

Capacidad predictiva de un cuestionario clínico para identificar la propensión a enfermedades profesionales de salud mental

Enrique Escobar^{1,a,*}, Juan Pablo Osorio^{2,b}, Natalia Martini^{2,c}.

Predictive Capacity of a Clinical Questionnaire to Identify the Propensity for Occupational Mental Health Disorders

RESUMEN

El proceso de calificación de enfermedad profesionales de salud mental en Chile es regulado por la ley N° 16.744. Pese a esto, es constantemente exigido en aspectos como precisión y objetividad.

Objetivo: Evaluar la viabilidad de algoritmos de aprendizaje automático para apoyar la calificación de salud mental. **Métodos:** Aplicación de cuestionario de propensión a enfermedades de salud mental, a una muestra de 340 trabajadores chilenos. Evaluación de modelos de árboles de decisión y regresión logística, considerando también versiones mejoradas con variables extras ("Plus") asociadas a la intensidad y temporalidad de estresores. **Resultados:** Se identifica mejor precisión en el "Árbol Plus" (91,2%, IC 95%: 83,9% - 95,9%), especialmente con datos equilibrados (76,9%). No obstante, existe un margen para mejorar la especificidad del modelo, debido al desequilibrio de datos provocado por personas con presencia o no de enfermedad mental. **Conclusiones:** Se demuestra que la inclusión de algoritmos al proceso de calificación mejora la eficiencia y objetividad del proceso. No obstante, requiere una expansión de la base de datos y el refinamiento de los modelos para una mejor precisión. **Palabras clave:** Aprendizaje Automático; Árboles de Decisión; Enfermedades Profesionales; Salud Laboral; Salud Mental.

ABSTRACT

The process of qualifying work-related mental health disorders in Chile is regulated by Law No. 16.744. However, it is frequently challenged

¹Universidad Complutense de Madrid. Madrid, España.

²Universidad de Chile. Santiago, Chile.

^aPsicólogo, Mg. en Ciencias del Comportamiento.

^bMédico Psiquiatra, Mg. en Ciencias Biomédicas y Biológicas.

^cPsicóloga, Mg. Psicología Clínica Adultos, Mención Cognitivo Constructivista.

* Correspondencia: Enrique Escobar G. / enriesco@ucm.es

Normandia 1941, Providencia, Chile.

Financiamiento: El trabajo no recibió financiamiento.

Declaración de conflicto de intereses: Los autores declaran no tener conflicto de intereses.

Recibido: 14 de noviembre de 2024.

Aceptado: 15 de marzo de 2025.

in terms of precision and objectivity. **Aim:** To assess the feasibility of machine learning algorithms in supporting mental health qualification.

Methods: Application of a mental health disease propensity questionnaire to a sample of 340 Chilean workers. Evaluation of decision tree models and logistic regression, including enhanced versions with additional variables ("Plus") related to the intensity and temporality of stressors. **Results:** The "Plus Tree" model showed higher accuracy (91.2%, 95% CI: 83.9%-95.9%), particularly with balanced data (76.9%). However, there is room for improving the model's specificity due to data imbalance caused by the presence or absence of mental health condition. **Conclusions:** The inclusion of algorithms in the qualification process enhances efficiency and objectivity. However, further database expansion and model refinement are necessary to achieve better precision.

Keywords: Decision Trees; Machine Learning; Mental Health; Occupational Diseases; Occupational Health.

La Superintendencia de Seguridad Social (SUSESO) en Chile es una entidad autónoma que fiscaliza la aplicación de normativas relacionadas con la seguridad social, y de forma especial se focaliza en la protección de los trabajadores ante accidentes y enfermedades laborales. A partir de la constante búsqueda de mejoras, SUSESO ha impulsado iniciativas de investigación y financiamiento desde 2005, aumentando el apoyo a proyectos de investigación desde 2015 hasta llegar a los proyectos especiales el 2017. En este contexto en el año 2020, se promovió el desarrollo de un proyecto para objetivar el proceso de calificación de enfermedades profesionales de salud mental; a partir de este proyecto se generó un cuestionario para facilitar la calificación²³, lo cual culminó con resultados prometedores.

Para llegar hasta el punto de desarrollo actual, es importante destacar que Chile en 1968 crea la Ley N° 16.744²¹, alineándose de esta manera con lo indicado por la Organización Internacional

del Trabajo (OIT). Esta ley define la enfermedad profesional, de la siguiente manera:

"Es enfermedad profesional la causada de una manera directa por el ejercicio de la profesión o el trabajo que realice una persona y que le produzca incapacidad o muerte" (Art. N° 7).

