

Algoritmos inteligentes aplicados al análisis del perfil de estrés con perspectiva de género

Intelligent algorithms applied to stress profile analysis with a gender perspective

Marta-Lilia Eraña-Díaz* **Alejandra Rosales-Lagarde****

* Universidad Autónoma del Estado de Morelos (México) merana@uaem.mx Orcid: <https://orcid.org/0000-0001-8450-8247> Dirección Postal: Av. Ferrocarril México Balsas #50-4. Col. Ocotepc, Cuernavaca, Mor. C.P.62220. Correo Electrónico: merana@uaem.mx ** Consejo Nacional de Humanidades, Ciencias y Tecnologías-Instituto Nacional de Psiquiatría Ramón de la Fuente Muñiz (México) alexiaro@rocketmail.com Orcid: <https://orcid.org/0000-0002-3557-603X>

Recibido 4 septiembre, 2023; Aceptado 18 de octubre 2023

Resumen

Las respuestas al estrés y los estilos de afrontamiento son distintas entre los individuos. La perspectiva de género es importante para el establecimiento de medidas realistas en la promoción de la salud de los trabajadores, ya que las respuestas ante situaciones consideradas de riesgo suceden a nivel conductual, fisiológico y psicológico. En la actualidad, desde la perspectiva psicológica y psicobiológica, se aplican escalas para medir los niveles de estrés y los estilos de afrontamiento entre los individuos.

En este trabajo se llevó a cabo un estudio para obtener un indicador o modelo que permite mostrar los niveles de vulnerabilidad existentes entre los niveles de riesgo, analizándolo desde la perspectiva de género, entre mujeres y hombres. El indicador seleccionado es el nivel de estrés, el cual fue estimado aplicando el instrumento el Perfil de Estrés de Nowack.

Los resultados de tres estudios realizados en diferentes contextos fueron recopilados y analizados bajo una perspectiva de género. El primer estudio fue de laboratorio y se aplicaron escalas para detectar depresión y estrés (n = 136 estudiantes). El segundo estudio se realizó a un grupo de Adultos Mayores en una investigación sobre la relación del sueño y el deterioro cognitivo. El tercer estudio fue realizado a trabajadores del Instituto Nacional de Estadística y Geografía, con el propósito de promover la salud mental.

El análisis de la información obtenida del instrumento se llevó a cabo aplicando los algoritmos inteligentes del Machine Learning, ML, k-means, Decision Tree (DT), y Random Forest (RF), con diferentes configuraciones de los conjuntos de datos de los estudios mencionados. En el análisis con perspectiva de género, el mejor modelo se obtuvo con el algoritmo RF donde las primeras cuatro dimensiones relevantes fueron: bienestar psicológico, red de apoyo social, hábitos de salud y valoración negativa. Además, el porcentaje de mujeres con recursos más limitados para afrontar el estrés fue menor que el de los hombres. Estos análisis permiten enfocarse en el grupo con mayor nivel de riesgo para generar estrategias tempranas de prevención y manejo del estrés.

Palabras clave: estrés, salud mental, machine learning, perspectiva de género, bienestar psicológico.

Abstract

Stress responses and coping styles vary among individuals. Under deemed risky situations eliciting behavioral, physiological, and psychological responses, a gender approach is crucial for setting up realistic measures in promoting the worker's health. Currently, from a psychological and psychobiological perspective, scales are applied to measure stress levels and coping styles among individuals.

This study was conducted to obtain an indicator or model that allows displaying existing vulnerability levels among risk levels, analyzing it from a gender perspective, comparing women and men. The selected indicator is the level of stress, estimated by applying the Nowack Stress Profile instrument.

The results of three studies conducted in different contexts were compiled and analyzed from a gender perspective. The first study took place in a laboratory, and scales were administered to detect depression and stress ($n = 136$ students). The second study examined the relationship between sleep and cognitive decline ($n = 14$ older adults). The third study was conducted on workers at the National Institute of Statistics and Geography ($n = 116$), with the purpose of promoting mental health.

The analysis of data obtained from the instrument was carried out using intelligent machine learning algorithms, specifically k-means, Decision Tree (DT), and Random Forest (RF), with different configurations of the datasets from the mentioned studies. With the gender perspective analysis, the best model was obtained from the RF algorithm and the first four relevant dimensions were psychological well-being, social support network, health habits, and negative appraisal. Additionally, in coping with stress, the percentage of women with fewer resources was lower than that of men. These analyses allow focus on the group with higher level of risk in order to generate early prevention and stress management strategies.

Key words: stress, mental health, machine learning, gender approach, psychological well-being.

1. Introducción

Actualmente, es posible manejar grandes volúmenes de información agilizando el procesamiento o análisis de estos mediante la inteligencia artificial (IA). Podemos decir que la inteligencia artificial es la capacidad que tienen las computadoras de mostrar un comportamiento inteligente, definiendo inteligencia como la facultad de realizar procesos de aprendizaje, razonamiento, toma de decisiones, entre otras. Una definición simple de algoritmo es: un conjunto de instrucciones informáticas que recibe una máquina para realizar una acción o resolver un problema, teniendo una entrada (input) y/o una salida (output). Los algoritmos son los que otorgan autonomía a la Inteligencia Artificial. De manera que los algoritmos inteligentes son aquellos capaces de basar el procesamiento automático tomando decisiones y creando procesos no programados, esto generalmente bajo modelos matemáticos. Dentro de estos algoritmos tenemos los de aprendizaje máquina, ML por sus siglas en inglés "Machine Learning", que es una rama de la inteligencia artificial relacionada con el diseño y la aplicación de algoritmos de aprendizaje (Mahesh, 2020). Los métodos de ML han demostrado ser una técnica muy útil para generar modelos que muestren, en cierta medida, el fenómeno observado (Chiogna, 1994). Así, ML se encarga de construir programas que puedan aprender de los datos. El aprendizaje se realiza mediante la extracción de información sobre los datos a través de algoritmos que analizan la estructura básica de ellos, llamada señal, y distinguir esta del ruido, es por esto que estas técnicas de ML son conocidas como algoritmos de reconocimiento de patrones. Dentro del ML, se aplican técnicas de aprendizaje no supervisado y supervisado.

Las técnicas de aprendizaje no supervisado clasifican sin tener etiquetas en los objetos, es decir las categorías son desconocidas. Para el caso de datos continuos, el objetivo en el análisis de agrupamiento (cluster) es poner los elementos en grupos separados de manera que los que pertenecen al mismo grupo sean lo más similar posible y lo

más diferentes a los de los otros grupos. Es decir, los clusters serán diferentes en la medida que exista una marcada diferencia entre los grupos y que en cada grupo haya una mayor similitud. En las técnicas de aprendizaje supervisado, se tienen a los árboles de decisión, y entre ellos los de tipo CART (Classification and Regression Trees). El proceso de generación de un árbol es un proceso iterativo. Empieza situando toda la muestra disponible en el nodo raíz, a partir del cual, por sucesivas particiones, se obtienen las ramas del árbol hasta los nodos terminales u hojas, formadas por conjuntos de individuos que han contestado un número similar de ítems, por ejemplo. Una manera de evitar que con las particiones que se van obteniendo, se genere un árbol poco fiable, es mediante una técnica de validación como criterio de parada. La muestra se divide en dos, una de aprendizaje (70 u 80%) y otra para validación (30 o 20%). Para profundizar en este tema se recomienda (Alpaydin, 2021; Mitchel, 1997).

Por otra parte, la salud mental según la Organización Mundial de la Salud, OMS, es definida como

"La salud mental es un estado de bienestar mental que permite a las personas hacer frente a los momentos estresantes, desarrollar sus habilidades, aprender, trabajar adecuadamente y contribuir al bienestar de su comunidad."

Tener una buena salud mental es importante porque mejora la calidad de vida, aumenta la autoestima, mejora las relaciones interpersonales, aumenta la productividad y reduce el estrés (Pilgrim, 2022).

Con respecto a gestionar el estrés, la escala de Perfil de Estrés de Kenneth M. Nowack (Nowack, 1999), consiste en la medida de una variedad de factores que pueden afectar la salud física y bienestar psicológico. Las respuestas del perfil de estrés se han comparado con las respuestas dadas por un gran grupo racial y culturalmente diverso de adultos que trabajan de varias partes del mundo que completaron el inventario, con las cuales se han determinado los baremos para determinar el nivel de estrés percibido. Este perfil está determinado por las puntuaciones en las

dimensiones Estrés; Hábitos de salud, ejercicio, sueño/relajación, Prevención y Alimentación/Nutrición, Red de Apoyo Social, Comportamiento Tipo A; Flexibilidad Cognitiva, Valoración Positiva, Valoración Negativa, Minimización de Amenazas y concentración en el problema y Bienestar Psicológico. Profundizando en el estrés, esta escala lo define como la experiencia de irritantes, molestias y frustraciones mayores y menores de la vida diaria. Esta escala mide la experiencia con las molestias diarias durante un período de tres meses en seis áreas diferenciadas: 1) Salud; 2) Trabajo; 3) Finanzas Personales; 4) Familia; 5) Obligaciones Sociales; y 6) Preocupaciones ambientales y mundiales.

La escala de Bienestar Psicológico es una medida de la satisfacción con la vida en general. Una puntuación alta indica que la persona está satisfecha consigo misma y se siente capaz de relajarse y disfrutar de la vida. Aquellos con puntajes altos reportan sentirse feliz con su familia, trabajo, relaciones interpersonales, éxitos y logros. En general, Las personas con un fuerte sentido de bienestar psicológico reportan menos enfermedades relacionadas con el estrés que aquellas sin un sentido tan fuerte.

