

Detección de estrés por medio de redes neuronales artificiales en personal sanitario

Stress Diagnosis by Means of Artificial Neural Networks in Healthcare Personnel

Carlos Eduardo Cañedo Figueroa^{1*}, Xóchitl Duque Alarcón², María Teresa Silvia Tinoco Zamudio³

^{1,2} Universidad Autónoma de Chihuahua, Facultad de Medicina y Ciencias Biomédicas. Circuito Universitario 31109, Campus II C.P. 31125, Chihuahua, Chihuahua, México.

² Instituto de Seguridad y Servicios Sociales de los Trabajadores del Estado (ISSSTE), Ahuehueté 505, Ángel Trías, C.P. 31203, Chihuahua, Chihuahua, México,

^{1,3} Universidad Contemporánea de las Américas, Paseo de la República 3143, Las Américas, C.P. 58270, Morelia, Michoacán, México

*Correspondencia: ccanedo@uach.mx (Carlos Eduardo Cañedo Figueroa)

DOI: <https://doi.org/10.54167/tch.v18i3.1641>

Recibido: 05 de septiembre de 2024; Aceptado: 29 de noviembre de 2024

Publicado por la Universidad Autónoma de Chihuahua, a través de la Dirección de Investigación y Posgrado.

Resumen

En el presente documento se describe un estudio sobre la detección de estrés en profesionales sanitarios mediante el uso de redes neuronales artificiales. Se generó un modelo de red neuronal para clasificar datos relacionados con la detección oportuna de problemas de estrés en personal sanitario. Para ello, se obtuvieron datos clasificados utilizando la referencia del instrumento ProQOL, seguido de la aplicación de un modelo matemático para incremento de datos de forma artificial. Posteriormente, se aplicó el entrenamiento de redes neuronales artificiales modificando hiperparámetros y funciones de activación de forma experimental mediante el lenguaje de programación de Python. Los resultados obtenidos muestran una estimación de la capacidad de clasificación (F1-score) del 85.3, 67.5 y 89.3 % para la detección de Burnout, fatiga por compasión y estrés traumático secundarios, respectivamente. Se advierte la posibilidad de mejorar el desempeño de estos resultados incrementando los datos de entrenamiento. Debe resaltarse que esta es una investigación que involucra datos únicamente del contexto del hospital del ISSSTE de la ciudad de Chihuahua.

Palabras clave: estrés psicológico, aprendizaje supervisado de máquinas, detección.

Abstract

This paper presents the findings of a study investigating the potential of artificial neural networks in detecting stress in healthcare professionals. A neural network model was constructed for the purpose of classifying data pertaining to the timely detection of stress issues among healthcare personnel. The classification of data was conducted with reference to the ProQOL document. Subsequently, a mathematical model was employed to artificially increase the data set. Subsequently, the training of artificial neural networks was conducted through the experimental modification of hyperparameters and activation functions using the Python programming language. The results demonstrate an estimated classification ability (F1-score) of 85.3, 67.5, and 89.3 % for the detection of Burnout, compassion fatigue, and secondary traumatic stress, respectively. These results indicate potential for improvement in performance, with the option to expand the training data available. It should be noted that this investigation is limited to data from the ISSSTE hospital in Chihuahua City.

Keywords: psychological stress, supervised machine learning, detection.

1. Introducción

El estrés laboral ha tenido un impacto significativo en la salud mental de los trabajadores (Gamero, 2022). El sector salud ejemplifica este fenómeno, ya que la constante exposición de emergencias sanitarias, la alta demanda de servicios, escasez de insumos, ambientes laborales comprometidos y la combinación con situaciones personales elevan la presencia de estrés en los trabajadores del sector sanitario (Barral-Coral y Albán-Pérez, 2021).