Posteriormente la definición de salud mental se vuelve más específica a través del Decreto Supremo N° 109²², la cual establece normas para calificar y evaluar los accidentes como las enfermedades profesionales en el país. De esta manera, se genera un sistema de listas de enfermedades, específicamente en el área de salud mental, indicando que todos los trabajos que pongan en riesgo de tensión psíquica, comprobando la causalidad, pueden provocar la siguiente enfermedad:

"Neurosis profesionales incapacitantes que pueden adquirir distintas formas de presentación clínica, tales como: trastorno de adaptación, depresión reactiva, trastorno por somatización y por dolor crónico" (Extracto Art. 19).

Si bien el concepto de “neurosis laboral”, no es considerado en los sistemas de clasificación utilizados a nivel global como Clasificación Internacional de Enfermedades, 10ª Edición (CIE-10) o Manual Diagnóstico y Estadísticos de los Trastornos Mentales. 5ª Edición (DSM-5)⁴, durante un largo tiempo se mantuvo esta forma de distinguir las enfermedades de salud mental. Es recién en el año 2016, que se introduce un cambio sobre la forma de calificar las enfermedades por SUSESO, el cual genera una estandarización a través de un Compendio de Normas del Seguro Social de Accidentes del Trabajo y Enfermedades Profesionales¹².

Dentro de este compendio se dedica un libro específico para esta materia; “Libro III Denuncia, Calificación y Evaluación de Incapacidades Permanentes”¹², donde se indica que la calificación de enfermedad será realizada por un comité de calificación compuesto por tres o más profesionales, dos de ellos médicos, el primero médico del trabajo y el segundo, psiquiatra, en este aspecto también distingue que “para calificar el origen, común o laboral, de una patología mental, el Comité deberá contar con todos los elementos de la evaluación clínica (médica y psicológica), las evaluaciones de condiciones de trabajo (información de empresa y el EPT-PM) y los antecedentes de la vigilancia de factores de riesgo psicosocial en el trabajo, según el protocolo del Ministerio de Salud, cuando corresponda.” Actualmente dicha forma se adopta en la mayoría de los procedimientos de calificación en latinoamericana, presentando además una marcada adhesión a las definiciones de la OIT, por lo que las maneras de calificación no presentan mayor diferencia entre países de la región, en los cuales se consideran tanto la revisión del historial del paciente como también otros antecedentes complementarios^{32,36}.

Según lo que puede observar en el estado del arte, existen problemas desde la base epistemológica de la salud mental en el trabajo²⁴, lo cual difumina la existencia de causales sociales y económicos en los países latinoamericanos¹⁹. Asimismo, se han expuesto críticas directas a la calificación de enfermedades profesionales de salud mental en Chile, entre ellas están: el cuestionamiento a los

requisitos, alcances, procedimientos y factores de riesgos para calificar una patología de salud mental³⁷, la comprensión etiológica centrada en la mono-causalidad, la falta de claridad del significado de “tensión psíquica”, el concepto de “neurosis profesional/laboral”⁶, la falta de instructivos adecuados para el proceso de calificación, así como también la falta de claridad de criterios para la determinación y multicausalidad de la enfermedad⁶. Esto amplificaría la disparidad en la aplicación de los criterios, dificultando así una determinación precisa y confiable, lo cual no solo impacta en la equidad y justicia en el proceso de calificación de estas patologías, sino que también limita el reconocimiento efectivo de la causa.

De acuerdo con lo señalado, la calificación debe cumplir con los criterios normativos alineados con los estándares de SUSESO¹², aplicando protocolos y dictámenes conforme al artículo N° 7 de la ley N° 16.744²¹. Sin embargo, la inclusión del criterio clínico de expertos puede afectar la objetividad y estandarización del proceso. Para reducir esta brecha y garantizar el cumplimiento normativo, es crucial evaluar el uso de herramientas tecnológicas, como el aprendizaje automático, para optimizar y estandarizar la calificación.