El uso de esta herramienta de Nowack ha sido ampliamente utilizado para determinar el perfil de estrés (D la Roca-Chiapas, Reyes-Pérez, Huerta-Lépez, Acosta-Gómez, Nowack y Colunga-Rodríguez, 2019), (Pozos-Radiño, 2021), (Llanes-Castillo, 2022), sin embargo, no se ha trabajado lo suficiente en evaluar la vulnerabilidad ante el estrés desde la perspectiva de género, con las ventajas que presentan este tipo de estudios al identificar elementos o procesos que marcan desigualdades entre los hombres y mujeres (Esteban, 2006), (Cuadro, 2017).

En el presente trabajo se aplicaron técnicas de ML para el tratamiento de los datos obtenidos de tres estudios sobre el perfil de estrés, el primero aplicado a una población estudiantil, el segundo a un estudio realizado para determinar deterioro cognitivo en adultos mayores y el último a los trabajadores del Instituto Nacional de Estadística y Geografía, INEGI, este último con el propósito de conocer su estado de salud y entregar los resultados globales a los directivos y personalizados a cada empleado. Los algoritmos y scripts de ML, se realizaron en R (R Core Team, 2013). R es un lenguaje libre muy potente para manipular y analizar datos. Debido a su gran popularidad en la ciencia de datos, la comunidad de estadistas y programadores ha generado cantidad de paquetería, haciendo que R provea múltiples técnicas en este ramo (Sánchez-Villena, 2019). El resto del documento está organizado como sigue: la Sección 2 presenta trabajos relacionados recientes y relevantes en la investigación de la aplicación de inteligencia artificial. La Sección 3 describe el método realizado para evaluar y determinar el perfil de estrés desde una perspectiva de género. En la Sección 4 se presenta el análisis y los resultados, por último, en la sección 5, la discusión, y en la sección 6 las conclusiones y trabajo futuro.

2. Estudios Relacionados

Existe gran evidencia de la aplicación de técnicas de IA en múltiples áreas como la medicina, la ingeniería o las ciencias sociales (Breiman, 2001). En el área de la psicología, Alikhanian, Crawford, DeSouza y Blohm (2013), utilizaron el aprendizaje no supervisado para encontrar áreas activas del cerebro a través de datos obtenidos mediante magnetoencefalografía (MEG). La localización confiable de las áreas del cerebro utilizando MEG, ha sido difícil debido a las variaciones en la señal y la extensión espacial de la actividad reconstruida. El enfoque que se propone en la publicación para resolver esta variación se efectúa mediante clustering o la agrupación adaptativa en imágenes reconstruidas para encontrar ubicaciones que son consistentemente activas en los diferentes participantes. Se utiliza descomposición del valor singular (SVD). SVD es la composición de una matriz simétrica a través de una extensión de la descomposición polar. En Bulteel, Tuerlinckx, Brose y Ceulemans (2016) se comenta que en la psicología se está utilizando cada vez más el modelo vectorial autorregresivo (VAR). Éste contabiliza las relaciones entre las variables explicativas considerando el efecto de la retroalimentación, es decir, la dependencia de observaciones pasadas. Bulteel et al. (2016) plantean la necesidad de analizar los datos de varias personas para captar similitudes y diferencias individuales al aplicar cierta dinámica. Por lo que su propuesta es realizar una clasificación de las personas mediante su valor VAR (Huang, Zhou, Ding y Zhang, 2011). El modelo además de generar los clusters de acuerdo al peso VAR, proporciona un modelo común a todas las personas del cluster, identificando así personas con dinámicas similares, lo que puede apoyar a los especialistas en asignar tratamientos personalizados. Posterior a la creación del modelo, se evaluó el desempeño con datos de series de tiempo multivariantes sobre los síntomas relatados de depresión en mujeres jóvenes. Concluyen que los estudios en psicología investigan cada vez más los procesos internos de las personas, donde la propuesta del modelo de clusters mediante la clasificación del valor VAR, capta las diferencias cualitativas de las dinámicas intraindividuales. En Trujillano, Sarria-Santamera, Esquerda, Badia, Palma y March (2008) se realiza una aproximación a la metodología de árboles de decisión tipo CART (Classification and Regression Trees) desarrollando un modelo para calcular la probabilidad de muerte hospitalaria en infarto agudo de miocardio. Se hace un comparativo entre el uso de árboles de decisión tipo CART, regresión Logística (RL) y Redes neuronales artificiales (RNA) llegando a la conclusión de que los tres modelos obtienen resultados similares en su capacidad de discriminación, sin embargo, el modelo CART es el seleccionado ya que ofrece como ventaja, una simplicidad en su utilización e interpretación de las reglas de decisión. En Eraña-Díaz, Cruz-Chávez, Juárez-Pérez, Enriquez-Urbano, Rivera-López y Acosta-Flores (2021) se aplica una metodología computacional con técnicas de IA para

obtener el máximo beneficio en salud laboral atendiendo los factores de riesgo psicosocial en la empresa. Este esquema se basa en una adaptación del problema de la mochila multi-dimensional (MKP) que selecciona un subconjunto óptimo de factores de riesgo psicosocial, considerando el presupuesto de los departamentos de una empresa como restricciones del problema. En Josephy, Loeys y Rosseel (2016) se realiza una comparación de la eficiencia de los paquetes del software R para mejorar los efectos aleatorios de datos en muestras pequeñas, ya que los investigadores de las ciencias sociales y del comportamiento se enfrentan a estructuras de datos correlacionados donde un análisis que ignora estas dependencias puede subestimar el error estándar, mientras que una inadecuada incorporación entre niveles puede dar como resultado coeficientes sesgados. Utilizan dos marcos (frameworks), el primero utilizando Adaptive Gaussian Quadrature (AGQ) y otro con Structural Equation Models (SEM), el resultado fue que SEM tuvo mejor desempeño con dos clusters mientras que AGQ tuvo mayor precisión conforme el tamaño del cluster se incrementa, de manera que AGQ es la mejor opción para manejar el sesgo, mostrando mayor precisión. Las pruebas se realizaron con una muestra de 37 niños de una sola escuela, de manera que la estructura de datos se simplifica a dos niveles con una respuesta binaria que se evalúa repetidamente en cada niño.

3. Estudio con perspectiva de género para evaluar la respuesta al estrés

El nivel de la calidad de vida del ser humano es función de una buena salud mental, sin embargo, cuando el estrés no se afronta en forma adecuada se pueden originar enfermedades mentales (depresión, ansiedad, etc.) lo que incide en la calidad de vida. En este trabajo, considerando la perspectiva de género, se llevó a cabo un estudio para evaluar los niveles de vulnerabilidad a través de la medición de perfiles de Estrés de Nowack.

3.1 Metodología

La metodología que describe, en forma general el proceso que se llevó a cabo para la realización del estudio de los niveles de vulnerabilidad, a partir de la medición del perfil de estrés de los participantes, fue el siguiente:

Se seleccionaron los grupos de personas, con diferentes características (edad, oficio, etc.)

Se aplicó el instrumento de Perfil de Estrés de Nowack para determinar los recursos del individuo para lidiar con el estrés.

Clasificación y análisis de la base de datos mediante algoritmos de Machine Learning, lo anterior con el software y paquetería de R.

3.1.1 Participantes y modalidades de los grupos de estudio

De tres estudios realizados entre los años 2016 y 2017 se obtuvieron tres muestras a las que se les aplicó el

instrumento de Perfil de Estrés de Nowack. Cada uno de estos estudios tuvo diferentes objetivos pero un fin común que fue identificar las dimensiones que presentan menores puntuaciones que implican pocos recursos para lidiar con el estrés cotidiano. Se incluye en este estudio un cuarto grupo con la agrupación de estas tres muestras y 4 resultados más del equipo de trabajo. Las características de estos grupos son las siguientes:

Grupo A. La muestra es de 136 estudiantes de la Facultad de Ciencias Químicas e Ingeniería de la UAEM, la edad promedio de los participantes es de 20 años. La muestra, en su mayoría, es de hombres (86%).

Grupo B. La muestra es de 14 adultos mayores, la edad promedio de los participantes es de 68 años. El total de la muestra es de 57% mujeres y 43% de hombres.

Grupo C. La muestra es de 116 trabajadores del INEGI delegación Hidalgo, la edad promedio de los participantes es de 46 años. El total de la muestra es de 63% mujeres y 37% hombres.

Grupo D. La muestra es la suma de los tres grupos anteriores y 4 personas más que colaboraron en el grupo B, en total 270 participantes, la edad promedio de los participantes es de 34 años con un 38% de mujeres y 62% de hombres.

En cada uno de estos estudios en su momento, se les comentó a los participantes sobre la importancia de la salud mental en la calidad de vida y las formas de evaluarlas, se describió el objetivo de ese estudio y se entregó a cada participante su resultado en forma personal y confidencial. Los participantes firmaron un consentimiento informado donde se especificó la posibilidad de utilizar sus datos en estudios posteriores ya que el equipo de trabajo comunicó que el levantamiento de información era solo para fines académicos reiterando la confidencialidad de los mismos.

Se explica a continuación cada uno de los estudios realizados en los grupos A, B, C y el estudio actual con el grupo D.

ESTUDIO A. Respuesta del Cortisol ante paradigma de Defensa.

Objetivo: Evaluar en grupos balanceados en la respuesta de estrés con sus recursos de afrontamiento la relación entre la respuesta conductual para conocer la actividad autónoma del eje hipotálamo-hipófisis-adrenal (HHA) y en particular el nivel de cortisol en saliva (Eraña-Díaz, 2016).

Se aplicó el instrumento de Perfil de Estrés para determinar los recursos de afrontamiento ante el estrés obteniendo un indicador nombrado CRAf (Conglomerado de Recursos de Afrontamiento) categorizado en CRAf Alto y Bajo.

