

Minería de datos y aprendizaje máquina aplicado en la predicción de salud mental en trabajadores de tecnologías de la información

Kori Antunez*, Ingrid Cortez, Mishell Gomez, Alexandra Gonzales,
Naysha Santiago, David Calderón, Flor Cárdenas

Universidad Nacional Mayor de San Marcos,
Departamento de Ingeniería de Software,
Perú

{kori.antunez, ingrid.cortez, mishell.gomez, alexandra.gonzales1, naysha.santiago,
hcalderonv, fcardenasm}@unmsm.edu.pe

Resumen. En la actualidad la salud mental es un problema cada vez más frecuente en las personas. Trastornos mentales tales como los de ansiedad y depresión tienden a contribuir a los cambios de comportamiento relacionados con su trabajo, como la reducción del nivel de actividad y el mal rendimiento. El objetivo de esta investigación es medir las actitudes respecto la salud mental en el área de TI. Como técnicas de selección de atributos se usó el filtro ANOVA F-test y el filtro Chi-Cuadrado, para el modelado se aplicaron los algoritmos de K-Nearest Neighbor (KNN), Decision Tree, Support Vector Machine (SVM), Naive Bayes y Neural Network. Se trabajó con un conjunto de datos obtenidos de OSMH/OSMI Mental Health in Tech Survey, el cual contó con alrededor de 1400 respuestas, estos resultados fueron obtenidos de una encuesta llevada a cabo en el 2016. El algoritmo que obtuvo los mejores resultados en el conjunto de datos analizados fue Neural Network. Como métricas del modelo se obtuvo un F1-Score del 85.92%, un área bajo la curva ROC de 0.903, un menor valor de falsos negativos con 23 y mayor valor de verdaderos positivos con 119 en la matriz de confusión.

Palabras clave. Salud mental; predicción de salud mental; minería de datos; trabajadores de TI; machine learning.

Data Mining and Machine Learning Applied to Mental Health Prediction in Information Technology Workers

Abstract. Currently, mental health is an increasingly frequent problem. Mental disorders such as anxiety and depression tend to contribute to work-related behavioral changes, such as reduced activity levels and poor

performance. The objective of this research is to measure attitudes towards mental health in the IT sector. The ANOVA F-test and Chi-Square filter were used as feature selection techniques. For modeling, the following algorithms were applied: K-Nearest Neighbor (KNN), Decision Tree, Support Vector Machine (SVM), Naive Bayes, and Neural Network. The study used a dataset obtained from the OSMH/OSMI Mental Health in Tech Survey, which included around 1400 responses from a survey conducted in 2016. The Neural Network algorithm achieved the best results on the analyzed dataset. The model metrics obtained were an F1-Score of 85.92%, an Area Under the ROC Curve (AUC) of 0.903, a lower value of 23 false negatives, and a higher value of 119 true positives in the confusion matrix.

Keywords: Mental health; mental health prediction; data mining; IT workers; machine learning.

1. Introducción

De entre todas las enfermedades que existen, la magnitud de las enfermedades que afectan a la salud mental repercute fuertemente en el mundo, cuya necesidad de un tratamiento es amplia. Para dar una idea clara, en los países de recursos bajos y medios, entre 76 y 85% de personas que sufren trastornos mentales no tienen oportunidad de recibir un tratamiento, mientras que, en los países de altos ingresos económicos, la cifra abarca entre el 35 a 50% [1].

La salud mental es una de las principales causas de ausencia por enfermedad y discapacidad laboral en gran parte de los países desarrollados, siendo la mayoría de estos tratables

[2]. Para el año 2030 se espera que los costos globales para tratar la salud mental superarán los 6000 millones de dólares por año, superando a costos de salud como la diabetes y el cáncer [3].

Entre varios de los afectados por este tipo de enfermedades, se encuentran los trabajadores de la industria del Tecnologías de Información (TI), que son propensos a desarrollar problemas de salud debido al estrés físico y mental continuo por su trabajo.

De hecho, un estudio realizado a trabajadores de TI en la India reveló que cerca del 56% de ellos sufrían de problemas musculoesqueléticos, 54% depresión y ansiedad, 40% obesidad y 36% dislipidemia, siendo ellos los que tuvieron una puntuación de estrés muy alta [4].

Al tener un ambiente laboral estresante, impacta a los empleados manifestándose a través de una reducción de la satisfacción laboral, disminución de la motivación, reducción de la calidad del trabajo y el aumento del tabaquismo [5].

También se ve reflejado en un informe de la Unión Europea sobre la salud mental [6], en España llegan a fallecer 17970 personas al año por problemas de salud mental.

Por tanto, el objetivo de esta investigación es la predicción de la probabilidad de que los trabajadores del sector de TI padezcan problemas de salud mental.

Para diseñar el modelo de predicción se consideraron los datos recolectados de la Encuesta de Salud Mental en el área de la Tecnología realizada por la corporación Open Sourcing Mental Health durante el año 2016, mediante las técnicas de minería de datos se ha integrado como conjunto de datos, realizando el preprocesamiento y reducción, selección de mejores variables predictoras utilizando χ^2 y ANOVA, considerando el conjunto de datos limpiado y reducido, finalmente se ha probado los algoritmos de machine learning K-Nearest Neighbor, Neural Network, Decision Tree, Support Vector Machine y Naive Bayes para buscar el mejor modelo de predicción.

2. Trabajos relacionados

2.1. Análisis de la salud mental en los trabajadores de TI en organizaciones

En el sector de tecnologías de la información donde se han realizado diversas investigaciones, en el estudio [7] emplearon el algoritmo Naive Bayes y árbol de decisiones con el objetivo de evaluar el grado del riesgo psicosocial para así poderlo reducir sistemáticamente, también en [8] analizaron y demuestran que existen varios factores personales y laborales que influyen en su salud mental, así como su prevalencia, usaron en este caso técnicas de minería de datos y algoritmos de machine learning para construir el modelo de predicción.

El análisis de la salud mental en los trabajadores de empresas e instituciones contempla el estudio de variables y factores individuales, organizacionales y sociales, con el objetivo de identificar los atributos más importantes que desencadenan problemas de salud mental [2]. En Irán que sus trabajadores de TI dedicaban una larga parte de su vida a sus lugares de trabajo, vieron importante realizar una investigación [9] donde analizaron a través de los modelos de árbol de decisión y clasificador bayesiano la prevalencia de los problemas de salud mental en sus trabajadores relacionados a esta área.

Sandhya [11] implementó la predicción de trastorno mental para los empleados de una industria de TI. En este estudio se utilizaron los datos obtenidos de una encuesta realizada entre los profesionales de las diferentes regiones de la India. Se aplicaron 7 técnicas de aprendizaje automático tales como Regresión Logística, K-vecinos más cercanos, Árbol de decisiones, Bosque aleatorio, Bagging, Boosting y Red Neuronal; a fin de comparar el mejor modelo que se adapta al conjunto de datos. Los resultados indican que el mejor modelo para identificar si un empleado necesita atención o no a los problemas de salud mental, resulta ser el algoritmo de Boosting superando a los otros algoritmos con una precisión del 81,7%. Esta investigación prueba que las técnicas de clasificación de aprendizaje automático resultan ser alentadoras para la

detección de problemas mentales entre los empleados de una organización de TI.