En una línea de trabajo afín, la revisión bibliométrica entre el 2012 al 2023 por parte de Sharma & Chariar (2024)²⁸, sobre el diagnóstico de enfermedades mentales mediante el uso de aprendizaje automático, identifica que los algoritmos más utilizados son: Máquina de Vectores de Soporte (Support Vector Machine, SVM), Clasificador de Árbol de Decisión (Decision Tree) y Clasificador de Bosque Aleatorio (Random Forest). Asimismo, en dicho estudio se destaca que el aprendizaje profundo, estaría estrechamente vinculado al análisis de técnicas de neuroimagen, como la resonancia magnética, la resonancia magnética funcional y la electroencefalografía, particularmente en el contexto del trastorno bipolar, en donde los indicadores de precisión oscilaban entre el 66% y el 100%.

De igual manera a nivel mundial, el uso de tecnologías para el diagnóstico de enfermedades mentales está en constante desarrollo. En los Países Bajos, van Eeden, et al. (2021)³³, lograron una

precisión del 79% al aplicar regresión logística multinomial; Naive Bayes y Auto-sklearn en un estudio longitudinal sobre ansiedad y depresión. En Nigeria, algoritmos como Naive Bayes y Árboles de Decisión alcanzaron precisiones del 76,7% y 83,3%, respectivamente¹³. En China, el estudio de redes neuronales realizado por Chang (2023)¹⁰ detectaron riesgos de salud mental en empleados con una precisión del 85%. Richens, Lee & Johri, (2020)²⁷ reportaron desde el Reino Unido que algoritmos asociativos y contrafactuales superaron a médicos en un 48% y 25%, respectivamente, al diagnosticar a partir de viñetas clínicas. Desde Pakistán, Aleem, et al. (2022)³ destacaron el uso de SVM, Naive Bayes y Random Forest, logrando precisiones superiores al 86% en detección de depresión. Iyortsuun, et al. (2023)¹⁶ en Corea del Sur, revisaron algoritmos como Random Forest y redes neuronales profundas, reportando eficacias superiores al 90% en diagnósticos de ansiedad, depresión, esquizofrenia y TDAH. Por otra parte, Shatte, et al. (2019)²⁹, analizaron 300 estudios desde Australia, identificando aplicaciones exitosas de SVM, árboles de decisión y redes neuronales en condiciones como depresión, esquizofrenia y Alzheimer.

En Chile, el uso de algoritmos en el ámbito de la salud también ha mostrado un desarrollo sostenido, tal como lo evidencia el Informe Anual 2024 del Repositorio de Algoritmos Públicos de la Universidad Adolfo Ibáñez, el cual indica la existencia de 101 algoritmos en el sector de la salud, aplicados a procesos clave como diagnóstico, tratamiento y gestión de pacientes⁸, no obstante, ninguno de estos se está utilizando para el proceso de calificación.

Esta investigación tiene como objetivo evaluar la aplicación de algoritmos de aprendizaje automático en un entorno normativo, con un enfoque en la identificación de las causas de enfermedades dentro del marco regulador de SUSESO. Por ello, la selección de los algoritmos debe garantizar un equilibrio entre precisión e interpretabilidad, facilitando su implementación en la toma de decisiones.

En este sentido, los árboles de decisión y la

regresión logística se presentan como algoritmos adecuados, debido a su capacidad para generar modelos comprensibles y basados en reglas explícitas. Abdulqader & Abdulazeez (2024)¹ destacan que los árboles permiten simplificar procesos complejos mediante reglas claras y efectivas aplicadas a datos clínicos diversos. Asimismo, Christodoulou, et al. (2019)¹¹ concluyen que, aunque la regresión logística es un método más sencillo en comparación con otros enfoques de aprendizaje automático, mantiene una alta interpretabilidad y ofrece un rendimiento competitivo en problemas de clasificación binaria.

Dichas características posicionan a ambos algoritmos como herramientas óptimas en entornos que requieren precisión diagnóstica e identificación causal. Se espera que su implementación logre una precisión superior al 85%, lo que podría generar impactos significativos en la optimización y objetividad del procedimiento.

Métodos

Para efectos de la presente investigación aplica un diseño cuantitativo, observacional, transeccional y no experimental, ya que no manipula variables ni incluye grupos control, y analiza las variables en un único momento para identificar asociaciones sin alterar el entorno ni las condiciones de los sujetos¹⁴.