ESTUDIO B. Dissociation of Arousal Index Between REM and NREM Sleep in Elderly Adults with Cognitive Impairment, No Dementia: A Pilot Study (Rosales-Lagarde, Cubero-Rego, Menéndez-Conde, Rodríguez-Torres, Itzá-Ortiz, Martínez-Alcalá y Eraña Díaz, 2023).

Objetivo: Investigar si el deterioro cognitivo no demencia (CIND) está relacionada con índices altos de agitación entre las etapas del sueño NREM y REM mediante el uso de polisomnografía (PSG) nocturna completa.

Se aplicaron diversos instrumentos neuropsicológicos, entre estos el Perfil de Estrés, para conocer el nivel de estrés de los grupos de estudio.

ESTUDIO C. Promoción de la Salud Mental en trabajadores del INEGI, en Hidalgo.

Objetivo: Identificar y generar resultados individuales de los factores protectores y de riesgo de salud de la población adscrita del Instituto Nacional de Estadística e Informática (INEGI) mediante la aplicación de test psicológicos y el tratamiento de datos con técnicas de ML.

Se realizaron diferentes pruebas y se aplicaron varios instrumentos entre los cuales estuvo el de Perfil de Estrés, se obtuvieron los baremos de la población con ML y se contrastaron con los del manual de Nowack. Con el aprendizaje no supervisado, la clasificación en cuatro clústeres fue la más representativa de los datos por lo que se generaron cuatro niveles de riesgo: nulo, bajo, alto y muy alto para cada una de las 15 dimensiones del instrumento de Nowack, en el Apéndice A se muestran los baremos semaforizados de ML y los del manual de Nowack.

ESTUDIO D. Para este estudio actual, se utilizaron los datos de los tres estudios anteriores y se incorporaron 4 resultados más del instrumento de Nowack de mujeres del equipo de trabajo del estudio B. De manera que la muestra para el análisis con perspectiva de género de este instrumento es de 270 con un 38% de mujeres y 62% de hombres.

Las características de los grupos de los participantes de los casos de estudio se presentan en las tablas 1, 2 3 y 4.

Tabla 1. Características de participantes del caso de estudio A

	Mujeres	Hombres	Total
Participantes	19	117	136
Edad promedio y DS (Prom/DS)	20.8 / 1.7	20 / 2.3	20.2 / 2.22
Nivel de Educación (años)	13.82 / 1.62	13. 1 / 1. 4	13.2 / 1.42

Tabla 2. Características de participantes del caso de estudio B

	Mujeres	Hombres	Total
Participantes	8	6	14
Edad promedio y DS (Prom/DS)	66.9 / 6.5	69.5 / 3.2	68 / 5.3
Nivel de Educación (años)	11 / 3.3	12.2 / 2.2	11.64 / 2.9

Tabla 3. Características de Participantes del caso de estudio C

	Mujeres	Hombres	Total
Participantes	73	43	116
Edad promedio y DS (Prom/DS)	46.2 / 9.8	46.9 / 7.1	46.4 / 8.8
Nivel de Educación (años)	15.6/ 2.4	15.3 / 2.5	15.5 / 2.4

Tabla 4. Características de Participantes del caso de estudio D (unión de participantes estudios A, B y C e incorporación de 4 resultados de las mujeres que aplicaron el instrumento en el estudio B)

	Mujeres	Hombres	Total
Participantes	104	166	270
Edad promedio y DS (Prom/DS)	42.5 / 14.9	28.8 / 14.8	34.1 / 16.2
Nivel de Educación (años)	14.9/ 2.7	13.6 / 2.1	14.1 / 2.4

3.2 Materiales y Recursos Tecnológicos

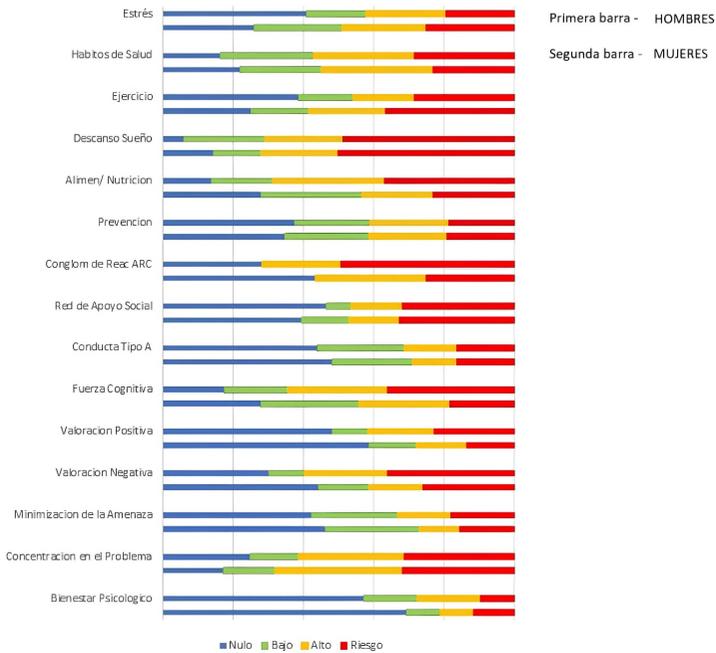
- Escala de Perfil de Estrés de Kenneth M. Nowack (digital y empresa) con 15 dimensiones, presentadas en la tabla 5.

Tabla 5. Escala de Perfil de Estrés de Kenneth M. Nowack. Nota: H4, H5, H6 y H7 son dimensiones que complementan la dimensión de Hábitos de Salud.

Clave	Descripción
D1_Estres	Estrés
D2_Hab_Salud	Hábitos de Salud
D3_Ejercicio	Ejercicio
H4_sueno	Descanso Sueño
H5_Nutricion	Alimentación/ Nutrición
H6_Preencion	Prevención
H7_ConglARC	Conglomerados de Reactivos ARC
D8_Red_Apoyo	Red de Apoyo Social
D9_ConductaA	Conducta Tipo A
D10_Fza_Cog	Fuerza Cognitiva

En la gráfica de la figura 2 se observan en forma global los niveles de riesgo obtenidos para este estudio D. Es importante, notar que, en algunas de las 15 dimensiones, existe un contraste relevante entre los niveles de riesgo mostrados en las mujeres, con respecto al mostrado por los hombres.

Figura 2. Gráfica de los niveles de riesgo para el caso de estudio



Los datos clasificados son analizados con los algoritmos de machine learning con aprendizaje no supervisado y supervisado.

En la tabla 6 se nombran los dataset para simplificar la presentación de resultados y la tabla 7 contiene los elementos de cada una.

Tabla 6. Conjunto de datos (dataset)

ID	n	Descripción
DS00	270	Contiene todos los datos del estudio
DS01	117	Contiene los datos del modelo del segundo estudio
DS02	153	Contiene los datos de las otras investigaciones
DS03	104	Contiene los datos del grupo mujeres
DS04	166	Contiene los datos del grupo hombres

Tabla 7. Conjunto de datos (dataset)

Clave	Descripción	Tipo de datos	Rango valores
NInves	Número de Investigación del participante	entero	1 a.3
Nombre	Clave del nombre del participante	texto	variable
Edad	Edad del participante	entero	18 a 78
NEduc	Nivel de Estudios	real	5 a 20
D1_Estres	Puntuación de la dimensión Estrés	entero	0 a 80
D2_Hab_Salud	Hábitos de Salud	entero	0 a 80
D3_Ejercicio	Ejercicio	entero	0 a 80

Clave	Descripción	Tipo de datos	Rango valores
H4_sueno	Descanso Sueño	entero	0 a 80
H5_Nutricion	Alimentación/ Nutrición	entero	0 a 80
H6_Prevention	Prevención	entero	0 a 80
H7_ConglARC	Conglomerado de Reactivos ARC	entero	0 a 80
D8_Red_Apoyo	Red de Apoyo Social	entero	0 a 80
D9_ConductaA	Conducta Tipo A	entero	0 a 80
D10_Fza_Cog	Fuerza Cognitiva	entero	0 a 80
D11_Val_Pos	Valoración Positiva	entero	0 a 80
D12_Val_Neg	Valoración Negativa	entero	0 a 80
D13_Min_Amenaza	Minimización de la Amenaza	entero	0 a 80
D14_Concentracion	Concentración en el Problema	entero	0 a 80
D15_Bienestar	Bienestar Psicológico	entero	0 a 80
CRAf/Puntuación	Conglomerado de Recursos de Afrontamiento	entero	0 a 6

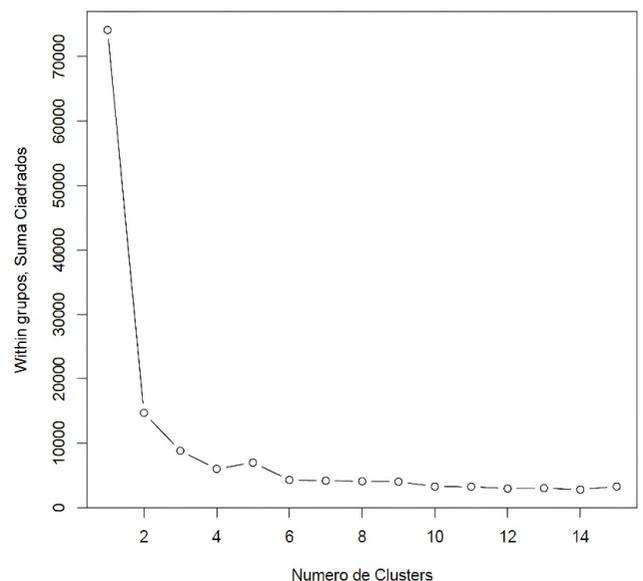
APRENDIZAJE NO SUPERVISADO

Tiene lugar cuando no se dispone de datos “etiquetados” para el entrenamiento. Sólo se conocen los datos de entrada, pero no existen datos de salida que correspondan a un determinado input. Por tanto, sólo es posible describir la estructura de los datos para intentar encontrar algún tipo de organización que simplifique el análisis. Por ello, se dice que tienen un carácter exploratorio. El problema de agrupación de objetos, de acuerdo con sus atributos, es ampliamente utilizado debido al descubrimiento de conocimiento y reconocimiento de patrones. El objetivo de la clasificación es particionar el conjunto de objetos de manera que los patrones en cada grupo sean similares en los atributos que son vectores multi-dimensionales asociados.