Youse y Raeesi [10] desarrollaron un modelo para evaluar la salud mental de los trabajadores en empresas de base tecnológica. Dicho estudio se centró en técnicas de minería de datos con el fin de introducir un modelo de predicción para identificar los aspectos y características que dan lugar a problemas de salud mental en los empleados de empresas de base tecnológica. Los autores emplearon métodos de clasificación para determinar la probabilidad de padecer o no trastornos mentales, tales como Árbol de decisión, Árbol ID3, Árbol CHAID, Bosque aleatorio, K-vecino más cercano, Naive Bayes y redes neuronales. Así también emplearon métodos de agrupación para identificar clusters y obtener información sobre la distribución y el procesamiento de los datos, utilizando algoritmos como K-Means y K-Medoids.

La evaluación de los resultados indicó que los algoritmos de clasificación lograron predecir las posibilidades de aflicción con trastornos mentales con una precisión promedio de 79,89%. El algoritmo de árbol de decisión superó a los otros algoritmos con una precisión (accuracy) de 84,99%, obteniendo resultados muy prometedores en comparación a los obtenidos por Sandhya [11]. Por otro lado, los algoritmos de agrupación lograron dividir las muestras en grupos de alto riesgo, riesgo medio, y clases de bajo riesgo. Este estudio revela que los modelos diseñados pueden ayudar a los gerentes organizacionales a identificar los factores que pueden afectar la salud mental de los empleados y predecir las posibilidades de aflicción con la salud mental.

Otros estudios consideran relevante en el análisis de la salud mental, la identificación de factores que desencadenan este tipo de problemas. Rahman [2] mediante la implementación de técnicas de clasificación de minería de datos en el conjunto de datos del Observatorio de Salud y Medicina Integrativa (OSMI) sobre la atención de salud mental en trabajadores tecnológicos, encontró que, la interferencia laboral y los antecedentes familiares son los atributos más importantes para predecir si un empleado ha solicitado/buscado o no tratamiento de salud mental. Este estudio determinó que, de las técnicas de clasificación de

minería de datos, el árbol de decisión presentaba mejores predicciones con un 88,5% de precisión; ofreciendo mejores resultados que los obtenidos en Youse y Raeesi [10].

En otro estudio se centraron en la etapa de diagnóstico e identificación de factores y a usuarios con posible riesgo de enfermedad mental, hacen uso de los algoritmos de redes bayesianas, árboles de decisión y regresión logística arrojando un accuracy de 84%, 78% y 63% respectivamente [16]. Otro estudio centrado con un enfoque predictivo en la identificación de factores agrupa en etiquetas de edad, sexo, distancia de lugar de trabajo desde casa, enfermedad mental previa, historia familiar entre otros. Se demuestra una mayor precisión por parte de los algoritmos de aprendizaje automático, el algoritmo de árboles de decisión obtuvo un resultado de 82.2% de accuracy por encima del algoritmo de random forest (79.3%) y regresión logística (81.4%) [16].

Los factores que pueden afectar a la salud mental distinguen del área donde se realizan las evaluaciones por ello Mosquera [19] menciona que para el Área educativa los factores más relevantes son los psicosociales como "Demandas del trabajo", "Demandas sobre el trabajo", "Liderazgo y relaciones sociales en el trabajo" se utilizó los métodos de Árboles de Clasificación J48 y Naive Bayes para su comparación; cómo entrada se usaron los factores psicosociales mencionados, compararon que el clasificador J48 dio 91% de accuracy a diferencia del algoritmo Naive Bayes que tuvo 89% de accuracy [19]. Mientras que en el estudio de Wang en su investigación los factores que afectan a los trabajadores del área de salud más relevantes son la edad, sexo y antigüedad en el centro laboral para el estudio propuso el Algoritmo Murciélagos (Algoritmo Bat) utilizado en muchos campos por su simplicidad, rápida convergencia y pocos parámetros necesarios; este busca simular la ecolocalización de los murciélagos para el tratamiento de los datos [20].

Gabarain [21] realizó un estudio sobre la predicción de salud mental en trabajadores de TI creó dos modelos predictivos para predecir el riesgo de padecer una enfermedad mental. Los datos usados fueron respuesta a un cuestionario que se dividía en 4 secciones considerando factores como: Información demográfica, factores

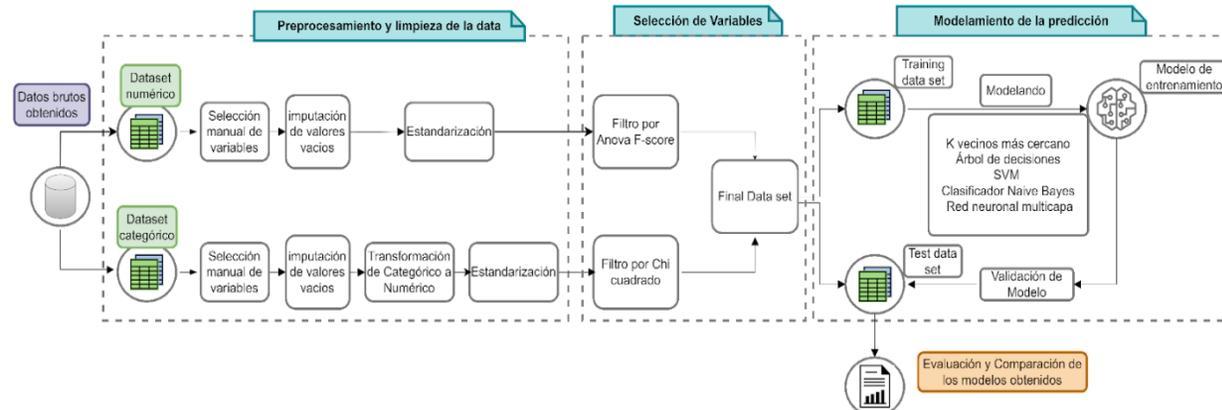


Fig. 1. Metodología propuesta para el modelamiento para predecir la probabilidad de padecimiento de problemas de salud mental en los trabajadores del sector de TI

biológicos, factores psicológicos y factores medioambientales; se utilizaron 2 algoritmos el clasificador Naive Bayes y, por otro lado, un árbol de decisión generado por el algoritmo C4.5. Gabarain obtuvo que el algoritmo de Árboles de Decisión tenía mayor accuracy a comparación que el clasificador Naive Bayes; el modelo creado con árboles de decision fue capaz de predecir el riesgo de salud mental con una accuracy de 83,3% mientras que Naive con una accuracy de 76,6%.

En el estudio de Lima Rojas [24] sobre la prevalencia y predicción de salud mental de trabajadores de TI el estudio se realizó con más de 1000 personas encuestadas; focalizándose en el área de Tecnologías de la Información, se utilizaron los algoritmos Árboles de decisión, Clasificador bayesiano (Naive Bayes) y Árboles de decisión J48. El algoritmo de árboles de decisión mostró un % de efectividad de 76.6%; mientras que Clasificador Bayesiano 73,4% y los Árboles de decisión solo 70,9%; con esto determinó que el factor más influyente fue el de “Antecedentes familiares”.