La muestra se compone por 340 personas, de las cuales 249 personas están insertos al servicio público-privado de salud y 91 personas asociadas al Organismo Administrador de la Ley (OAL). En términos de distribución de género, 135 son hombres (39,7%) y 205 mujeres (60,3%). Su rango etario está entre 20 a 60 años, con una edad promedio en hombres de 41, mientras que para mujeres es 37. Respecto a los participantes del sistema público-privado, están sujetos al proceso de peritaje de licencia médica, mientras que aquellos los vinculados al OAL son evaluados por enfermedad profesional. Cabe destacar que, ambos grupos participaron voluntariamente en el estudio.

En términos del proceso de entrenamiento de datos, es relevante enfatizar que para el entrenamiento de los modelos aprendizaje automático

será de un 70% y un 30% para fase prueba, mediante una división al azar.

El instrumento diseñado para evaluar la propensión a desarrollar una enfermedad laboral de salud mental integró diversos criterios de evaluación en un cuestionario con preguntas dicotómicas, de selección múltiple, escala Likert, texto libre y abiertas. De forma inicial, el cuestionario contenía un conjunto más amplio de ítems, sin embargo, para este estudio, se aplicó un proceso de adaptación y reducción, eliminando aquellos que no eran pertinentes para todos los participantes. Como resultado, se definieron dos escalas principales: una basada en la teoría de Bradford-Hill, compuesta por 9 ítems, y otra fundamentada en el criterio de Rothman, con 10 ítems. La aplicación de los cuestionarios se llevó a cabo entre marzo y junio de 2021 mediante entrevistas dirigidas por videoconferencia, conducidas por expertos en salud mental.

El proceso de medición y evaluación de los algoritmos se llevó a cabo en dos fases. En la primera, se usaron los 19 ítems seleccionados, y los modelos entrenados con este conjunto de variables conservaron la denominación original del algoritmo.

En la segunda etapa, el conjunto de ítems fue ampliado mediante la incorporación de cinco ítems discretos adicionales, diseñados para capturar información sobre la intensidad y temporalidad generales (Tabla 1: Preguntas discretas para algoritmos plus). Adicionalmente, se incluyeron las variables de sexo y edad, conformando un total de 26 ítems. Los modelos entrenados con esta versión expandida fueron denominados "algoritmo plus".

Con la finalidad de entrenar los algoritmos de manera efectiva, se realizó este proceso de análisis en RStudio, y se emplearán los siguientes paquetes de R: readxl, DataExplorer, ggplot2, tidyverse, ggstatsplot, corrplot, psych, GPArotation, pROC, caret, rpart y MASS. Al obtener un primer resultado, se buscará optimizar los modelos a través de los diferentes métodos, como son: el cumplimiento de supuestos, ajustes de parámetros y eliminación de outliers. Una vez alcanzado el punto máximo de eficiencia

realizando estos ajustes, se ocupará el paquete "Caret" para conseguir una serie de métricas comparables entre los distintos algoritmos.

Resultados

De acuerdo con los resultados obtenidos (Tabla 2. Resultados Predictivo), se puede indicar que el modelo Árbol Plus presentó la mayor precisión (Precisión= .912; Intervalo de Confianza (IC) 95%: .839 - .959), superando al Árbol de decisión (.853; IC 95%: .769 - .915) y modelos de regresión. Respecto a la Regresión Plus, los datos muestran una precisión moderadamente alta (.833 con un IC 95%: .747 - .900), mientras que el modelo de Regresión logística mostró la menor precisión (.803; IC 95%: .714 - .876). Cuando los modelos fueron comparados con datos equilibrados, que consideran tanto la sensibilidad como la especificidad, el modelo Árbol Plus nuevamente volvió a destacar (.769), en comparación con el Árbol de decisión (.677) y los modelos de regresión, que presentaron valores más bajos, Regresión (.654) y Regresión Plus (.581). Mientras los valores predictivos positivo, se asocian a las personas que no padecen una enfermedad, sus resultados fueron significativos en todos los modelos aplicados, destacando el Árbol Plus alcanzando el máximo (.934); los valores predictivos negativos, quienes eran las personas que, si presentan una enfermedad a juicio de experto, sus resultados fueron menos significativos en el rendimiento de los modelos, no obstante, destaca en esta categoría el Árbol Plus (.727). Por otra parte, es posible establecer que el modelo "Árbol Plus" tiene un rendimiento superior en términos de precisión, sensibilidad, pudiendo ser capaz de afrontar de mejor manera el balanceo de datos. Sin embargo, la especificidad es relativamente baja, por lo cual sería necesario hacer una validación adicional y una posible optimización de los modelos para ajustar su aplicabilidad en distintos escenarios. Las visualizaciones de los árboles pueden identificarse en la figura 1. Árbol de Decisión y Árbol de Decisión Plus, mientras que las preguntas asociadas a este último árbol están en la tabla 3 Preguntas Árbol Plus.