Aunque cada trabajador puede experimentar diferentes afecciones a causa del estrés, en general, se manifiestan reacciones psicológicas y conductuales como ansiedad, depresión, agotamiento emocional, irritabilidad y mal humor, así como dificultad para concentrarse, aumento en el consumo de sustancias nocivas como el alcohol u otras sustancias, lo cual puede llegar a tener consecuencias graves como el suicidio (Agüero-Moreira *et al.*, 2022; Magaña-Salazar *et al.*, 2023).

El estrés puede provocar reacciones físicas como dolor de cabeza, desde un nivel leve a uno intenso, dolor de espalda, extremidades y zona estomacal, mareos, estreñimiento o diarrea, cansancio excesivo y trastornos del sueño. Estas afectaciones disminuyen la capacidad de atención al paciente, la sensibilidad y el rendimiento durante el horario laboral, lo que puede resultar en diagnósticos y tratamientos erróneos, afectando negativamente la calidad de la asistencia médica (Cajamarca-Chicaiza *et al.*, 2023; Magaña-Salazar *et al.*, 2023).

Los problemas de estrés en el personal de salud se pueden agrupar en: Burnout, fatiga por compasión (CF) y estrés traumático secundarios (STS). Un trabajador puede presentar uno o más de estas condiciones, de acuerdo con su personalidad y rasgos psicológicos (Hinderer *et al.*, 2014).

El Burnout afecta entre el 35 y 50 % del personal de salud, manifestándose en agotamiento emocional, despersonalización y baja realización personal. Los factores de riesgo incluyen largas jornadas laborales, falta de apoyo en insumos, así como relaciones laborales negativas. La CF impacta al 25-30 %, esta se relaciona con el estrés por brindar ayuda a los pacientes y, finalmente, el STS, que presenta síntomas similares al trastorno de estrés postraumático, el cual afecta al 7-10 % del personal sanitario,

debido a la exposición indirecta al trauma de los pacientes. Si bien, la incidencia del STS es mucho menor al BO y CF, esta condición puede incapacitar laboralmente de forma temporal o permanente a quien lo presente (Meadors *et al.*, 2010; Hinderer *et al.*, 2014; Barone y Zakriževska-Belogradova, 2022; Cajamarca-Chicaiza *et al.*, 2023).

Existen diversos métodos para la detección de problemas de estrés, tal como el análisis de variabilidad de la frecuencia cardiaca, medición de cortisol en saliva, termografía infrarroja, modelos de encuestas, inventario de síntomas y la intervención psicológica. Sin embargo, se vuelve complicado realizar un diagnóstico eficiente para todo el personal de una determinada zona laboral (Súarez-Carreño y Rosales, 2019). Con la llegada y uso cotidiano de algunos sistemas inteligentes como los dispositivos portátiles (relojes y pulseras de monitoreo fisiológico), en conjunto con los modelos de inteligencia artificial (IA) como las redes neuronales artificiales (ANN), algoritmos de regresión lineal (RL), algoritmos de agrupamiento de datos con el algoritmo KNN, entre otros, se han desarrollado modelos y dispositivos eficientes para la detección del estrés de forma genérica (Carreño y Rosales, 2019).

Se han desarrollado algunos dispositivos específicos para la detección de estrés basados en el estado mental. Campanella *et al.* (2023) describen el desarrollo de una banda a modo brazalete que tiene una eficiencia del 71 % de *F1 score* en la detección de estrés, lo cual se obtuvo mediante la implementación de algoritmos *random forest*, *svm* y regresión. Así como este caso, también se puede mencionar la detección de estrés mediante el análisis de señales EEG (Zhu *et al.*, 2023) y de visión (Siam *et al.*, 2023), en donde se muestra que se podría tener un rendimiento superior al 80 % en la detección de estrés, sin embargo, la implementación de estos sistemas involucra realizar la toma de muestras con dispositivos que puedan estar en contacto con la piel, o bien sistemas de cómputo con alto procesamiento de datos, como es el caso de algoritmos que trabajan con la toma de imágenes.

La necesidad de realizar clasificaciones dentro del espectro del estrés surge debido a que las afecciones pueden involucrar acciones contraproducentes si no se abordan de manera específica.

