutional neural network architecture to identify SNARE proteins from high-throughput sequencing data. *PeerJ Computer Science*, 2019(5). <https://doi.org/10.7717/peerj-cs.177>
- Minsalud. (2020). Minsalud ratifica su compromiso con la salud mental de los colombianos. Ministerio de salud. <https://www.minsalud.gov.co/Paginas/Minsalud-ratifica-su-compromiso-con-la-salud-mental-de-los-colombianos.aspx>
- OMS. (2012). Plan de acción sobre salud mental 2013-2020. Organización Mundial de la Salud. [https://www.who.int/mental\\_health/publications/action\\_plan/es](https://www.who.int/mental_health/publications/action_plan/es)
- OMS. (2016). ¿Qué es la promoción de la salud? Organización Mundial de la Salud. <https://www.who.int/features/qa/health-promotion/es/>

## PROGRAM

### The 2021 online Multidisciplinary International Conference of Research Applied to Defense and Security (MICRADS'21)

Cartagena, Colombia

18th to 19th of August 2021

**Time Zone: (GMT-5:00) Bogotá**

**S3 - Session 3 | Room 2:**

<https://us02web.zoom.us/j/82329686800?pwd=RTlZNmxhcnh3ZjlvVnRhMXdrUWUxZz09>

**Chair:** John Castro

**267** - Estadística aplicada a la predicción de enfermedades mentales: Una revisión sistemática.  
(Sebastián Osorio Castrillón, Lillyana María Giraldo Marín, Herman Horacio Jaramillo Villegas, Carlos César Piedrahita Escobar)