K-Means

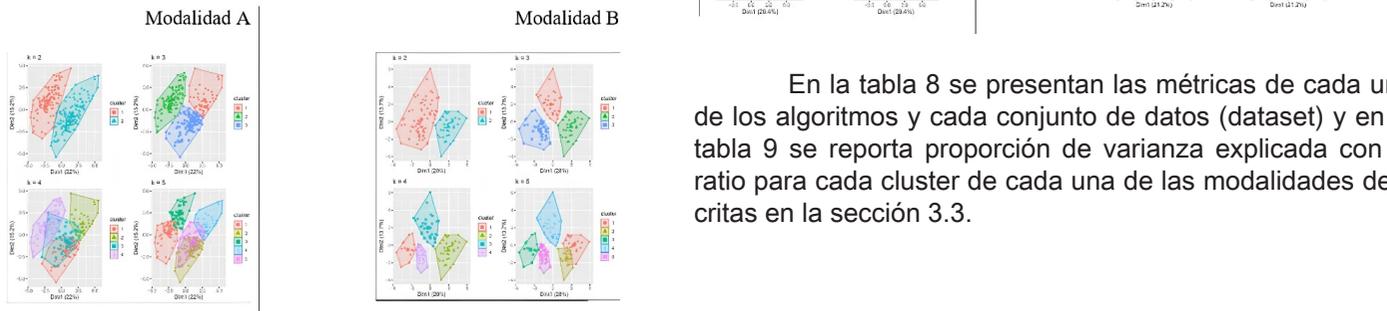
Para la selección del valor k, número de clusters de k-means se utilizó el método Elbow, para este estudio se consideró k =3 para las modalidades A y B y k=2 en las modalidades C y D. Un gráfico de coordenadas, figura 3, permite ver cómo se disminuye la suma de cuadrados del error conforme se agregan más clústeres.

Figura 3. Método del codo (Elbow) que muestra el número de clúster en relación con la disminución de la suma de cuadrados del algoritmo K-means



En el cuadro de la figura 4 se presentan las gráficas de la clasificación de las variables más relevantes, para las modalidades A y B, se selecciona el modelo con k=3, para las modalidades C y D, la mejor selección es con k=2.

Figura 4. Agrupamiento de datos más relevantes para valores de k desde 2 a 5. Se selecciona k=3 para las modalidades A y B y k=2 para las modalidades C y D



En la tabla 8 se presentan las métricas de cada uno de los algoritmos y cada conjunto de datos (dataset) y en la tabla 9 se reporta proporción de varianza explicada con el ratio para cada cluster de cada una de las modalidades descritas en la sección 3.3.

Tabla 8. Métricas de cada algoritmo y conjunto de datos.

	Grupo 1	Grupo 2	Grupo 3	Grupo 4
totss	5649	2436	202978	334364
withinss	1533 1437 1283	496 543 645	58639 108831	127544 157094
tot.withinss	4252	1684	167470	284637
betweenss	1397	752	35508	49727
size	96 90 84	33 38 46	35 69	79 87

Tabla 9. Ratio para cada modalidad y para cada clúster.

Modalidad	Cluster	Tamaño	ratio (withinss/ tot.withinss)
Modalidad A	1	96	0.36
	2	90	0.34
	3	84	0.29
Modalidad B	1	33	0.29
	2	38	0.32
	3	46	0.38
Modalidad C	1	35	0.35
	2	69	0.65
Modalidad D	1	79	0.45
	2	87	0.55

APRENDIZAJE SUPERVISADO

En el aprendizaje supervisado, los algoritmos trabajan con datos “etiquetados” (labeled data), intentando encontrar una función que, dadas las variables de entrada (input data), les asigne la etiqueta de salida adecuada. El algoritmo se entrena con un “histórico” de datos y así “aprende” a asignar la etiqueta de salida adecuada a un nuevo valor, es decir, predice el valor de salida.

Se aplicaron los métodos DT y RF a cada una de las Modalidades del presente estudio.

MODALIDAD A

La tabla 10 muestra el desempeño de los algoritmos DT y RF sobre los datos DS00, con n=270.

Tabla 10. Desempeño de los algoritmos DT y RF sobre los datos DS00, n=270.

Dataset	n	Correctas	Incorrectas	Accuracy (%)	Algoritmo de ML	Conjunto de dimensiones	Punto de corte
DS01 train	191	144	47	0.7539	DT	Edad, D8	<28,<51
DS01 test	79	59	20	0.7468	DT		
DS01 train	191	185	6	0.9686	RF	D15, Edad,Craf,D11	<59,<32.5,3.5,<43
DS01 test	79	62	17	0.7848	RF		

MODALIDAD B

En esta modalidad, se utiliza el conjunto de datos DS01 para entrenar el modelo, se prueba con el 30% de esa

misma y se valida con el conjunto de datos DS02, la tabla 11 muestra la información del desempeño de los algoritmos DT y RF.

Tabla 11. Desempeño de los algoritmos DT y RF, sobre los datos DS01 validados con los datos DS02.

Dataset	n	Correctas	Incorrectas	Accuracy	Algoritmo de ML	Conjunto de Dimensiones en el modelo	Punto de corte
DS01 train	84	70	14	0.8333	DT	Edad,Craf	<43,<2.5
DS01 test	33	23	10	0.697	DT		
DS02 valida	153	58	95	0.3791	DT		
DS01 train	84	80	4	0.9524	RF	Craf, D15,D2,D11	<2.5,<61,<69
DS01 test	33	20	13	0.6061	RF		
DS02 valida	153	101	52	0.6601	RF		

MODALIDAD C (Mujeres)
 El conjunto de datos utilizado en esta modalidad es el DS03 que es la información de todas las mujeres del estudio, n=104. La tabla 12 presenta el desempeño de esta modalidad.

Tabla 12. Desempeño de los algoritmos DT y RF sobre los datos DS03, n=104.

Dataset	n	Correctas	Incorrectas	Accuracy	Algoritmo de ML	Conjunto de Dimensiones	Punto de corte
DS03 train	74	68	9	0.8784	DT	D15	<54
DS03 test	30	23	7	0.7468	DT		
DS03 train	74	74	0	1	RF	D15, D2, D12	<53.5, <41, 3.5, <69.5
DS03 test	79	26	4	0.8667	RF		

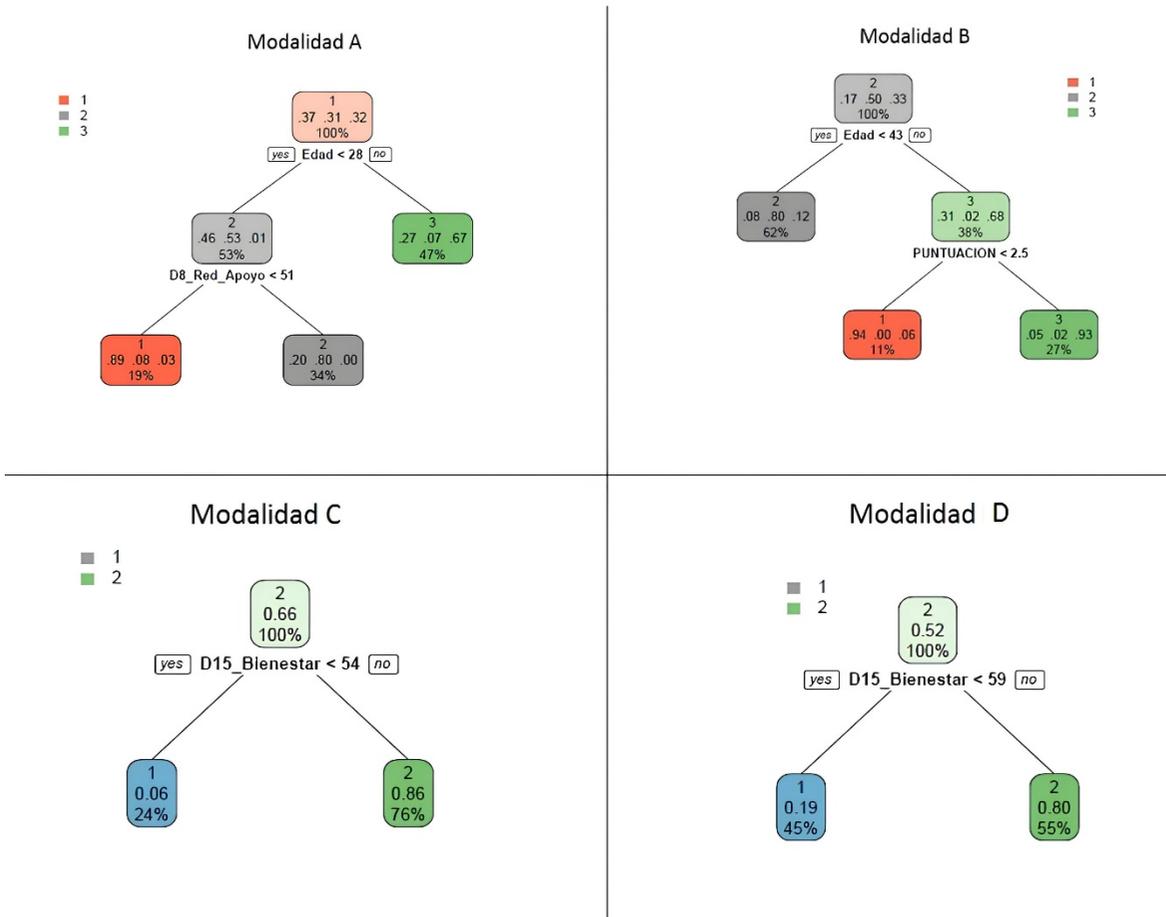
MODALIDAD D (Hombres)
 Con el conjunto de datos DS04 n=166, se aplican los algoritmos DT y RF a los datos de todos los hombres del estudio.