En el presente trabajo se describe un modelo de tres redes neuronales que clasifica datos obtenidos de una encuesta de 30 preguntas para determinar la presencia o ausencia de estrés a partir de la detección de Burnout, fatiga por compasión y/o estrés traumático secundario.

2. Materiales y métodos

Se generó una base de datos utilizando el instrumento "The Concise Manual for the Professional Quality of Life Scale" (Stamm, 2010), el cual consta de 30 preguntas (ver Tabla 1). El cuestionario se aplicó a 215 profesionales sanitarios del Instituto de Seguridad y Servicios Sociales de los Trabajadores del Estado (ISSSTE) Chihuahua, bajo consentimiento informado, cumpliendo con las normas de ética establecidas por la institución. Cada una de las preguntas se respondieron en escala de 1 a 5 según la percepción del participante, siendo 1 = nunca, 2 = en ocasiones, 3 = algunas veces, 4 = casi siempre y 5 = siempre. Se le pidió a cada participante que contestara las preguntas según las experiencias vividas en los últimos 30 días.

De los 215 participantes, 62 fueron de sexo masculino y 153 de sexo femenino, comprendiendo un rango de edades de los 18 a los 68 años. Los datos obtenidos de la encuesta se clasificaron mediante el instrumento de evaluación que se señala en Stamm (2010) (Ver Tabla 2).

Tabla 1. Preguntas de test obtenidas del documento ProQOL

Table 1. Test questions obtained from the ProQOL document.

#	Pregunta
1	¿Soy feliz?
2	¿Estoy preocupado por una o más personas a las que he ayudado o ayudo?
3	¿Estoy satisfecho de poder ayudar a la gente?
4	¿Me siento vinculado a otras personas, con ocasión de mi trabajo?
5	¿Me sobresaltan los sonidos inesperados?
6	¿Me siento fortalecido después de trabajar con las personas a las que he ayudado?
7	¿Encuentro difícil separar mi vida personal de mi vida profesional?
8	¿Pierdo el sueño por las experiencias traumáticas de las personas a las que he ayudado?
9	¿Creo que he sido afectado negativamente por las experiencias traumáticas de aquellos a quienes he ayudado?
10	¿Me siento 'atrapado' por mi trabajo?
11	¿Debido a mi profesión tengo la sensación de estar al límite en varias cosas?
12	¿Me gusta trabajar ayudando a la gente?
13	¿Me siento deprimido como resultado de mi trabajo?
14	¿Me siento como si fuera yo el que experimenta el trauma de alguien al que he ayudado?
15	¿Tengo creencias (religiosas, espirituales u otras) que me apoyan en mi trabajo profesional?
16	¿Estoy satisfecho por cómo soy capaz de mantenerme al día en las técnicas y procedimientos de asistencia médica?
17	¿Soy la persona que siempre he querido ser?
18	¿Mi trabajo me hace sentirme satisfecho?
19	¿Por causa de mi trabajo me siento agotado?
20	¿Tengo pensamientos de satisfacción acerca de las personas a las que he ayudado y sobre cómo he podido ayudarles?
21	¿Me siento abrumado por la cantidad y tipo de trabajo que tengo que afrontar?
22	¿Creo que puedo hacer cambiar las cosas a través de mi trabajo?
23	¿Evito ciertas actividades o situaciones porque me recuerdan a las experiencias espantosas de la gente a la que he ayudado?
24	¿Planeo continuar con mi trabajo por muchos años?
25	¿Como resultado de mi trabajo profesional, tengo pensamientos molestos, repentinos, indeseados?
26	¿Me siento 'estancado' (sin saber qué hacer) por cómo funciona el sistema sanitario?
27	¿Considero que soy un buen profesional?
28	¿No puedo recordar determinados acontecimientos relacionados con víctimas muy traumáticas?
29	¿Soy una persona demasiado sensible?
30	¿Estoy feliz por haber elegido hacer este trabajo?

Tabla 2. Escala de valoración según las respuestas del cuestionario de la tabla 1
Table 2. Rating scale is based on the responses provided in Table 1.