Tabla 1. Preguntas discretas para algoritmos plus.

"p"	Detalle	Resp.
13	Inicio síntomas meses	1-&
14	Días de reposo	0-&
24	¿Cuánto tiempo ha estado sometido el paciente al estresor laboral referido? Indique su respuesta en número de meses.	1-&
28	¿Cuántos meses ha estado expuesto el paciente al estresor laboral, previo a la aparición de síntomas?	1-&
30	¿Cuántos meses cesó la exposición al estresor laboral? Indique su respuesta en número de meses, si es menor a un mes señale 1	1-&

**p = N° de pregunta asociada, Resp. = Tipo de respuesta.

Tabla 2. Resultados Predictivo.

Medidas	Árbol	Árbol Plus	Regresión	Regresión Plus
Accuracy	0,853	0,912	0,803	0,833
95% CI	(0,769-0,915)	(0,839-0,959)	(0,714-0,876)	(0,747-0,900)
No Information Rate	0,853	0,863	0,853	0,853
P-Value [Acc > NIR]	0,355	0,093	0,933	0,763
Kappa	0,400	0,591	0,173	0,317
McNemar's T. P-Value	0,308	0,505	0,823	1,000
Sensitivity	0,941	0,965	0,896	0,908
Specificity	0,419	0,571	0,267	0,400
Pos Pred Value	0,889	0,934	0,876	0,897
Neg Pred Value	0,583	0,727	0,307	0,429
Prevalence	0,833	0,863	0,853	0,853
Detection Rate	0,784	0,833	0,765	0,775
Detection Prevalence	0,882	0,892	0,873	0,863
Balanced Accuracy	0,677	0,769	0,581	0,654

**Precisión= Accuracy, Intervalo de confianza al 95%= 95% CI, Tasa de información nula No Information Rate, Valor P [Acc > NIR], Kappa, Valor P de la prueba de McNemar= McNemar's Test P-Value, Sensibilidad= Sensitivity, Especificidad= Specificity, Valor predictivo positivo=Pos Pred Value, Valor predictivo negativo= Neg Pred Value, Prevalencia= Prevalence, Tasa de detección= Detection Rate, Prevalencia de detección= Detection Prevalence y Precisión equilibrada= Balanced Accuracy.




Figura 1: Árbol de Decisión (Derecha) y Árbol de Decisión Plus (Izquierda). **Ejemplo de interpretación : si la pregunta 39 < 4, el paciente denota un 96% de probabilidad de no tener la enfermedad (0), y un 4% de si tenerla (1). Dicha pregunta abarca el 70% de los casos en la fase de prueba.

Tabla 3. Preguntas Árbol Plus.

"p"	Detalle	Resp.
39	¿El nivel de exposición al estresor laboral esta correlacionado con la intensidad sintomática?	1-5
25	Indique la intensidad del estresor laboral al que ha estado sometido en el paciente	1-5
24	¿Cuánto tiempo ha estado sometido el paciente al estresor laboral referido? Indique su respuesta en número de meses	1-&
41	El estresor laboral referido, ¿contribuye al origen de los síntomas?	1-5

**p= N° de pregunta asociada, Resp.= Tipo de respuesta.

Discusión

A pesar de que los árboles alcanzaron una precisión superior al 85%, este resultado debe interpretarse con cautela, puesto que cuando se analizaron los resultados entre los grupos considerados en este estudio, se encontraron diferencias significativas, lo cual podría producir sesgo ante el grupo minoritario (OAL). Esto es

consistente con estudios previos que advierten que "los árboles sobre ajustados no solo tienen pobres capacidades predictivas en datos nuevos previamente no vistos, sino que también pueden ser excesivamente difíciles de interpretar, lo cual es una barrera clave contra la adopción de estos modelos en aplicaciones prácticas"³⁵. Para mitigar este problema, se recomienda ampliar la muestra

del grupo OAL, y reentrenar el modelo, asegurando su validez así como también su capacidad de generalización.