2.2. Análisis de la salud mental a través de algoritmos de aprendizaje automático

Se prevé que los problemas de salud mental tengan un crecimiento sustancial y con ello los costos globales de salud que para el 2030 serían más que la combinación de todos los relacionados con el cáncer, la diabetes y las enfermedades

respiratorias [16]. Para resolver el problema hay propuestas como [18] que usaron algoritmos de aprendizaje automático Decision Tree, SVM, además de algoritmos de regresión lineal aplicado a estudiantes que se quejaban del alto nivel de estrés que experimentaron en su vida universitaria, incluidos sentimientos de ansiedad y depresión, especialmente hacia al final del semestre. Los porcentajes de accuracy obtenidos de estos algoritmos fueron DT (70.83%), SVM (64%) y LR (66%).

Entre otras técnicas basadas en algoritmos de minería de datos, tenemos al algoritmo de optimización, que permitió obtener mejor rendimiento con un menor índice de error y precisión más alta. La precisión de este método tiene un valor medio de 90% [13]. Por otro lado, tenemos a las máquinas de vectores de apoyo entrenados en el conjunto de datos, que lograron una precisión del 77% [12].

Queda demostrado que el algoritmo de optimización nos genera una mayor precisión.

Otros algoritmos que hay que tener en cuenta para predecir la salud mental son el árbol de decisión y Naive Bayes que siguen una serie de pasos para su evaluación. Naive Bayes resultó eficaz con 86,53% [14]. Por otro lado, tenemos al aprendizaje automático para predecir el problema de salud mental, mediante la simulación y validación del modelo formulado, el algoritmo usado para este caso viene a ser el de Árboles de

Tabla 1. Diccionario del conjunto de datos de OSMI-2016 (1)

1	P1	Are you self-employed?
2	P2	How many employees does your company or organization have?
3	P3	Is your employer primarily a tech company/organization?
4	P4	Is your primary role within your company related to tech/IT?
5	P5	Does your employer provide mental health benefits as part of healthcare coverage?
6	P6	Do you know the options for mental health care available under your employer-provided coverage?
7	P7	Has your employer ever formally discussed mental health (for example, as part of a wellness campaign or other official communication)?
8	P8	Does your employer offer resources to learn more about mental health concerns and options for seeking help?
9	P9	Is your anonymity protected if you choose to take advantage of mental health or substance abuse treatment resources provided by your employer?
10	P10	If a mental health issue prompted you to request a medical leave from work, asking for that leave would be:
11	P11	Do you think that discussing a mental health disorder with your employer would have negative consequences?
12	P12	Do you think that discussing a physical health issue with your employer would have negative consequences?
13	P13	Would you feel comfortable discussing a mental health disorder with your coworkers?
14	P14	Would you feel comfortable discussing a mental health disorder with your direct supervisor(s)?
15	P15	Do you feel that your employer takes mental health as seriously as physical health?
16	P16	Have you heard of or observed negative consequences for co-workers who have been open about mental health issues in your workplace?
17	P17	Do you have medical coverage (private insurance or state-provided) which includes treatment of mental health issues?
15	P15	Do you feel that your employer takes mental health as seriously as physical health?
16	P16	Have you heard of or observed negative consequences for co-workers who have been open about mental health issues in your workplace?
17	P17	Do you have medical coverage (private insurance or state-provided) which includes treatment of mental health issues?
15	P15	Do you feel that your employer takes mental health as seriously as physical health?
16	P16	Have you heard of or observed negative consequences for co-workers who have been open about mental health issues in your workplace?
17	P17	Do you have medical coverage (private insurance or state-provided) which includes treatment of mental health issues?
15	P15	Do you feel that your employer takes mental health as seriously as physical health?
16	P16	Have you heard of or observed negative consequences for co-workers who have been open about mental health issues in your workplace?
17	P17	Do you have medical coverage (private insurance or state-provided) which includes treatment of mental health issues?
15	P15	Do you feel that your employer takes mental health as seriously as physical health?
16	P16	Have you heard of or observed negative consequences for co-workers who have been open about mental health issues in your workplace?
17	P17	Do you have medical coverage (private insurance or state-provided) which includes treatment of mental health issues?
33	P33	Would you have been willing to discuss a mental health issue with your previous co-workers?
34	P34	Would you have been willing to discuss a mental health issue with your direct supervisor(s)?
35	P35	Did you feel that your previous employers took mental health as seriously as physical health?

decisión con una precisión del 83,3% superando al algoritmo de Bayes [15].

Se prevé la construcción de modelos predictivos de salud mental utilizando integrado algoritmos de clasificación como Árbol de decisión, Bosque aleatorio y Naïve Bayes, a un sitio web para que pueda obtener resultados sobre

potenciales enfermedades mentales de estos resultados se encontró que el algoritmo óptimo es el Árbol de decisiones debido a su bajo tiempo de ejecución y alta precisión de 82,2% por encima de las demás [23]. Por otro lado, tenemos al aprendizaje automático para analizar y predecir la salud mental, el algoritmo usado en este caso es

Tabla 1. Diccionario del conjunto de datos de OSMI-2016 (2)

36	P36	Did you hear of or observe negative consequences for co-workers with mental health issues in your previous workplaces?
37	P37	Would you be willing to bring up a physical health issue with a potential employer in an interview?
38	P38	Why or why not?
39	P39	Would you bring up a mental health issue with a potential employer in an interview?
40	P40	Why or why not?_1
41	P41	Do you feel that being identified as a person with a mental health issue would hurt your career?
42	P42	Do you think that team members/co-workers would view you more negatively if they knew you suffered from a mental health issue?
43	P43	How willing would you be to share with friends and family that you have a mental illness?
44	P44	Have you observed or experienced an unsupportive or badly handled response to a mental health issue in your current or previous workplace?
45	P45	Have your observations of how another individual who discussed a mental health disorder made you less likely to reveal a mental health issue yourself in your current workplace?
46	P46	Do you have a family history of mental illness?
47	P47	Have you had a mental health disorder in the past?
48	P48	Have you been diagnosed with a mental health condition by a medical professional?
49	P49	If yes, what condition(s) have you been diagnosed with?
50	P50	If maybe, what condition(s) do you believe you have?
51	P51	Have you been diagnosed with a mental health condition by a medical professional?
52	P52	If so, what condition(s) were you diagnosed with?
53	P53	Have you ever sought treatment for a mental health issue from a mental health professional?
54	P54	If you have a mental health issue, do you feel that it interferes with your work when being treated effectively?
55	P55	If you have a mental health issue, do you feel that it interferes with your work when NOT being treated effectively?
56	P56	What is your age?
57	P57	What is your gender?
58	P58	What country do you live in?
59	P59	What US state or territory do you live in?
60	P60	What country do you work in?
61	P61	What US state or territory do you work in?
62	P62	Which of the following best describes your work position?
63	P63	Do you work remotely?