Tabla 13. Desempeño de los algoritmos DT y RF sobre los datos DS04, n=166.

Dataset	n	Correctas	Incorrectas	Accuracy	Algoritmo de ML	Conjunto de Dimensiones	Punto de corte
DS04 train	117	94	23	0.8034	DT	D15	<59
DS04 test	49	41	8	0.8367	DT		
DS04 train	117	117	0	1	RF	D8, D11, D15, D13	<35, <61.5, 59, <51
DS04 test	49	46	3	0.9388	RF		

Se muestran en la figura 5 los DT de cada una de las modalidades en el siguiente cuadro mostrando la clasificación por clúster, tres para las modalidades A y B y dos para C y D.

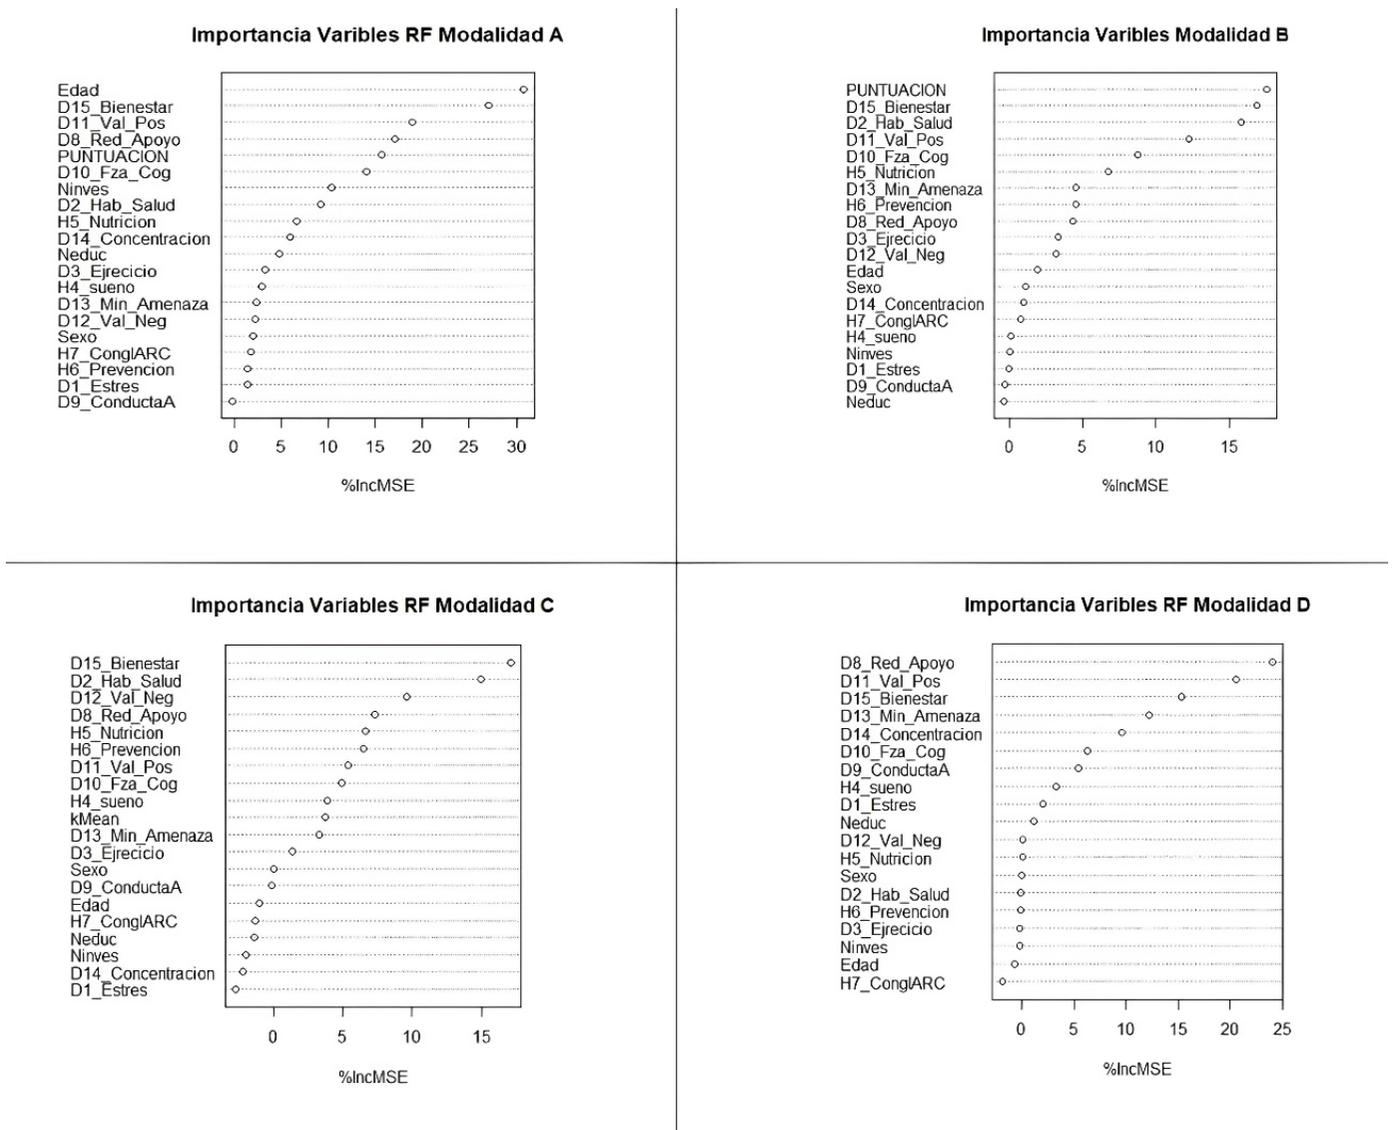
Figura 5. DT de cada una de las modalidades



De acuerdo con las tablas 10-13 del desempeño de los dataset en cada una de las modalidades, se observa que se tiene mayor exactitud en los modelos de RF. En el presen-

te cuadro se muestra la gráfica de cada modalidad con las variables en orden de importancia.

Figura 6. RF de cada una de las modalidades



En la tabla 14 se observan las variables relevantes en la exactitud del modelo, en el entrenamiento (70%), en la prueba (30%) y en la modalidad B para la validación.

Tabla 14. Elementos relevantes en cada modelo en orden de importancia

Clave	Descripción	Modalidad A		Modalidad B		Modalidad C		Modalidad D	
		DT	RF	DT	RF	DT	RF	DT	RF
Edad		0.75-	0.96-	0.83-	0.95-	0.8	1.0-	0.80	1.0-
D2_Hab_Salud	Hábitos de Salud	0.75	0.78	0.69 y	0.60 y	0.7	0.8	-	0.94
				0.38	0.66	5	7	0.84	

Clave	Descripción	Modalidad A		Modalidad B		Modalidad C		Modalidad D	
		DT	RF	DT	RF	DT	RF	DT	RF
		0.75-0.75	0.96-0.78	0.83-0.69 y 0.38	0.95-0.60 y 0.66	0.88-0.75	1.0-0.87	0.80-0.84	1.0-0.94
D8_Red_Apoyo	Red de Apoyo Social	2							1
D11_Val_Pos	Valoración Positiva		4		4				
D12_Val_Neg	Valoración Negativa						3		2
D14_Conc entr	Concentración en el Problema								4
D15_Bien estar	Bienestar Psicológico		1		2	1	1	1	3
CRAf/Puntuación	Conglomerado de Recursos de Afrontamiento		3	2	1				

Ya que los mejores modelos son los de RF y las modalidades C y D, se seleccionan las dimensiones más relevantes de estos, por el número de aparición y el orden en que se presentó su importancia. Así, D15_Bienestar psicológico, D8_Red de Apoyo Social, D2_Hábitos de Salud y D12_Valo-

ración Negativa serían las dimensiones en general, es decir, para los dos grupos más relevantes. En las tablas 15 y 16 se presentan los datos del clúster, se observa que, en las dos modalidades, el clúster uno es el de mayor riesgo.