La suma de las preguntas relacionadas con la satisfacción por compasión	Nivel de satisfacción por compasión
22 o menos	Bajo
Entre 23 y 41	Moderado
42 o superior	Alto

Las preguntas relacionadas a la satisfacción por compasión son 3, 6, 12, 16, 18, 20, 22, 24, 27 y 30.

La suma de las preguntas relacionadas con el Burnout	Nivel de Burnout
22 o menos	Bajo
Entre 23 y 41	Moderado
42 o superior	Alto

Las preguntas relacionadas el Burnout son 1*, 4*, 8, 10 15*, 17*, 19, 21, 26, 29*.

Las preguntas indicadas con asterisco (*) deben contemplar la puntuación a la inversa.

En donde 0=0, 1=5, 2=4, 3=3, 4=2 y 5=1 (Lado izquierdo de la igualdad, respuesta del paciente, lado derecho, puntuación que le corresponde)

La suma de las preguntas relacionadas con el estrés traumático secundario	Nivel de estrés traumático secundario
22 o menos	Bajo
Entre 23 y 41	Moderado
42 o superior	Alto

Las preguntas relacionadas con el estrés traumático secundario son 2, 5, 7, 9, 11, 13, 14, 23, 25 y 28.

Por cada una de las clases (satisfacción por compasión, Burnout y estrés traumático secundario) se obtuvieron los datos que se indican en la Tabla 3.

Tabla 3. Niveles obtenidos pertenecientes a cada categoría.
Table 3. Levels obtained for each category.

Clase	Alto	Moderado	Bajo
Burnout	0	110	105
STS	1	84	130
CS	119	93	3

2.1 Aumento de datos y conjuntos de entrenamiento

Se aplicó la segmentación de los datos tomando 30 vectores característicos de forma aleatoria, los cuales se utilizaron para el entrenamiento de las redes neuronales. Se generaron dos conjuntos de

datos, 30 para entrenamiento (E) y 185 que se utilizarán para validar los algoritmos (V). Si bien es posible entrenar algoritmos de *machine learning* con estos datos, se optó por incrementar los datos aplicando de forma aleatoria y experimental valores de 0.0015 hasta 0.999 a cada una de las características para el conjunto de entrenamiento, esto con la finalidad de incrementar la variabilidad que se tienen en los datos y no generar sobre ajuste por los vectores que se recabaron. Esto es necesario implementar debido a que la base de datos corresponde únicamente a la zona del ISSSTE Chihuahua, por lo que se busca implementar ruido en la señal para generalizar el procesamiento de datos en la red. Al seleccionar una cantidad pequeña de información, se planteó el tener solo dos clases, presencia o no presencia de cada uno de los tipos de estrés. Se obtuvo la cantidad de 234 datos para cada una de las clases, 117 con presencia del tipo de estrés y 117 sin presencia del mismo. A este conjunto de datos se le puede referenciar como (AE).

2.2 Diseño y desarrollo de redes neuronales

Las redes neuronales son modelos matemáticos que intentan simular el funcionamiento de la mente humana para la toma de decisiones. Pueden llegar a tener cierto criterio de razonamiento con base en diversos datos obtenidos del entorno. Estos modelos se basan en la teoría de la computación neuronal, que postula que la información se procesa en el cerebro a través de un sistema de neuronas interconectadas que pueden definir una o múltiples respuestas según los datos que se tengan como entradas al sistema algorítmico (García-Chávez y Cañedo-Figueroa, 2021; Valdez-Hernández *et al.*, 2022; Sarwar y Saadeh, 2023).

Para el desarrollo de este trabajo, se realizó una codificación binaria del estilo “One hot” para cada una de las salidas de los elementos del conjunto AE , tal como se muestra en la Tabla 4, esto debido a que se generó una red neuronal de tipo “totalmente conectada hacia adelante” (*feedforward*, por su terminología en inglés) para cada una de las clases definidas.