Tabla 2. Resumen global del conjunto de datos OSMI-2016

Nombre	Valor
Filas	1433
Columnas	63
Columnas numéricas	7
Columnas categóricas	56
Filas completas	1433
Filas con valores faltantes	9228
Asignación de memoria	1,05 MB

la máquina de vectores de soporte que cuenta con una precisión de entre el 70 y 96% [24]. Dependiendo de la cantidad de datos, cualquiera de los algoritmos sería el adecuado para usar.

3. Materiales y métodos

La metodología usada se puede visualizar en la Fig. 1. Las fases comprendidas en esta metodología son las siguientes: limpieza y

preprocesamiento de datos, selección de características y modelado predictivo. A continuación, se desarrollará cada una de las fases.

El dataset usado para este estudio, se obtuvo de la Encuesta de Salud Mental en el área de la Tecnología desarrollada por la corporación Open Sourcing Mental Health durante el año 2016 [26]. Dada la extensión del nombre de las columnas se realizó un renombramiento de cada una de ellas como se observa en la "Tabla 1".

Tabla 3. Selección manual de las variables

N°	Variable	¿Incluida en el análisis?	Motivo de la exclusión
1	P1	Sí	
2	P2	Sí	
3	P3	Sí	
4	P4	Sí	
5	P5	Sí	
6	P6	Sí	
7	P7	Sí	
8	P8	Sí	
9	P9	Sí	
10	P10	No	Se considera que no tiene carácter predictivo
11	P11	No	En una opinión
12	P12	No	Es una opinión
13	P13	No	Es un sentimiento
14	P14	No	Es un sentimiento
15	P15	No	Es un sentimiento
16	P16	No	Se considera que no tiene carácter predictivo
17	P17	Sí	
18	P18	Sí	
19	P19	No	Se considera que no tiene carácter predictivo
20	P20	No	Es una opinión
21	P21	No	Se considera que no tiene carácter predictivo
22	P22	No	Es una opinión
23	P23	No	Es una opinión
24	P24	No	Se considera que no tiene carácter predictivo
25	P25	Sí	
26	P26	Sí	
27	P27	Sí	
28	P28	Sí	
29	P29	Sí	
30	P30	Sí	
31	P31	No	Es una opinión
32	P32	No	Es una opinión
33	P33	No	Se considera que no tiene carácter predictivo
34	P34	No	Se considera que no tiene carácter predictivo
35	P35	No	Se considera que no tiene carácter predictivo
36	P36	No	Es una opinión
37	P37	No	Se considera que no tiene carácter predictivo
38	P38	No	Pregunta abierta
39	P39	No	Se considera que no tiene carácter predictivo
40	P40	No	Pregunta abierta
41	P41	No	Es un sentimiento
42	P42	No	Es una opinión
43	P43	No	Se considera que no tiene carácter predictivo
44	P44	No	Se considera que no tiene carácter predictivo
45	P45	No	Se considera que no tiene carácter predictivo
46	P46	Sí	
47	P47	Sí	
48	P48	Sí	
49	P49	No	Puede tener más de un valor
50	P50	No	Es una opinión
51	P51	Sí	
52	P52	No	Puede tomar más de un valor
53	P53	No	Se considera que no tiene carácter predictivo
54	P54	No	Es una opinión
55	P55	No	Es una opinión
56	P56	Sí	
57	P57	Sí	
58	P58	Sí	
59	P59	Sí	
60	P60	Sí	
61	P61	Sí	
62	P62	No	Puede tener más de un valor
63	P63	Sí	

3.1. Limpieza y preprocesamiento de datos

El dataset usado para este estudio presenta como dimensiones 1433 instancias y 63 atributos, de los cuales 56 campos son tipo categórico y 7 son campos tipo numérico como se observa en la “Tabla 2”. En esta encuesta se midieron las actitudes hacia la salud mental en el lugar de trabajo tecnológico y se examinó la frecuencia de los trastornos de salud mental entre los trabajadores tecnológicos.

De las 63 columnas, se realizó una primera selección de 28 atributos en base a los estudios realizados en [20] que tuvo como fin determinar las características que dan lugar a problemas de salud mental. El análisis realizado se puede observar en la “Tabla 3”, donde se detalla el motivo por el cual se realizó la exclusión.

También se tomó como criterio de exclusión aquellas columnas que tienen un solo valor para todas las filas, así como las que tenían mayor o igual cantidad de datos vacíos que la media de la cantidad de datos de los atributos vacíos, debido a que aplicar modelos de predicción con estas variables pueden causar errores o generar resultados inesperados. Tras realizar este preprocesamiento quedó un total de 28 variables entre numéricas y categóricas, cabe detallar que la encuesta presenta valores de N/A o vacíos que corresponden a aquellas respuestas donde el usuario no especifica su respuesta o lo deja sin responder, por lo que fue necesario imputar valores.

3.1.1. Imputación de valores vacíos y eliminación de valores atípicos

En esta fase se procedió a completar los valores vacíos con el valor más frecuente que presenta este atributo. De acuerdo con [27] este procedimiento se llena con el dato faltante de cada variable, por la moda cuando se trata de una variable categórica. Por ello, en este caso se realizó la imputación del valor más frecuente.

En base a las 28 variables que quedaron para hacer el preprocesamiento, se identificaron aquellas variables que presentan cantidad de datos nulos o vacíos mayor o igual a la media de la cantidad de datos nulos o vacíos. Como resultado de este proceso quedaron 15 variables.

Entre estas se encuentran 3 variables numéricas y 12 variables categóricas.

3.1.2. Transformación de valores de tipo categórico a numérico

En las variables categóricas se procedió a la transformación, las variables que presentaban 3 tipos de respuesta se transformó cada respuesta en un número entero del 0 al 2.

3.1.3 Estandarización

Posteriormente se aplica la estandarización z-score con el propósito de usar una escala común entre todas las variables del dataset y de esta manera poder modelar los datos correctamente.

3.2. Selección de características

Para pruebas univariadas, con técnicas estadísticas que apoyan la minería de datos seleccionar las mejores características del conjunto de datos, según [31] se deben elegir aquellas características que obtienen las puntuaciones más altas. Para las variables numéricas se puede utilizar Anova (F-test) y para variables categóricas se utiliza el filtro Chi-cuadrado [28].

3.2.1. Filtro Anova F-test

En ese trabajo se ha usado el filtro de Anova F-test, se aplicó a las 3 variables numéricas del conjunto de datos, con respecto a la variable objetivo P51, que indica si un trabajador de TI ha sido diagnosticado con un problema de salud mental o no. Asimismo, se estableció como parámetros de configuración `score_func = f_classif` y `k = 'all'` en la clase `SelectKBest`, permitiéndonos obtener las variables numéricas más y menos significativas que se observan en la Fig. 2.

De la Fig.2 se obtiene que las variables del tipo numérico más significativas son P25 y P56, ya que presentan un score más alto que las demás. Por lo tanto, se excluye P1 del conjunto de datos final.