Tabla 15. Dimensiones que determinan la diferencia entre clústeres del grupo DS03.
Marcado con * el más vulnerable

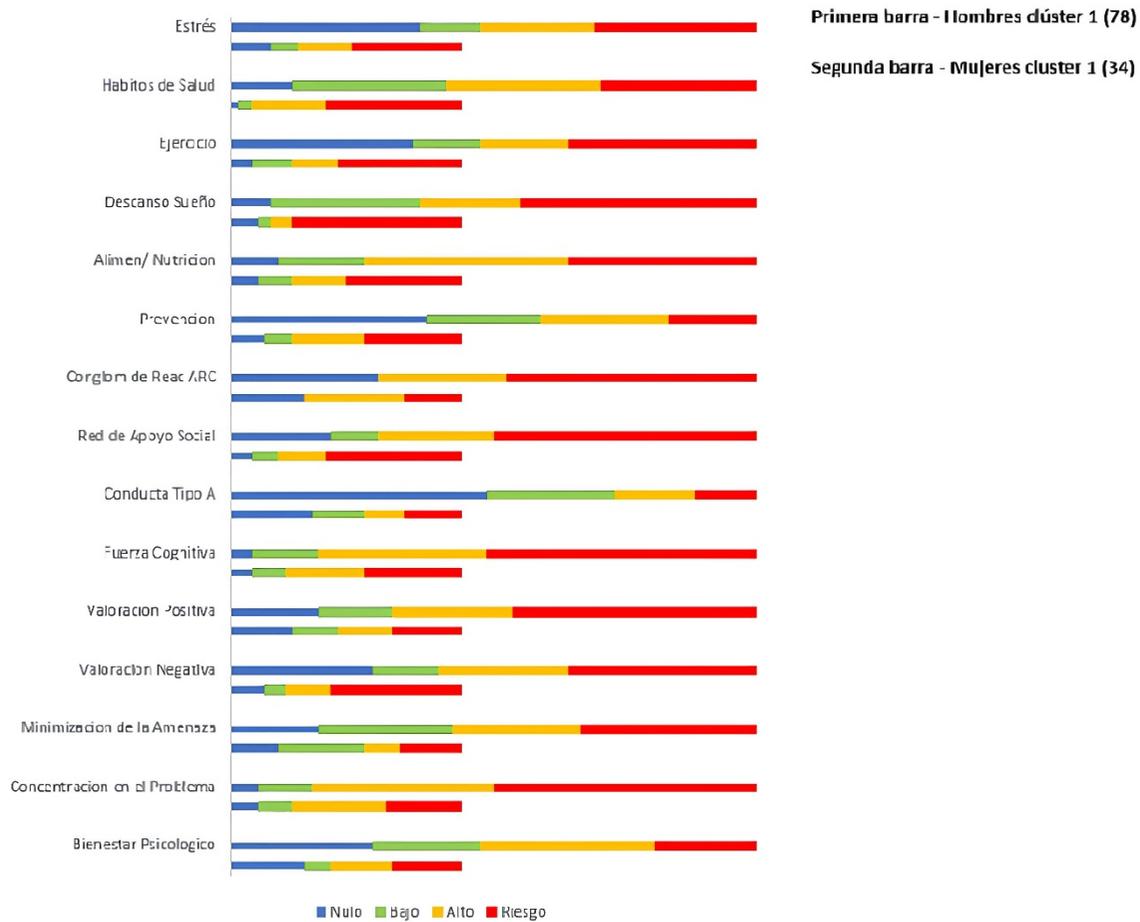
MUJERES		CLUSTER* UNO DS03 n=35	CLUSTER DOS DS03 n=68
D15_Bienestar	Bienestar Psicológico	53.5 <	>
D2_Hab_Salud	Hábitos de Salud	41 <	>
D12_Val_Neg	Valoración Negativa	69.5 >	<

Tabla 16. Dimensiones que determinan la diferencia entre clústeres del grupo DS04.
Marcado con * el más vulnerable

HOMBRES		CLUSTER* UNO DS03 n=35	CLUSTER DOS DS03 n=68
D8_Red_Apoyo	Red de Apoyo Social	35 <	>
D11_Val_Pos	Valoración Positiva	61.5 <	>
D15_Bienestar	Bienestar Psicológico	59 <	>
D13_Min_Amenaza	Minimización de la Amenaza	51 <	>

En la figura 7 se presenta la gráfica del grupo más vulnerable acorde a los baremos del estudio de Salud Mental.

Figura 7. Semaforización de Dimensiones del Grupo Vulnerable (cluster uno) con barras para hombres y mujeres



5. Discusión

La principal aportación de este estudio es extraer mediante técnicas de inteligencia artificial, información de cómo influye la perspectiva de género en los niveles de vulnerabilidad al estrés, evaluados a través del perfil de estrés de Nowack en diferentes grupos de personas con diversas características, como edad y ocupación. En Ortiz de Zárate-Alcarazo y Guevara-Gómez (2021) se comenta que, en muchos casos hay sectores donde las mujeres no tienen aún una representación equitativa, por lo que se dificulta el integrar dichos grupos a la identificación de perfiles utilizando la inteligencia artificial, una propuesta con los algoritmos de machine learning es el oversampling o el undersampling (Mohammed, Rawashdeh y Abdullah, 2020) cuyo objetivo es balancear los datos para entrenar modelos que produzcan mayor precisión en los resultados ante un número de datos menor de una de las clases, como sería el caso de falta de representatividad de las mujeres, sin embargo, en este trabajo, la integración de los tres estudios realizados previamente

nos permitió la incorporación de personas en distintos contextos. Un trabajo futuro para este estudio sería incrementar la muestra de mujeres y hombres con otras características, como por ejemplo, responsables del hogar.

Con respecto a los resultados del análisis no supervisado, Tabla 8 y 9, para cada modalidad descrita en la sección 3.3 inciso 3, observamos que los clústeres son efectivos para capturar la estructura de los datos ya que la varianza en los datos se explica principalmente por la agrupación en clústeres, es decir, los clústeres son representativos de las similitudes intrínsecas en los datos. Pero para el presente estudio de perspectiva de género, al aplicar el aprendizaje supervisado sobre la agrupación realizada, no se obtuvo la variable sexo como un discriminante entre grupos. En la modalidad A, tabla 10 es el Bienestar, la edad, el CRAf y la valoración positiva los elementos que el modelo de RF tuvo mejor desempeño con un 0.9686 en el entrenamiento y un 0.7848 en los datos de prueba. Cabe notar que el modelo DT presenta como discriminante la edad y red de apoyo teniendo una exactitud en

los datos de prueba similar al RF por lo que también muestra la importancia de la edad para diferenciar a los participantes de la muestra completa de 270 personas.

La importancia de los resultados de la modalidad B radica en que se agruparon los datos, mediante el algoritmo k-means, con el conjunto de datos del estudio C que contiene los puntos de corte de la prueba de perfil de estrés, misma que nos da la semaforización en cuatro niveles: nulo, bajo, alto y muy alto, para luego validarla con los datos de los otros estudios. En la tabla 11 observamos que la clasificación con DT es mala cuando se realiza la validación con datos totalmente ajenos al entrenamiento del modelo (accuracy de 0.37). Para el modelo RF da una mejor clasificación con los discriminantes que diferencian a los grupos que son la puntuación del CRAf que indica que para los que tuvieron una clasificación menor que 2.5, el bienestar psicológico, principalmente, marcan la mayor diferencia. Cabe notar que, de nuevo, la variable sexo no se presenta como relevante en el modelo.

Por lo anterior, al estudiar las modalidades C y D de datos separados para cada género, los modelos que se generaron tuvieron mayor exactitud (accuracy) donde las variables importantes son similares a las obtenidas en las otras modalidades solo que ahora segmentadas, es decir, vemos que en los modelos de DT la exactitud es del 74% para mujeres con los datos de la prueba y 83% para los hombres con la misma variable de Bienestar Psicológico, con una variante del punto de corte de 54 para las mujeres y 59 para los hombres. Esta dimensión de bienestar psicológico se obtuvo en todas las modalidades. Además, los modelos C y D tuvieron una exactitud del 100% con los datos de entrenamiento con el modelo de RF.

Así vemos que, para esta muestra, el clúster de mujeres con menores recursos para afrontar el estrés, es decir, el grupo vulnerable, es casi del 25% en cambio para los hombres es del doble. Otra diferencia significativa en este estudio fue la dimensión de red de apoyo, para las mujeres no fue determinante, mientras que para los hombres es considerada un buen recurso para lidiar con el estrés cotidiano. Se podría decir que esto coincide con el estudio de Pérez Ramos (2021) donde no se encontraron diferencias significativas entre hombres y mujeres al conciliar la vida familiar – laboral, pero en los resultados presentados por Menéndez-Espina Llosa, Aguiló-Tomás, Rodríguez-Suárez, Sáiz-Villar, R. y Lahseras-Díez (2019) se presentan diferencias en lo que respecta a la red de apoyo social, donde concluyen que las mujeres han desarrollado estrategias para cumplir exitosamente con las demandas laborales y familiares.

6. Conclusiones

Gracias al desarrollo tecnológico es posible manejar grandes volúmenes de información agilizando su procesamiento mediante algoritmos inteligentes. En este estudio se aplicaron algoritmos inteligentes de machine learning para identificar las diferentes dimensiones que marcan la diferencia entre los recursos de afrontamiento entre mujeres y hombres, lo que permitió efectuar un “semáforo” de acuerdo con la clasificación obtenida para así detectar a los participantes con menores recursos para afrontar el estrés y poder así establecer estrategias tempranas de prevención.

Los datos se recopilaron de tres estudios que utilizaron el cuestionario de perfil de estrés de Nowack. Se aplicaron tres técnicas de clasificación diferentes: una de aprendizaje no supervisado, k-means, y dos de aprendizaje supervisado: Árbol de decisión (DT) y bosque aleatorio (RF). Se encontró que la precisión del RF era la más alta, por lo que fue identificado como el mejor modelo. Los modelos sobre los conjuntos de datos de solo mujeres y solo hombres, tuvieron una exactitud del 100% en el entrenamiento que fue el 70% de la muestra y un 86.7% en la prueba para mujeres y de 93.9% para la prueba de la muestra de hombres. Dentro de las dimensiones más importantes de estos modelos están el bienestar psicológico, hábitos de salud, red de apoyo social, valoración positiva y valoración negativa.

Es importante notar que el bienestar psicológico marcó una diferencia en ambos grupos de hombres y mujeres cuando se analizaron por separado. Por lo que, se considera que las personas con un fuerte sentido de bienestar psicológico cuentan con mayores recursos para afrontar las situaciones cotidianas de estrés.