Además, se observó que el añadir más variables ("plus") mejoró la precisión del modelo, lo que resalta la importancia de una selección y construcción adecuada de características. Esto permitiría identificar ítems adicionales que optimicen el proceso de clasificación. Sin embargo, es fundamental evitar la inclusión de variables redundantes o irrelevantes, dado que podrían dificultar la interpretabilidad, puesto que algunas características mínimas logran resultados óptimos⁷.

El ajuste del umbral para mejorar la sensibilidad a expensas de la especificidad, debe considerar las prioridades clínicas y éticas, ya que los modelos de aprendizaje automático pueden amplificar desigualdades si no se abordan sesgos en datos y diseños^{17,20}. En el ámbito clínico, una identificación precisa de las causas tiene implicancias directas en el tratamiento e intervención. Además, la creciente incorporación de herramientas tecnológicas que se están introduciendo en las áreas de salud, permite abordar la complejidad del ser humano en contextos críticos^{5,30}, haciendo imprescindible la integración de marcos éticos robustos que garanticen, equidad, transparencia y predicciones justas^{25,26}. Así, estos estudios deben trascender la utilidad técnica del procesamiento de información y alinearse con una perspectiva centrada en la persona.

Un aspecto relevante del estudio, es la selección de técnicas de aprendizaje automático, las cuales se fundamentan en criterios como interpretabilidad, simplicidad, eficiencia computacional y robustez frente a datos binarios, sirviendo como punto de partida para investigaciones con modelos más avanzados^{2,34}. Asimismo, el proceso de calificación se encuentra dentro de lo normativo, por lo cual la inserción de cualquier herramienta en lo que signifique la clasificación de una enfermedad debe ser interpretable para la comunidad.

Por último, el sexo y edad como variables dentro del algoritmo no influyeron en los resultados finales de la clasificación, lo cual podría indicar que el modelo se encuentra libre de este tipo de sesgos. No obstante, se puede encontrar que los

modelos de árbol de decisión tienden a ser más sensibles a cambios en los datos de entrenamiento, lo que podría afectar su estabilidad si estas variables de edad y/o sexo tienen gran variabilidad en la muestra^{9,31}, lo cual es justificado en algunas enfermedades como diabetes o enfermedades cardiovasculares^{15,18}.

El modelo desarrollado presenta un notable potencial para apoyar la calificación de enfermedades profesionales de salud mental, al ofrecer criterios claros y cuantificables que pueden estandarizar el proceso, reducir la subjetividad y respaldar decisiones con mayor objetividad. Sin embargo, su implementación exitosa requiere que sea accesible, interpretable y adaptable a las normativas vigentes, respetando las especificidades de cada caso. En este sentido, el uso de este modelo sería más adecuado como herramienta de apoyo al proceso de calificación, facilitando que un profesional valide o ajuste las propuestas generadas, dado que cada caso demanda un análisis específico.

Como conclusión, el "Árbol Plus" posee un rendimiento superior en términos de precisión y balance de predicción al integrar preguntas adicionales que optimizan su desempeño. Sin embargo, se observaron limitaciones en la especificidad y en la capacidad de generalización del modelo, esto refuerza la necesidad de validaciones más robustas y optimizaciones adicionales. No obstante, todos los algoritmos superan la precisión de 80%, pero esto se debe al desequilibrio de los datos, lo cual provoca que un modelo acierte gran cantidad de casos solo dando una respuesta de "no enfermedad" en los grupos de prueba. De forma específica, en esta evaluación de aprendizaje automático no se ha producido un sesgo asociado al sexo ni la edad. Este hallazgo sugiere que los problemas de salud mental no están influenciados directamente por estas variables en el modelo analizado.

Como respuesta a este análisis realizado, resulta pertinente desarrollar un proyecto exclusivo para la población consultante a través de la ley 16.744, con el objetivo de identificar ítems independientes que optimicen la predictibilidad de un modelo de decisión de una calificación de origen de la enfermedad.