3.2.2. Filtro Chi-cuadrado

Para utilizar este filtro, previamente realizamos la categorización de los datos, la variable objetivo se contrasta con las 11 variables categóricas, con los siguientes parámetros de configuración `score_func = chi2` y `k = 'all'`. Para cada una de las

comparaciones se utilizó la variable categórica objetivo P51. Una vez realizado el filtro, se obtuvieron las puntuaciones presentadas en la Fig. 3.

De la Fig. 3. se desprende que las variables del tipo categóricas menos significativas son P27, P63 y P28, por ser las variables con puntuaciones más bajas. En consecuencia, las variables P47, P46, P60, P58, P30, P26, P57 y P29 se usarán para el conjunto de datos final.

3.2.3. Conjunto de datos final

Después de realizar las pruebas Anova F-Test y Chi-cuadrado, el número de características se redujo a 10, entre las cuales se encuentran 8 variables del tipo categóricas y 2 variables numéricas.

En la "Tabla 4", se observa la descripción de las características seleccionadas como variables predictoras y la última P51 es la variable objetivo que permite clasificar si una persona tiene problemas de salud mental o no tiene.

En la Fig. 5 se detalla la estructura del conjunto de datos final. Donde la variable P51 (Have you been diagnosed with a mental health condition by a medical professional?) es la variable objetivo que indica si el personal de TI tiene un problema de salud mental, donde uno representa "Sí" y cero representa "No".

C. Modelado predictivo

C.1. Conjunto de datos de entrenamiento y validación

En la investigación se realizó la partición del conjunto de datos en 80% para el entrenamiento y 20% para la validación de los modelos, como en la investigación [21].

De esta partición se obtuvieron 1146 instancias de entrenamiento y 287 instancias de validación. Dada la partición de datos, se verifica la distribución de los datos correspondiente a la variable objetivo, esto se observa en la Fig 6 donde se ve que la distribución es balanceada.

C.2. Modelado

Para determinar el mejor modelo de predicción de salud mental en el sector TI, se ha analizado varios estudios. En [11] el algoritmo de KNN alcanzó un accuracy de 80,4%.

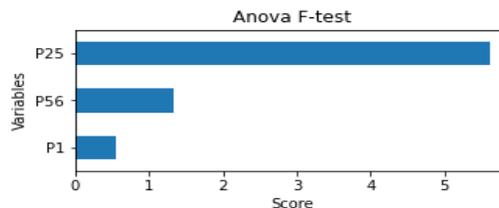


Fig. 2. Puntuaciones ANOVA en la predicción de la salud mental del trabajador de TI

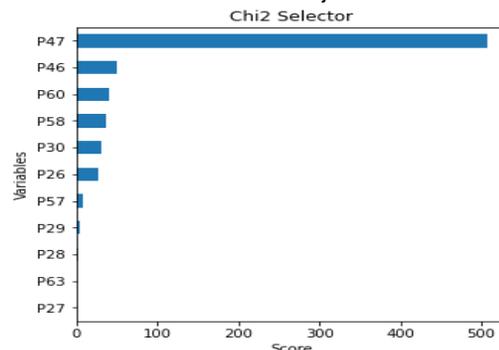


Fig. 3. Puntuaciones Chi-Cuadrado en la predicción de la salud mental del trabajador de TI

Tabla 4. Descripción de las características seleccionadas

ID	Denominación	Descripción
1	P25	Do you have previous employers?
2	P26	Have your previous employers provided mental health benefits?
3	P29	Did your previous employers provide resources to learn more about mental health issues and how to seek help?
4	P30	Was your anonymity protected if you chose to take advantage of mental health or substance abuse treatment resources with previous employers?
5	P46	Do you have a family history of mental illness?
6	P47	Have you had a mental health disorder in the past?
7	P56	What is your age?
8	P57	What is your gender?
9	P58	What country do you live in?
10	P60	What country do you work in?
11	P51	Have you been diagnosed with a mental health condition by a medical professional?

Mientras que Neural Network, un 81.4%; siendo estos dos los modelos con mejores resultados en la evaluación de la salud mental.

Además, en [10] el modelo basado en Decision Tree obtuvo una alta exactitud de 88,5% de precisión. Por otro lado, en [24] el modelo basado en Support Vector Machine dependiendo del tamaño de data obtuvo una exactitud del 96%. En el caso de la investigación [19], Mozquera utilizó el algoritmo Naive Bayes que tuvo una exactitud del 89%. Según lo observado en los diferentes estudios, queda evidenciado que sus medias en cuanto a exactitud se encuentran sobre el 70%.

También se tomó en cuenta el bajo tiempo de ejecución de estos algoritmos, dado que es un criterio de selección que también se toma en el artículo [23].

Por lo tanto, en esta investigación se ha tomado los algoritmos de K-Nearest Neighbor o KNN, Neural Network, Decision Tree, Support Vector Machine y Naive Bayes. Estos se eligieron en base al análisis documental realizado donde se tomó como criterio de selección la alta precisión de los modelos.

Para el entrenamiento de los modelos se consideraron los siguientes valores de hiperparámetros:

- K-Nearest Neighbor (KNN): {n_neighbors: 3}
- Decision Tree: {criterion: 'entropy', max_depth: 3}.
- Support Vector Machine (SVM): {kernel: 'linear'}
- Naive Bayes: Valores por defecto
- Neural Network: {hidden_layer_sizes:(3,2)}

C.3. Validación de modelos

La validación de los modelos se ha realizado en el conjunto de datos de prueba, al realizar la repartición entre el entrenamiento y la prueba.

C.4. Evaluación y comparación de modelos obtenidos

En esta etapa, es necesario determinar las métricas que serán usadas para comparar los algoritmos utilizados, los cuales son el accuracy (exactitud), la precisión, la sensibilidad, la especificidad, el F1-score, el área bajo la curva ROC (AUC), el mayor número de verdaderos positivos y el menor número de falsos negativos.

A continuación, se detallará cada métrica mencionada anteriormente:

	P26	P29	P30	P46	P47	P57	P58	P60	P25	P56	P51
0	1	0	0	1	2	1	47	47	1	39	1
1	3	1	3	2	2	1	48	48	1	29	1
2	1	1	0	1	1	1	47	47	1	38	0
3	2	0	0	1	2	1	47	47	1	43	1
4	0	0	0	2	2	0	48	48	1	43	1
...
1428	3	1	0	2	0	0	48	48	1	34	0
1429	2	0	0	2	0	1	48	0	0	56	1
1430	2	1	2	2	2	1	48	48	1	52	1
1431	1	0	0	2	1	0	48	48	1	30	1
1432	2	0	0	0	2	2	11	10	0	25	0

Fig. 5. Conjunto de datos final

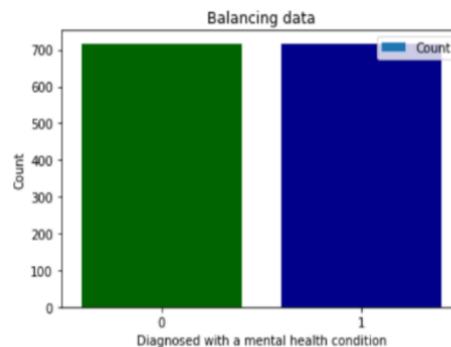


Fig. 6. Distribución de clases de la variable objetivo

Exactitud representa la proporción de correctas predicciones respecto a la salud mental en los trabajadores de TI.