Cabe señalar que las muestras, aunque aleatorias, sólo representan una población pequeña, por lo que el peso de los resultados solo puede ser considerado como cualitativo, es decir, para generalizar y dar resultados cuantitativos, son necesarios mayores estudios.

Como trabajo a futuro se recomienda complementar el modelo, dando seguimiento al grupo vulnerable para obtener los ítems de las dimensiones relevantes que obtuvieron una puntuación alta de riesgo. Así también sería importante continuar con la aplicación de las técnicas de IA en esta y otras áreas de estudio equivalentes, ya que permite profundizar y obtener conocimiento (knowledge) y sabiduría (wisdom) de los datos, importante para una óptima toma de decisiones.

APÉNDICE A. Baremos semaforizados del Estudio C.

Se realizó lo siguiente:

1. Calificación del test de Nowack conforme a las instrucciones del manual
2. Asignación de grupos conforme a relación puntuación alta o baja, implica mejor recurso.
3. Preparar la información generando archivos tipo csv, delimitado con comas, para cada una de las dimensiones/grupo, agregar un campo de suma de las puntuaciones por individuo.

4. Generar un archivo csv con los datos de las dimensiones para registrar los valores máximo y mínimo de cada cluster y un archivo concentrador para registro del cluster asignado.
5. Diseñar y ejecutar el algoritmo para clasificar mediante aprendizaje no supervisado, clustering con k-means.
6. Realizar semaforización de cada participante para cada dimensión con los baremos obtenidos.

En la siguiente tabla A1 se muestran los baremos semaforizados obtenidos con el ML (Cluster) y el del manual de Nowack para puntuaciones bajas y para puntuaciones altas que implican buenos recursos para afrontar el estrés.

Baremos obtenidos con ML

		Clúster 1		Clúster 2		Clúster 3		Clúster 4	
		Valor Min	Valor Max						
Id	Dimensiones Puntuación baja implica mayores recursos								
D1_Estres	Puntuación de la dimensión Estrés	29.8	41.5	42.0	48.3	48.4	55.0	55.1	65.3
H7_ConglARC	Conglomerado de Reactivos ARC								
D9_ConductaA	Conducta Tipo A								
D12_Val_Neg	Valoración Negativa								

Id		Dimensiones Puntuación alta implica mayores recursos							
D2_Hab_Salud	Hábitos de Salud	58.2	65.5	52.4	57.7	46.5	51.8	36.0	46.2
D3_Ejercicio	Ejercicio								
H4_sueno	Descanso Sueño								
H5_Nutricion	Alimentación/ Nutrición								
H6_Prevenccion	Prevención								
D8_Red_Apoyo	Red de Apoyo Social								
D10_Fza_Cog	Fuerza Cognitiva								
D11_Val_Pos	Valoración Positiva								
D13_Min_Amenaza	Minimización de la Amenaza								
D14_Concentracion	Concentración en el Problema								
D15_Bienestar	Bienestar Psicológico								

Baremos del Manual

Perfil Alto		Perfil Medio		Perfil Bajo	
-------------	--	--------------	--	-------------	--

Valor Min Valor Max Valor Min Valor Max Valor Min Valor Max

Id		Dimensiones Puntuación baja implica mayores recursos							
D1_Estres	Puntuación de la dimensión Estrés	0.0	39.0	40.0	--	--	59.0	60.0	100
H7_ConglARC	Conglomerado de Reactivos ARC								
D9_ConductaA	Conducta Tipo A								
D12_Val_Neg	Valoración Negativa								

Id		Dimensiones Puntuación alta implica mayores recursos							
----	--	------------------------------------------------------	--	--	--	--	--	--	--

D2_Hab_Salud	Hábitos de Salud	60.0	100	40.0	--	--	59.0	0.0	39.0
D3_Ejercicio	Ejercicio								
H4_sueno	Descanso Sueño								
H5_Nutricion	Alimentación/ Nutrición								
H6_Prevenccion	Prevención								
D8_Red_Apo-yo	Red de Apoyo Social								
D10_Fza_Cog	Fuerza Cognitiva								
D11_Val_Pos	Valoración Positiva								
D13_Min_Ame-naza	Minimización de la Amenaza								
D14_Concen-tracion	Concentración en el Problema								
D15_Bienestar	Bienestar Psicológico								

APÉNDICE B. Algoritmos utilizados en el estudio.

Modelos del aprendizaje máquina, ML, para clasificación

Los principios de funcionamiento de cada algoritmo de aprendizaje automático se describen en las siguientes subsecciones.

K-Means

Se ha identificado como una de las clasificaciones de aprendizaje no supervisado más populares (Xindong Wu et.al,2008).

Es un algoritmo de aprendizaje no supervisado que particiona el conjunto de objetos en un determinado número de grupos de acuerdo con un criterio de optimización. En su implementación la convergencia a una agrupación óptima no está garantizada y para problemas grandes, se requiere de un mayor número de iteraciones. Para determinar el número de grupos o clústeres, se utiliza el algoritmo de Elbow (Bholowalia, 2014).

De acuerdo con la literatura especializada (Bottou & Bengio, 1995), (Pelleg et al., 2000) se pueden identificar cuatro pasos en el algoritmo:

Paso 1. Inicialización: Se definen un conjunto de objetos a particionar, el número de grupos y un centroide por cada grupo. Algunas implementaciones del algoritmo estándar determinan los centroides iniciales de forma

aleatoria; mientras que algunos otros procesan los datos y determinan los centroides mediante cálculos.

Paso 2. Clasificación: Para cada objeto de la base de datos, se calcula su distancia a cada centroide, se determina el centroide más cercano, y el objeto es incorporado al grupo relacionado con ese centroide.

Paso 3. Cálculo de centroides: Para cada grupo generado en el paso anterior se vuelve a calcular su centroide.

Paso 4. Condición de convergencia: Se han usado varias condiciones de convergencia, de las cuales las más utilizadas son las siguientes: converger cuando alcanza un número de iteraciones dado, converger cuando no existe un intercambio de objetos entre los grupos, o converger cuando la diferencia entre los centroides de dos iteraciones consecutivas es más pequeña que un umbral dado. Si la condición de convergencia no se satisface, se repiten los pasos dos, tres y cuatro del algoritmo.

Supongamos que el número de grupos sea K=3, la formulación matemática es un conjunto de n datos o instancias en el vector d-dimensional $D=\{x_1, \dots, x_n\} \in R^d$, donde el problema es determinar un conjunto de 3 centroides $C=\{c_1, c_2, c_3\} \in R^d$ donde se minimice la función del error, ecuación A1).

$$E(C) = \sum_{x \in D} \min_{k=1,2,3} \|x - C_k\|^2 \tag{A1}$$

Consiste en encontrar la partición de las n instancias en 3 grupos cuya distancia al centro sea la mínima.

Una métrica para evaluar el agrupamiento es el ratio que se obtiene al dividir la suma de cuadrados del error dentro del grupo (WCSS, Within-Cluster Sum of Squares) entre la suma de cuadrados total (TSS, Total Sum of Squares). Se conoce comúnmente como la “proporción de varianza explicada” o “ratio de varianza explicada”. Si el ratio es cercano a 1: Esto indica que los clusters son efectivos para capturar la estructura de los datos, y la varianza en los datos se explica principalmente por la agrupación en clusters. En este caso, los clusters son representativos de las similitudes intrínsecas en los datos. Si el ratio es cercano a 0: Esto sugiere que los clusters no están capturando bien la estructura de los datos y que la mayoría de la varianza en los datos no se explica mediante la agrupación en clusters. Puede ser un indicio de que el número de clusters (k) es demasiado bajo o que el algoritmo no ha logrado encontrar una buena agrupación.

Árbol de decisión, DT.

El aprendizaje supervisado de árboles de decisión es una de las técnicas de inferencia inductiva más usadas (Chi et al., 2019), (Bao et al., 2019). Se trata de un método para aproximar funciones de valores discretos que sea capaz de expresar hipótesis disyuntivas y que presenten capacidad en la discriminación del ruido de los datos en los ejemplos de entrenamiento.

De manera simple, los árboles de decisión permiten representar en forma gráfica una serie de reglas sobre la

decisión que debe tomarse en la asignación de un valor de salida a un registro dado, se usan comúnmente en el análisis para toma de decisión, ayudando a identificar los elementos relevantes para alcanzar una meta. Al crear un árbol completo que ha clasificado todo el conjunto de datos, una medida de “bondad”, es decir, qué tan bien los atributos se discriminan entre las clases, se empleó el índice de GINI, esta función mide la impureza “de un atributo con respecto a las clases”. Dadas las probabilidades para cada clase p_i , la función general de GINI, o medida de impureza se presenta en la ecuación 2).

$$\sum \sum p_i p_j = (\sum p_i)^2 = \sum p_i^2 = 1 - \sum p_i^2 \quad A2)$$

Random Forest o Bosque aleatorio, RF.

El clasificador de RF crea múltiples árboles de decisión a partir de un subconjunto seleccionado aleatoriamente del conjunto de datos de entrenamiento, posteriormente promedia los resultados de diferentes árboles de decisión. En teoría, una gran cantidad de árboles no correlacionados crearán predicciones más precisas que un árbol de decisión individual (Shaik & Srinivasan, 2019).