Tabla 4. Codificación modo “One hot” para la detección de problemas.

Table 4. “One hot” coding mode for problem detection.

Clase	Predicción	Codificación
Burnout (burnout)	Sin presencia de Burnout	[1, 0]
	Con presencia de Burnout	[0, 1]
Estrés traumático secundario (STS)	Sin presencia de STS	[1, 0]
	Con presencia de STS	[0, 1]
Estrés por satisfacción de la compasión (CS)	Sin presencia de CS	[1, 0]
	Con presencia de CS	[0, 1]

La codificación “One hot” generó la formación de un conjunto de vectores con la forma que se muestra en la Ecuación 1. En donde C corresponde a la clase a la que el vector pertenece, teniendo valores $C = \{\text{Burnout, STS, CS}\}$, i es la posición del ID según corresponda a la clase, teniendo valores de $i = \{1,2,3... I\}$, siendo I el número máximo de elemento por cada clase (117), α representa a la respuesta obtenida en el cuestionario aplicado, por lo que $\alpha = \{1,2,3,4,5\}$ en la respuesta según corresponda el subíndice y $R = \{\text{respuesta según la codificación de la Tabla 7}\}$.

$$V_{C,i} = [\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_{30}, (R)] \quad (\text{Ec. 1})$$

Una vez teniendo cada uno de los datos de las encuestas con sus respectivas salidas (VC,i) se desarrolló un conjunto de 3 redes neuronales mediante el lenguaje de programación de Python 3.9. Para ello, se utilizaron las librerías de *TensorFlow* y *Keras* (Hamil et al., 2022; Nath Mohalder et al., 2024). Las estructuras de las redes constaron de 30 neuronas de entrada según la cantidad de entradas, 5 neuronas en la capa intermedia con la función de activación *sigmoidal* y 2 neuronas de salida. Todas fueron configuradas en su entrenamiento mediante la función de activación *softmax* (Deng et al., 2023).

Esta estructura se constituyó para las tres redes neuronales (Fig. 9), en donde la capa de entrada corresponde a los datos obtenidos y ordenados de la encuesta de 30 preguntas, las capas ocultas siguen la estructura de la sumatoria de los pesos de cada neurona por la entrada. Posteriormente, pasa por la función *sigmoidal*, para después pasar por la función *softmax* y obtener los resultados mediante la codificación *One hot* (Ver Tabla 4).

Para el entrenamiento de las redes neuronales se utilizó el optimizador *Adam*, un factor de aprendizaje de 0.001, una función de pérdida *crossentropy*, 900 épocas y bloques de 130 para garantizar la toma de valores aleatorios en su entrenamiento mediante la técnica de retropropagación (*backpropagation*, por su traducción del inglés). Estos hiperparámetros se seleccionaron debido a que se iteraron las neuronas de la capa intermedia, incrementando y decrementado de 3 a 10 neuronas, realizando entrenamientos por 900 épocas en cada incremento o decremento, con manejo de pesos iniciales aleatorios en escala de 0 a 1. De igual manera, se realizaron pruebas con los factores de aprendizaje, variando ese valor de 0.0001 a 0.01. Se generó un ciclo de entrenamiento actualizando estos hiperparámetros de forma experimental en incrementos según los rangos experimentales establecidos. La estructura descrita fue la que mejores resultados mostró durante el entrenamiento.

La estructura general del entrenamiento utilizado se puede observar en la Fig. 2. En donde se indica que todas las entradas del conjunto entrenamiento de cada clase (CS, STS y Burnout) son multiplicadas por pesos aleatorios iniciales, los cuales originarían una respuesta obtenida del sistema neuronal. Posteriormente, estas respuestas se comparan con la respuesta que realmente se desea obtener por cada uno de los vectores característicos.