Referencias

1. Abdulqader HA, Abdulazez AM. A review on decision tree algorithm in healthcare applications. *Indones J Comput Sci.* 2024; 13(3): 3863-3881. doi:10.33022/ijcs.v13i3.4026.
2. Ahmad MA, Eckert C, Teredesai A, Mckelvey G. Interpretable machine learning in healthcare. 2018. doi: 10.1145/3233547.3233667.
3. Aleem S, Huda N, Amin R, Khalid S, Alshamrani SS, Alshehri A. Machine learning algorithms for depression: Diagnosis, insights, and research directions. *Electronics.* 2022; 11(7): 1111. doi:10.3390/electronics11071111.
4. Almonte JC, Mena C, Ortiz S, Osorio JP. Psiquiatría y ley de enfermedades profesionales en Chile: Revisión histórica y crítica de una relación compleja. *Revista Médica de Chile.* 2016; 144(12): 1591-1597. doi: 10.4067/S0034-98872016001200011.
5. Aracena C, Villena F, Arias F, Dunstan J. Aplicaciones de aprendizaje automático en salud. *Revista Médica Clínica Las Condes.* 2023; 33(6): 568-575. doi: 10.1016/j.rmcl.2022.10.001.
6. Aranibar LA. Proceso de reconocimiento de una enfermedad mental de origen laboral: La experiencia chilena. *Revista Brasileira de Medicina do Trabalho.* 2018; 16(1): 100-105. doi: 10.5327/Z1679443520180189.
7. Bredensteiner EJ, Bennett KP. Feature minimization within decision trees. 1996.
8. Brzovic D, Hermosilla MP, Saldías J, Repositorio A, Garay V, Piña J, et al. Repositorio de algoritmos públicos, universidad Adolfo Ibañez, informe 2024. GobLab UAI. Available from: https://www.algoritmospublicos.cl/static/Informes/GobLab-UAI-Repositorio_Algoritmos_Publicos_Informe_2024.pdf.
9. Cha J, Nguyen N, Tran C, Shin W, Lee S, Lee Y, et al. Assessment of fractional flow reserve in intermediate coronary stenosis using optical coherence tomography-based machine learning. *Front Cardiovasc Med.* 2023; 10: 1082214. doi:10.3389/fcvm.2023.1082214.
10. Chang L. Employee mental health risk prediction and coping management based on neural network. *Appl Math Nonlinear Sci.* 2024; 9(1): 1-18. doi:10.2478/amns.2023.2.01601
11. Christodoulou E, Ma J, Collins GS, Steyerberg EW, Verbakel JY, Calster BV. A systematic review shows no performance benefit of machine learning over logistic regression for clinical prediction models. *J Clin Epidemiol.* 2019; 110: 12-22. doi: 10.1016/j.jclinepi.2019.02.004.
12. Compendio de normas del seguro social de accidentes del trabajo y enfermedades profesionales. Libro III. Denuncia, calificación y evaluación de incapacidades permanentes título III. Calificación de enfermedades profesionales. Available from: <https://www.suseso.cl/613/w3-propertyvalue-136474.html>.
13. Dooshima MP, Chidozie EN, Ademola BJ, Sekoni OO, Adebayo IP. A predictive model for the risk of mental illness in Nigeria using data mining. *Int J Immunol.* 2018; 6(1): 5-16. doi: 10.11648/j.iji.20180601.12.
14. Hernández R, Fernández C, Baptista P. Metodología de la investigación. McGraw-Hill; 2010.
15. Iwagami M, Inokuchi R, Kawakami E, Yamada T, Goto A, Kuno T, et al. Comparison of machine-learning and logistic regression models for prediction of 30-day unplanned readmission in electronic health records: A development and validation study. *PLOS Digit Health.* 2024; 3(8): e0000578. doi: 10.1371/journal.pdig.0000578.
16. Iyortsuun NK, Kim S, Jhon M, Yang H, Pant S. A review of machine learning and deep learning approaches on mental health diagnosis. *Healthcare.* 2023; 11(3): 285. doi: 10.3390/healthcare11030285.
17. Javed H, Muqet HA, Javed T, Rehman AU, Sadiq R. Ethical frameworks for machine learning in sensitive healthcare applications. *IEEE Access.* 2024; 12: 16233. doi: 10.1109/access.2023.3340884.
18. Joshi RD, Dhakal CK. Predicting type 2 diabetes using logistic regression and machine learning approaches. *Int J Environ Res Public Health.* 2021; 18(14): 7346. doi: 10.3390/ijerph18147346.
19. Leiva V, Rubí P, Vicente B. Determinantes sociales de la salud mental: Políticas públicas desde el modelo biopsicosocial en países latinoamericanos. *Rev Panam Salud Publica.* 2021; 45: e158. doi: 10.26633/RPSP.2021.158.
20. McCradden MD, Anderson JA, Stephenson EA, Drysdale E, Erdman L, Goldenberg A, et al. A research ethics framework for the clinical translation of healthcare machine learning. *Informa UK Limited.* doi: 10.1080/15265161.2021.2013977.
21. Biblioteca del Congreso Nacional | Ley Chile | Ley 16.744. Available from: <https://www.bcn.cl/leychile>.
22. Decreto 109 aprueba el reglamento para la calificación y evaluación de los accidentes del trabajo y enfermedades profesionales, de acuerdo con lo dispuesto en la ley 16.744, de 1° de febrero de 1968, que estableció el seguro social contra los riesgos por estos accidentes y enfermedades. Available from: <https://www.bcn.cl/leychile/navegar?idNorma=9391&idParte=8630485>.
23. Osorio JP, Martini N. Propuesta para la objetivación y tecnologización del proceso de calificación de enfermedades profesionales de salud mental. Asociación Chilena De Seguridad. Available from: https://www.achs.cl/docs/librariesprovider2/default-document-library/257-2020-%2851inv20achs%29-mind_osorio_calificacion-ep-salud-mental_informe-final.pdf?sfvrsn=e7b9c42f_0.
24. Perez S. Conciliación familia-trabajo y su relación con la salud mental y el apoyo social desde una perspectiva de género. *Dilemas Contemporáneos: Educación, Política Y Valores.* 2021; 8(SPE1). doi: 10.46377/dilemas.v8i2.2568.
25. Pfohl SR, Foryciarz A, Shah NH. An empirical characterization of fair machine learning for clinical risk prediction. *J Biomed Inform.* 2020; 113: 103621. doi: 10.1016/j.jbi.2020.103621.
26. Raza S, Pour PO, Bashir SR. Fairness in machine learning meets with equity in healthcare. 2023. doi: 10.48550/arXiv.2305.07041.
27. Richens JG, Lee CM, Johri S. Improving the accuracy of medical diagnosis with causal machine learning. *Nat Commun.* 2020; 11(1): 3923. doi: 10.1038/s41467-020-17419-7.
28. Sharma CM, Chariar VM. Diagnosis of mental di-