F1-score es la media armónica de precisión y recuperación respecto a la predicción de la salud mental de un trabajador de TI.

Sensibilidad proporción entre positivos reales que el modelo de modo correcto predijo respecto a la salud mental de un trabajador de TI.

Especificidad proporción de negativos reales que el modelo predice de modo correcto la salud mental en los trabajadores de TI.

Verdaderos positivos probabilidad de que un trabajador de TI dé un resultado positivo y se obtenga un diagnóstico correcto.

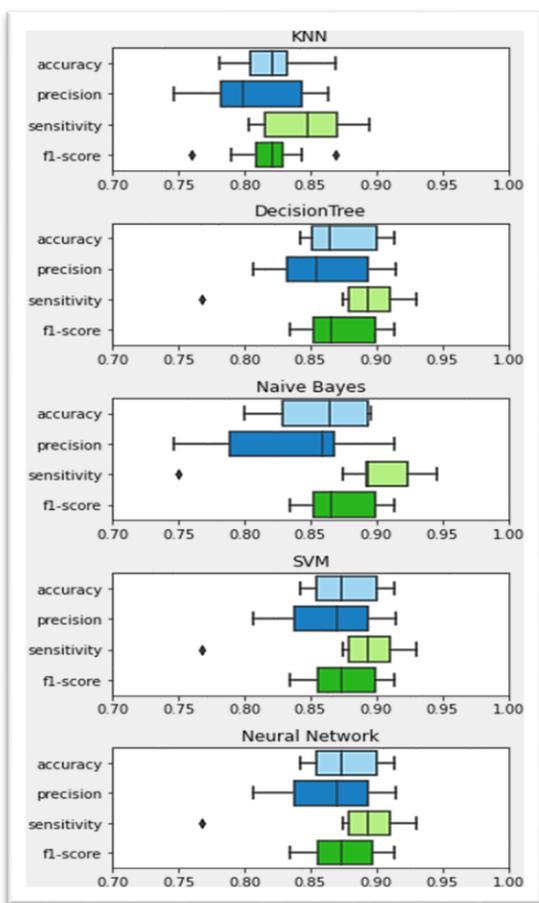


Fig. 7. Métricas en el conjunto de datos de entrenamiento

Tabla 5. Resumen de las métricas obtenidas en el conjunto de datos de entrenamiento

Model	Accuracy	Precision	Sensitivity	F1-Score	Model
KNN	0.81±0.01	0.80±0.01	0.83±0.01	0.81±0.01	KNN
DT	0.87±0.01	0.87±0.01	0.88±0.01	0.87±0.01	DT
NB	0.84±0.01	0.83±0.01	0.86±0.01	0.87±0.01	NB
SVM	0.87±0.01	0.87±0.01	0.88±0.01	0.87±0.01	SVM

Falsos negativos probabilidad de que un trabajador de TI dé un resultado negativo y se obtenga un diagnóstico incorrecto.

Área bajo la curva ROC (AUC) indica si es correcto el modelo para discriminar instancias de clase positiva y clase negativa. Según [29],

mientras más cercano a 1 tendrá mayor capacidad discriminadora respecto la salud mental de los trabajadores de TI.

4. Resultados y discusiones

En este estudio se evaluó el desempeño de cinco algoritmos de aprendizaje automático para la predicción de la salud mental de trabajadores de TI. Los algoritmos usados fueron: K-Nearest Neighbor (KNN), Decision Tree, Support Vector Machine (SVM), Naive Bayes y Neural Network.

Al aplicar la técnica K-Fold Cross-Validation con $k=10$ en el dataset de entrenamiento, se obtuvo como resultado la "Tabla 5". Donde se observa que los modelos Decision Tree y Support Vector Machine obtuvieron los mejores valores de accuracy con una media de 0.87 ± 0.01 , una precisión de 0.87 ± 0.01 , una sensibilidad de 0.88 ± 0.01 y un F1-Score de 0.87 ± 0.01 .

La Fig. 7, muestra el diagrama de cajas y bigotes de las métricas obtenidas en el conjunto de datos de entrenamiento.

Mediante el análisis de la mediana podemos afirmar que el algoritmo con peores valores de exactitud, precisión, sensibilidad y F1-score es K-Nearest Neighbor.

La Fig. 8 presenta la matriz de confusión de los modelos estudiados en el conjunto de datos de prueba, de donde se obtuvo que los modelos Decision Tree (b) y Support Vector Machine (d) poseen los valores más bajos de falsos negativos con 22 (Trabajadores de TI que tienen problemas de salud mental, pero no están clasificados como tales) y los modelos Naive Bayes (c) y Neural Network (e) tienen los valores más altos de verdaderos positivos con 123 (Trabajadores de TI que tienen problemas de salud mental que el modelo clasificación como tal).

Sin embargo, cabe resaltar que, el modelo Naive Bayes (c) tiene el mayor número de falsos negativos con 31; mientras que Neural Network (e) tiene solo 23, siendo superior que los modelos (b) y (d) con menor número de falsos negativos.

Al realizar la predicción del dataset de prueba, se obtuvo las métricas que se observan en la Fig.9; las cuales fueron usadas como criterio de selección del mejor modelo para predecir la salud mental de los trabajadores de TI.