En caso de tener un error diferente de cero, se aplican las ecuaciones (2) y (3). En donde se describe que, para obtener los pesos nuevos de cada peso sináptico, se debe considerar el valor anterior y restar el resultado de la multiplicación del factor de aprendizaje η por el incremento dado por el error de cada una de las salidas de las neuronas, denotado por T y oculta o salida, siendo cada uno de los términos referenciales a las neuronas específicas de la capa oculta o capa de salida visto en la Fig. 1.

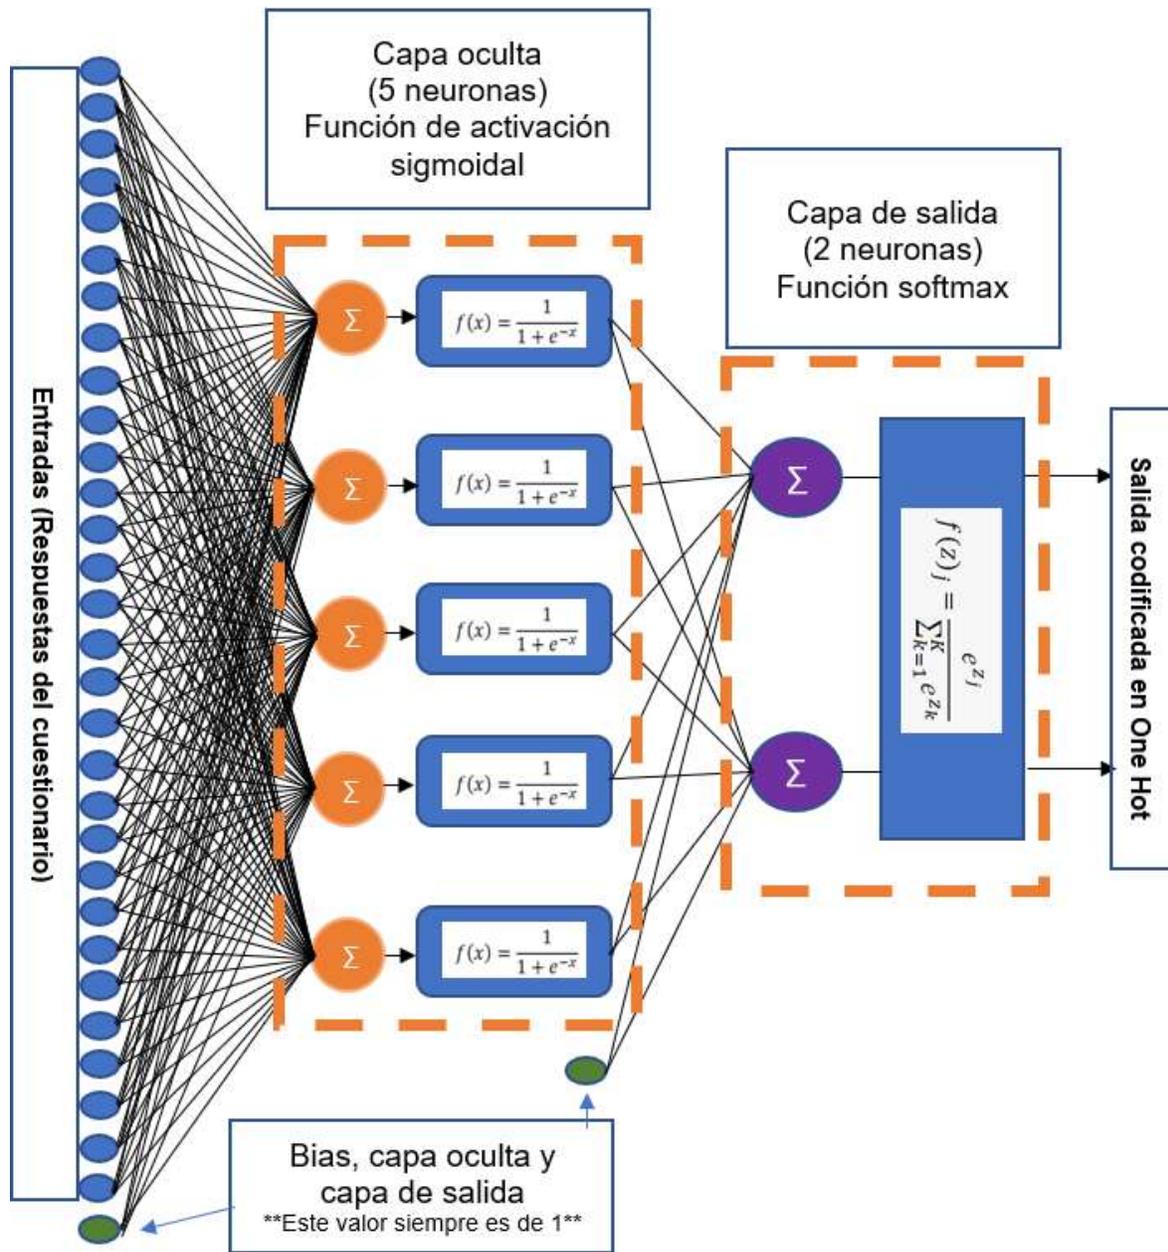


Figura 1. Estructura general de las redes neuronales generadas. Fuente: Esquema elaborado por el autor.

Figure 1. General structure of the generated neural networks. Source: Scheme drawn by the author.

$$nuevoW_{oculta_salida} = anteriorW_{oculta_salida} - \eta \Delta W_{oculta_salida} \quad (\text{Ec. 2})$$