- sorders using machine learning: Literature review and bibliometric mapping from 2012 to 2023. *Heliyon*. 2024; 10(12): e32548. doi: 10.1016/j.heliyon.2024.e32548.
29. Shatte ABR, Hutchinson DM, Teague SJ. Machine learning in mental health: A scoping review of methods and applications. *Psychol Med*. 2019; 49(9): 1426-1448. doi: 10.1017/S0033291719000151.
 30. Toh C, Brody JP. Applications of machine learning in healthcare. In: *Smart Manufacturing - When Artificial Intelligence Meets the Internet of Things*. 2021. doi: 10.5772/intechopen.92297.
 31. Usman K, Rajpoot K. Brain tumor classification from multi-modality MRI using wavelets and machine learning. *Pattern Anal Appl*. 2017; 20(3): 871-881. doi: 10.1007/s10044-017-0597-8.
 32. Valverde M. La enfermedad ocupacional en el régimen laboral de la actividad privada. *QuanTUNAB*. 2022. doi: 10.52807/qunab.v1i2.19.
 33. van Eeden WA, Luo C, van Hemert AM, Carlier IVE, Penninx BW, Wardenaar KJ, et al. Predicting the 9-year course of mood and anxiety disorders with automated machine learning: A comparison between auto-sklearn, naïve bayes classifier, and traditional logistic regression. *Psychiatry Res*. 2021; 299: 113823. doi: 10.1016/j.psychres.2021.113823.
 34. Vellido A. The importance of interpretability and visualization in machine learning for applications in medicine and health care. *Neural Comput Appl*. 2019; 31: 1615-1625. doi: 10.1007/s00521-019-04051-w.
 35. Verdonck T, Baesens B, Óskarsdóttir M, Vanden Broucke S. Special issue on feature engineering editorial. *Springer Sci Bus Media LLC*. 2021. doi: 10.1007/s10994-021-06042-2.
 36. Villalobos G. Logros y desafíos en la gestión psicosocial y de la salud mental en entornos laborales: Experiencia colombiana. *Universidad Nacional del Nordeste*. 2023. doi: 10.30972/rfce.3127153.
 37. Whipple N. Críticas al sistema de calificación de enfermedades profesionales mentales en el otorgamiento de cobertura de la ley N° 16.744. *Universidad De Chile*. Available from: <https://repositorio.uchile.cl/handle/2250/186555>