Dentro de las métricas para determinar un buen desempeño esta la exactitud, ecuación 3), que se obtiene de la clasificación correcta entre el total de elementos a clasificar.

$$Accuracy = \frac{\text{suma de correctas}}{\text{suma correctas e incorrectas}} \quad A3)$$

REFERENCIAS

- Alikhanian, H., Crawford, D., DeSouza, J. & Blohm, G. (2013). Adaptive cluster analysis approach for functional localization using magnetoencephalography. *Frontiers in Neuroscience*, 7, 73. <https://doi.org/10.3389/fnins.2013.00073>
- Alpaydin, E. (2021). Machine learning. Mit Press. ISBN 9780262542524.
- Bao, W., Lianju, N., & Yue, K. (2019). Integration of unsupervised and supervised machine learning algorithms for credit risk assessment. *Expert Systems with Applications*, 128, 301-315. <https://doi.org/10.1016/j.eswa.2019.02.033>.
- Bholowalia, P. & Kumar, A. (2014). EBK-means: A clustering technique based on elbow method and k-means in WSN. *International Journal of Computer Applications*, 105(9). <https://doi.org/10.1016/j.eswa.2019.02.033>
- Bottou, L., & Bengio, Y. (1994). Convergence properties of the k-means algorithms. *Advances in neural information processing systems*, 7. <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=cee30ccc0c341dfa-caac078f1560526ceae701df>
- Breiman, L. (2001). Statistical modeling: The two cultures (with comments and a rejoinder by the author). *Statistical science*, 16(3), 199-231. doi: 10.1214/ss/1009213726
- Bulteel, K., Tuerlinckx, F., Brose, A. & Ceulemans, E. (2016) Clustering Vector Autoregressive Models: Capturing Qualitative Differences in Within-Person Dynamics. *Front. Psychology*, 7, 1540. doi: 10.3389/fpsyg.2016.01540
- Cuadro, I. (2017). Salud mental con perspectiva de género. *Salud Pública de México*, 59(6), 601-602. <https://www.medigraphic.com/pdfs/salpubmex/sal-2017/sal176a.pdf>.
- Chi, S., Li, X., Tian, Y., Li, J., Kong, X., Ding, K., ... & Li, J. (2019). Semi-supervised learning to improve generalizability of risk prediction models. *Journal of biomedical informatics*, 92, 103117. <https://doi.org/10.1016/j.jbi.2019.103117>
- Chiogna, M. (1994). Probabilistic symbolic classifiers: an empirical comparison from a statistical perspective". *Workshop on Machine Learning and Statistics*. En Workshop of the Seventh European Conference on Machine Learning, Italy.
- D la Roca-Chiapas, D., María, J., Reyes-Pérez, V., Huerta-Lépez, E., Acosta-Gómez, M. G., Nowack, K., & Colunga-Rodríguez, C. (2019). Validation of Nowack's Stress Profile in Mexican university students. *Revista de Salud Pública*, 21(2), 146-153. <https://doi.org/10.15446/rsap.v21n2.73864>
- Elhai, J. D., & Montag, C. (2020). The compatibility of theoretical frameworks with machine learning analyses in psychological research. *Current Opinion in Psychology*, 36, 83-88. <https://doi.org/10.1016/j.copsyc.2020.05.002>
- Eraña-Díaz, M.L. (2016). *Evaluación de la Respuesta Defensiva y los Niveles de Cortisol*. Tesis de Maestría en Ciencias Cognitivas, Centro de Investigación Transdisciplinar en Psicología, Universidad Autónoma del Estado de Morelos. <https://drive.google.com/drive/folders/1dJNSSbo47JWdxB0kuWNGHZfPV2UlnhZN?usp=s>
- Eraña-Díaz, M. L., Cruz-Chávez, M. A., Juárez-Pérez, F., Enriquez-Urbano, J., Rivera-López, R. & Acosta-Flores, M. (2021). Optimization method to address psychosocial risks through adaptation of the multidimensional Knapsack Problem. *Mathematics*, 9(10), 1126. <https://doi.org/10.3390/math9101126>
- Esteban, M. (2006). La salud y el género: las ventajas de un enfoque antropológico y feminista. *Salud Colectiva*, 2(1), 9-20. http://www.scielo.org.ar/scielo.php?pid=S1851-82652006000100002&script=sci_arttext&tlng=en
- Huang, G. B., Zhou, H., Ding, X., & Zhang, R. (2011). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, 42(2), 513-529. doi: 10.1109/TSMCB.2011.2168604
- Josephy, H., Loeys, T. & Rosseel, Y. (2016) A Review of R-packages for Random-Intercept Probit Regression in Small Clusters. *Frontiers in Applied Mathematics and Statistics*, 2(18). doi: 10.3389/fams.2016.00018.
- Llanes-Castillo, A., Pérez-Rodríguez, P., Reyes-Valdéz, M. L., & Cervantes-López, M. J. (2022). Academic stress in undergraduate medical students. *Journal of Positive School Psychology*, 2802-2810. <https://journalppw.com/index.php/jpsp/article/view/7728>
- Maechler, M., Rousseeuw, P., Struyf, A., Hubert, M. & Hornik, K. (2017). *Cluster Analysis: Basics and Extensions*. R package version 2.0.6. <https://cir.nii.ac.jp/crid/1370290617548437512>
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research*, 9(1), 381-386.
- Menéndez-Espina, S., Llosa, J.A., Agulló-Tomás, E., Rodríguez-Suárez, J., Sáiz-Villar, R. and Lahseras-Díez, H.F. (2019). Job insecurity and mental health: The moderating role of coping strategies from a gender perspective. *Frontiers in Psychology*. 10(286). doi: 10.3389/fpsyg.2019.00286
- Milborrow, S. (2017). *rpart.plot: Plot 'rpart' Models: An Enhanced Version of 'plot.rpart'*. R package version 2.1.2. <https://CRAN.R-project.org/package=rpart.plot>
- Mitchell, T. M. (1997). Does machine learning really work? *AI magazine*, 18(3), 11. <https://doi.org/10.1609/aimag.v18i3.1303>

- Mohammed, R., Rawashdeh, J., & Abdullah, M. (2020). Machine learning with oversampling and undersampling techniques: overview study and experimental results. *IEEE: 11th international conference on information and communication systems*, pp. 243-248. doi: 10.1109/ICICS49469.2020.239556
- Nowack, K. M. (1999). *Stress profile*. Los Angeles, CA: Western Psychological Services.
- Ortiz de Zárate-Alcarazo, L. & Guevara-Gómez, A. (2021). Inteligencia artificial e igualdad de género. Un análisis comparado entre la UE, Suecia y España, *Fundación Alternativas*, 101, 1-81.
- Pelleg, D., & Moore, A. W. (2000). X-means: Extending k-means with efficient estimation of the number of clusters. *ICML*, 1, 727-734. <https://web.cs.dal.ca/~shepherd/courses/csci6403/clustering/xmeans.pdf>
- Pérez Ramos, S. P. (2021). 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*, 8. <https://doi.org/10.46377/dilemas.v8i.2568>
- Pilgrim, D. (2022). *Key concepts in mental health*. Sage Publications Ltd. <https://www.torrossa.com/en/resources/an/5409521>
- Pozos-Radilloa, E., Preciado-Serranoa, L., Plascencia-Campos, A., Morales-Fernández, A., & Valdez-López, R. (2021). Stress profile as a predictor of anxiety in Mexican medicine students. *International Journal of Early Childhood Special Education*, 30(3), 114. doi: 10.24205/03276716.2021.5013
- R Core Team (2013). R: A language and environment for statistical computing. *R Foundation for Statistical Computing*. Vienna, Austria. URL <http://www.R-project.org/>
- Rosales-Lagarde, A., Cubero-Rego, L., Menéndez-Conde, F., Rodríguez-Torres, E. E., Itzá-Ortiz, B., Martínez-Alcalá, C., ... & Eraña Díaz, M. L. (2023). Dissociation of Arousal Index Between REM and NREM Sleep in Elderly Adults with Cognitive Impairment, No Dementia: A Pilot Study. *Journal of Alzheimer's Disease*, 95(2), 477-491. doi: 10.3233/JAD-230101
- Sánchez-Villena, A. (2019). Uso de programas estadísticos libres para el análisis de datos: Jamovi, Jasp y R. *Revista perspectiva*, 20(1), 112-114. doi: <https://doi.org/10.33198/rp.v20i1.00026>
- Shaik, A.B., Srinivasan, S. (2019). A Brief Survey on Random Forest Ensembles in Classification Model. In: Bhattacharyya, S., Hassanien, A., Gupta, D., Khanna, A., Pan, I. (eds). *International Conference on Innovative Computing and Communications. Lecture Notes in Networks and Systems*, 56. Springer, Singapore. https://doi.org/10.1007/978-981-13-2354-6_27
- Therneau T, Atkinson B, Ripley B, Ripley MB. (2015). *rpart: Recursive Partitioning and Regression Trees*. R Package version 4.1-10. <http://cran.ma.ic.ac.uk/web/packages/rpart/rpart.pdf%5Cnhttps://cran.r-project.org/web/packages/rpart/rpart.pdf>
- Trujillano J, Sarria-Santamera, A., Esquerda, A., Badia, M., Palma, M., & March, J. (2008). Aproximación a la metodología basada en árboles de decisión (CART). Mortalidad hospitalaria del infarto agudo de miocardio. *Gaceta Sanitaria*, 22(1), 65-72 https://www.scielosp.org/article/ssm/content/raw/?resource_ssm_path=/media/assets/gs/v22n1/metodologica.pdf
- Tuszynski, J. (2014). *caTools: Tools: moving window statistics, GIF, Base64, ROC AUC, etc.*. R package version 1.17.1. <https://CRAN.R-project.org/package=caTools>.
- Wu, Q., Kumar, V., Ross, Q. J., Ghosh, J., Motoda, H., McLachlan, G.J., Ng, A., Liu, B., Philip, S.Y. (2008). Top 10 algorithms in data mining. Knowledge and information systems. *IEEE*, 14(1), 1-37. doi 10.1007/s10115-007-0114-2