$$\Delta W_{oculta_salida} = -E_{salida} * \phi(Z_{salida}) * (1 - \phi(Z_{salida})) * S_{oculta}^T \quad (\text{Ec. 3})$$

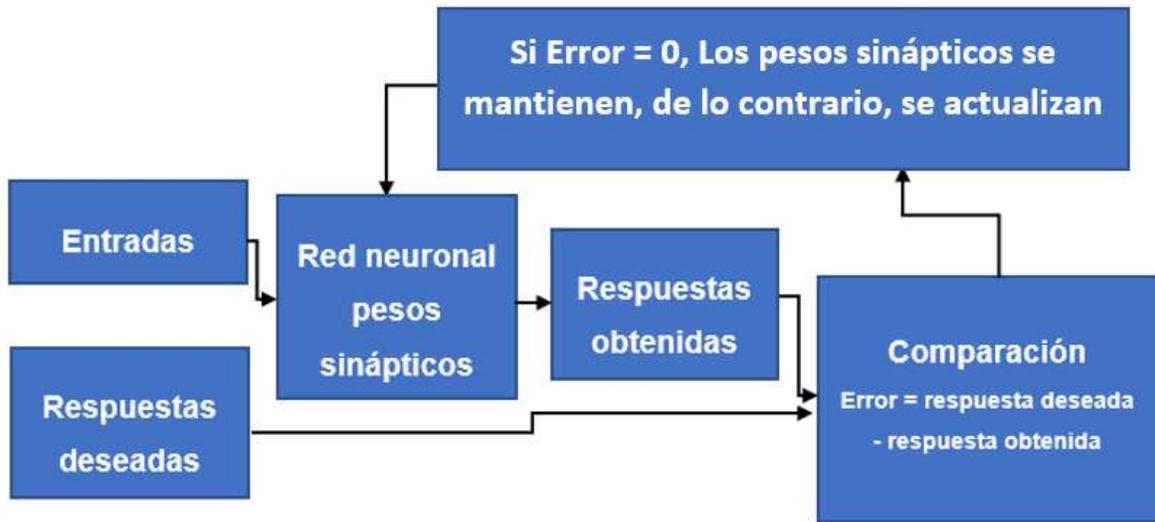


Figura 2. Estructura de entrenamiento de las redes neuronales. Fuente: Esquema elaborado por el autor
Figure 2. Training structure of a neural network. Source: Scheme developed by the author

2.3 Evaluación de algoritmos

Se examinó el desempeño de las tres redes neuronales diseñadas para clasificar datos en las tres categorías: síndrome de trauma secundario (STS), Burnout y satisfacción por compasión (CS). Para llevar a cabo esta evaluación, se recurrió a la implementación de métricas estándares como el *F1 score*, la precisión y la exhaustividad (*recall*), para lo cual se utilizaron los datos que se muestran en la Fig. 3.