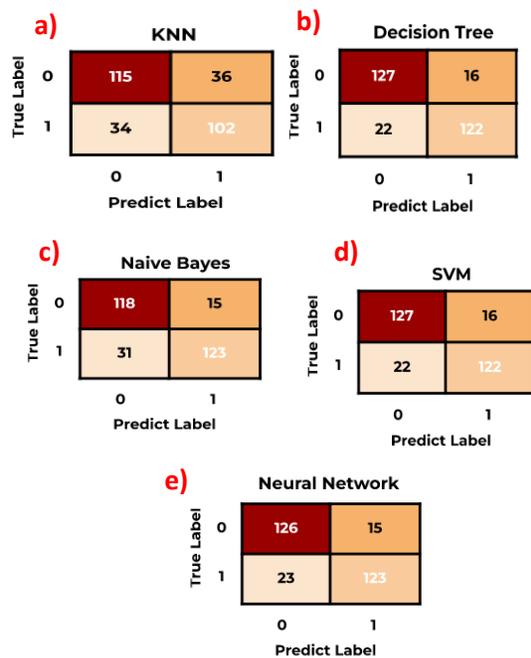


Fig. 8. Matriz de confusión de modelos estudiados

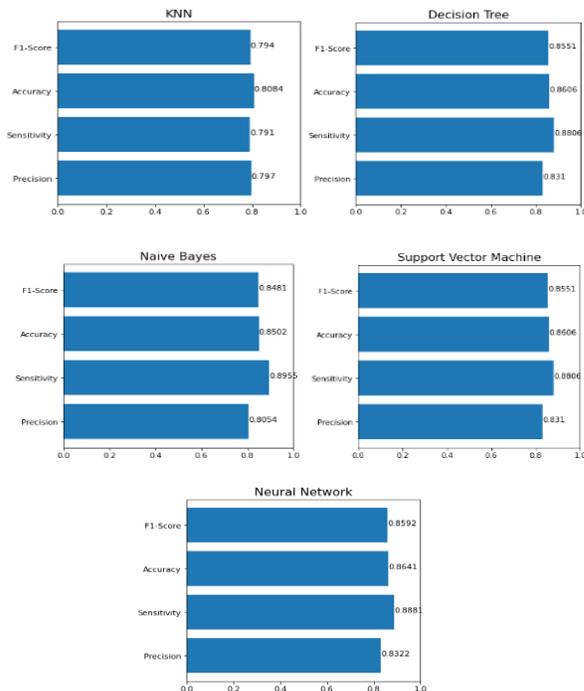


Fig. 9. Métricas obtenidas en el conjunto de datos de prueba

Analizando nuestros resultados el valor de exactitud más alto lo obtuvo el algoritmo Neural Network con 86.41%, se puede observar que los valores presentan mayor exactitud con con y data de entrenamiento. Inferior resultado se obtuvo en el estudio [11] donde este algoritmo obtiene una exactitud de 81.4%, el cual es el segundo valor más alto obtenido en comparación de los modelos aplicados en esa investigación. ya que el dataset de este estudio fue de 60 datos.

En relación con la métrica de sensibilidad, el porcentaje más alto lo obtuvo el algoritmo Naive Bayes con 89.55%. En el estudio [10] podemos observar que aplicando el mismo modelo se obtuvo 78.03%. Otro estudio [18] también muestra que el algoritmo Naive Bayes obtuvo un valor de sensibilidad del 41.94%. Comparando el valor de la sensibilidad de los estudios antes mencionado con el presente estudio, podemos observar que estos presentan un menor valor tanto en la métrica de sensibilidad como en base al número de instancias que presentan en sus conjuntos de datos.

En la Fig. 9, también se observa que el algoritmo Neural Network obtuvo los valores más altos de precisión del 83.22% indicando así que estos son buenos para predecir la clase, los trabajadores de TI diagnosticados con problemas de salud mental. Estos resultados son superiores al estudio reportado en [10, 11] donde el algoritmo Neural Network obtiene un valor de precisión de 75.5% y 77.14%, respectivamente.

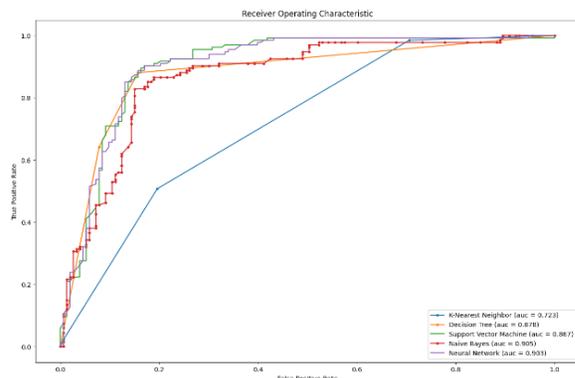
En la “Tabla 6” se presenta la comparación entre las métricas de accuracy y F1-Score, pero dado que presenta un conjunto de datos desequilibrado, el accuracy puede resultar un indicador engañoso; por ello, se usa como métrica de elección del mejor modelo, el F1-Score. De estos se obtuvo que el valor de F1-score más alto se obtuvo con el algoritmo Neural Network con un 85.92%.

En la Fig.10, tras predecir con el dataset de prueba se obtiene el área bajo la curva ROC, en el cual se observa que el modelo construido mediante Naive Bayes obtuvo el valor más alto con un AUC= 0.905, seguido de Neural Network con un valor de AUC=0,903.

De este modo se demuestra la capacidad discriminativa del modelo Neural Network para la clase sí ha sido diagnosticado con una condición

Tabla 6. Comparación de las métricas accuracy y F1-Score obtenidas en el conjunto de datos de prueba

Modelos	Accuracy (%)	F1-Score (%)
KNN	80.84	79.40
DT	86.06	85.51
NB	85.02	84.81
SVM	86.06	85.51
NN	86.41	85.92

**Fig. 10.** Área Bajo la curva ROC (AUC)

de salud mental por un profesional médico o no, esto según [30]. Resultados inferiores se obtuvieron en el estudio de [11] donde el algoritmo Neural Network alcanzó un valor de AUC= 87.6%. Dado que los valores de AUC en los algoritmos con mejores resultados tiende a ser muy cercanos, se optó por la métrica F1-Score para decidir el mejor algoritmo para predecir la salud mental en trabajadores de TI; obteniendo así, como mejor modelo el algoritmo Neural Network.

5. Conclusiones

En el estudio realizado se analizó e identificó los predictores más relevantes para la salud mental en los trabajadores del área de TI utilizando datos de OSMH/OSMI Mental Health in Tech Survey - 2016 elaborado por Open Source Mental Illness [26].

Debido a que el conjunto de datos poseía variables numéricas y categóricas fue necesario realizar un tratamiento diferente a cada tipo, por ello se realizó la selección de características empleando el filtro ANOVA F-test para las variables numéricas y el filtro Chi-Cuadrado para

las variables categóricas. Luego de realizarse la evaluación y comparación de los modelos construidos por los algoritmos de K-Nearest Neighbor (KNN), Decision Tree, Support Vector Machine (SVM), Naive Bayes y Neural Network, el algoritmo con mejores resultados obtenido en base al conjunto de datos analizados fue Neural Network con un valor de F1-Score del 85.92%, un área bajo la curva ROC de 0.903, un menor valor de falsos negativos con 23 y el segundo mayor valor de verdaderos positivos con 119 en la matriz de confusión. Dado que la distribución de clases del conjunto de datos analizado se encuentra desequilibrada, no se consideró el accuracy como métrica determinante para la selección del mejor algoritmo, sino, se consideró F1-score.

Por último, se espera que los resultados del presente estudio puedan servir como base para la elaboración de modelos predictivos de clasificación de la salud mental de los trabajadores en el área de TI que resulten óptimos, utilizando algoritmos más sofisticados como las redes neuronales artificiales o el aumento de gradiente.

Referencias

- Organización Mundial de la salud (2013).** Plan de acción sobre salud mental 2013-2020. Freshdesign, N.º E43, pp. 10.
- Joyce, S., Modini, M., Christensen, H., Mykletun, A., Bryant, R., Mitchell, P. B., Harvey, S. B. (2016).** Workplace Interventions for Common Mental Disorders: A Systematic Meta-Review. *Psychological medicine*, No. 46. Doi: 10.1017/S0033291715002408.
- Bloom, D.E., Cafiero, E.T., Jané-Llopis, E., Abrahams-Gessel, A. (2011).** Predictive modeling in e-mental health: A common language framework. *World Economic Forum*. https://www3.weforum.org/docs/WEF_Harvard_HE_GlobalEconomicBurdenNonCommunicableDiseases_2011.pdf.
- Padma, V., Anand, N.N., Swaminatha Gurukul, S.M.G., et al. (2025).** Health problems and stress in Information Technology and Business Process

- Outsourcing employees. *Journal of Pharmacy and Bioallied Sciences*. Doi: 10.4103/0975-7406.155764.
5. **Anitha, S., Vanitha, M. (2021)**. Optimal artificial neural network-based data mining technique for stress prediction in working employees. *Soft Comput*, Vol. 25. Doi: 10.1007/s00500-021-06058-9.
 6. **Leka, S., Jain, A. (2017)**. Mental Health in the Workplace in Europe. https://ec.europa.eu/health/sites/default/files/mentalhealth/docs/compass_2017workplace_en.pdf.
 7. **Mosquera, R., Parra, L., Castrillon, O. (2016)**. Metodología para la Predicción del Grado de Riesgo Psicosocial en Docentes de Colegios Colombianos utilizando Técnicas de Minería de Datos. *Información Tecnológica*, Vol. 27, No. 6, pp. 259–272. Doi: 10.4067/S0718-07642016000600026.
 8. **Arrúe, M. (2019)**. Sistema de estratificación y predicción de salud mental en trabajadores tecnológicos. M.S. thesis, Universidad Oberta de Catalunya, España.
 9. **Lima, B. (2019)**. Estudio de prevalencia y predictores de problemas de salud mental entre trabajadores tecnológicos. M.S. thesis, Universidad Oberta de Catalunya, España.
 10. **Yousefi, M. (2021)**. A Model for the Mental Health Evaluation of Skilled Workers in Technology-Based Companies. *Australian Journal of management*. Doi: 10.21203/rs.3.rs-30514/v1.
 11. **Sandhya, P. (2019)**. Prediction of Mental Disorder for employees in IT Industry. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, Vol. 8, Issue 6S.
 12. **Diederich, J., Al-Ajmi, A., Yellowlees, P. (2006)**. Data mining and mental health. Department of Computer Science, American University of Sharjah, United Arab Emirates.
 13. **Luo, M. (2021)**. Research on Students' Mental Health Based on Data Mining Algorithms. *Hindawi Journal of Healthcare Engineering*, Vol. 2021.
 14. **Kanasko, N., Surahio, F., Abbasi, H., Marre, M. (2019)**. Smart Mental Stress Predictive System for Healthcare Using Data Mining Techniques. Department of Computer Science, Sindh University Campus Larkana, Pakistan.
 15. **Dooshima, M., Ngozi, E., Balogum, A., Olusanya, S., Idowo, A. (2018)**. A Predictive Model for the Risk of Mental Illness in Nigeria Using Data Mining. Department of Computer Science and Engineering, Obafemi Awolowo University, Ile-Ife.
 16. **Becker, D., van Breda, W., Funk, B., Hoogendoorn, M., Ruwaard, J., Riper, H. (2018)**. Predictive modeling in e-mental health: A common language framework. *Internet Interventions*, Vol. 12, pp. 57–67. Doi: 10.1016/j.invent.2018.03.002.
 17. **Laijawala, V., Aachaliya, A., Jatta, H., Pinjarkar, V. (2020)**. Mental Health Prediction using Data Mining: A Systematic Review. *SSRN Journal*. Doi: 10.2139/ssrn.3561661.
 18. **Mutalib, S. (2021)**. Mental Health Prediction Models Using Machine Learning in Higher Education Institution. *TURCOMAT*, Vol. 12, No. 5, pp. 1782–1792. Doi: 10.17762/turcomat.v12i5.2181.
 19. **Mosquera, R., Parra-Osorio, L., Castrillón, O. D. (2016)**. Metodología para la Predicción del Grado de Riesgo Psicosocial en Docentes de Colegios Colombianos utilizando Técnicas de Minería de Datos, *Información Tecnológica*, Vol. 27, No. 6.
 20. **Xiaofeng-Wang, H., Chuanyong, S., Tan Wang, Chenyu Dong, Dongyang, G. (2020)**. Prediction of Mental Health in Medical Workers During COVID-19 Based on Machine Learning. *Frontiers in Public Health*. <https://www.frontiersin.org/>.
 21. **Arrúe-Gabarain, M. (2019)**. Sistema de estratificación y predicción de salud mental en trabajadores tecnológicos. Universidad Abierta de Cataluña.
 22. **Laijawala, V., Jatta, H., Pinjarkar, V., Aachaliya, A. (2020)**. Classification Algorithms based Mental Health Prediction using Data Mining. In: *Proceedings of the Fifth International Conference on Communication and Electronics Systems (ICCES 2020)*.

23. **Safika, N., Mutalib, S. (2020).** Prediction of Mental Health Problems among Higher Education Student Using Machine Learning. *I. J. Education and Management Engineering*, Vol. 6, pp. 1–9. DOI: 10.5815/ijeme.2020.06.01.
24. **Lima-Rojas, B. (2019).** Estudio de prevalencia y predictores de problemas de salud mental entre trabajadores tecnológicos. Universidad Abierta de Cataluña.
25. **Krešimir Ćosić, Siniša Popović, Marko Šarlija, Ivan Kesedžić, Tanja Jovanovic (2020).** Artificial intelligence in prediction of mental health disorders induced by the COVID-19 pandemic among health care workers. *Laboratory for Interactive Simulation Systems, Faculty of Electrical Engineering and Computing, University of Zagreb*. Doi: 10.33 25/ cmj.2020.61.279.
26. **OSMI (2016).** Open Sourcing Mental Health. <https://osmhhhelp.org/research>.
27. **Useche, L., Mesa, D. (2006).** Una introducción a la imputación de valores perdidos. *Terra*, Vol. XXII, No. 31, pp. 127–152. <https://www.redalyc.org/pdf/721/72103106.pdf>.
28. **Brownlee, J., Sanderson, M., Koshy, A., Cheremskoy, A., Halfyard, J. (2020).** *Machine Learning Mastery With Python: Data Cleaning, Feature Selection, and Data Transforms in Python*.
29. **Cerda, J., Cifuentes, L. (2012).** Uso de curvas ROC en investigación clínica: Aspectos teórico-prácticos. *Revista chilena de infectología*, Vol. 29, No. 2, pp. 138–141. Doi: 10.4067/S0716-10182012000200003.
30. **Gironés, J., Casas, J., Minguillón, J. R. (2017).** *Caihuelas. Minería de datos: modelos y algoritmos*, UOC, Ed., Barcelona.
31. **Holgado-Apaza, L.A., Carpio-Vargas, E.E., Calderon-Vilca, H.D., Maquera-Ramirez, J., Ulloa-Gallardo, N.J., Acosta-Navarrete, M.S., Barrón-Adame, J.M., Quispe-Layme, M., Hidalgo-Pozzi, R., Valles-Coral, M. (2023).** Modeling Job Satisfaction of Peruvian Basic Education Teachers Using Machine Learning Techniques, *Applied Sciences*, Vol. 13, No. 6, pp. 3945. Doi: 10.3390/app13063945.

Article received on 19/02/2023; accepted on 12/01/2025.

**Corresponding author is Kori Antunez.*