Clase Burnout			Clase CS			Clase STS		
Predicción	90	1	51	28	100	12		
	30	63	21	84	12	60		
	Real			Real			Real	

Figura 3. Matrices de confusión obtenidas por los tres algoritmos generados. Fuente: Esquema elaborado por el autor.

Figure 3. Confusion matrices obtained by the three generated algorithms. Source: Scheme developed by the autor.

Las métricas derivadas de las matrices de confusión proporcionan una evaluación cuantitativa del desempeño del modelo, por lo tanto, para esta investigación se utilizaron:

Precisión: Esta métrica (Ecuación 4) se calcula como la proporción de verdaderos positivos (VP) respecto al total de elementos clasificados como positivos (la suma de verdaderos positivos y falsos positivos (FP)). Proporciona una medida de la exactitud con la que el modelo realiza predicciones positivas.

$$Precisión = \frac{VP}{VP+FP} \quad (\text{Ec. 4})$$

Exhaustividad (*recall*): También conocida como sensibilidad (Ecuación 5), mide la capacidad del modelo para identificar correctamente todas las instancias reales de la clase positiva. En donde FN se refiere a los falsos negativos obtenidos.

$$Recall = \frac{VP}{VP+FN} \quad (\text{Ec. 5})$$

F1 Score: Esta métrica combina la precisión y el *recall* en un solo indicador que mide la precisión y la robustez del modelo (Ecuación 6). El *F1 score* es especialmente útil cuando las distribuciones de las clases son desiguales.

$$F1 = 2 * \frac{Precisión * Recall}{Precisión + Recall} \quad (\text{Ec. 6})$$

En el desarrollo de este proyecto de investigación se logró generar un conjunto de tres redes neuronales artificiales para la detección de tres problemas de estrés predominantes en la población de trabajadores de la salud (Burnout, estrés traumático secundario y estrés de satisfacción por compasión). Sin embargo, los resultados obtenidos fueron evaluados tomando como referencia a 215 trabajadores sanitarios, por lo que es necesario realizar la intervención en un centro médico para corroborar lo planteado en este estudio.

Es importante resaltar que los datos obtenidos y utilizados para el entrenamiento y validación de los algoritmos generados fueron adquiridos en la unidad del ISSSTE de la ciudad de Chihuahua, México, por medio de consentimiento informado de los participantes, bajo el protocolo del comité de ética aprobado por la dirección de la Secretaría de Salud del Estado de Chihuahua. Por lo tanto, es posible que existan sesgos si se llegasen a comparar con algunas otras regiones del país o de instancias internacionales.

La aplicación generada se puede ejecutar en cualquier entorno de Windows que tenga instalado el software Python 3.9 y las librerías de *tkinter* y *TensorFlow*. Lamentablemente, el recurso generado no se ha logrado convertir en un programa ejecutable para usuario; sin embargo, en el siguiente enlace se puede descargar la aplicación, la base de datos utilizada y los modelos de redes neuronales pre entrenadas: https://github.com/eduardcan/Medical_estres.

3. Resultados y discusión

Utilizando las Ecuaciones 4, 5 y 6, se calcularon las métricas para cada una de las clases evaluadas, obteniendo los resultados que se muestran en la Tabla 5, en donde se muestran variaciones significativas en el rendimiento entre las clases. La clase Burnout presenta una precisión de 0.989, lo que sugiere que la mayoría de las predicciones de Burnout son acertadas. Sin embargo, un menor nivel de *recall* (0.750) revela que el modelo falló en identificar un número significativo de casos reales de Burnout, impactando negativamente en su puntuación F1, dejando una métrica de 0.853.

En la categoría de CS se registran niveles moderados de precisión y recuperación, resultando con la métrica *F1 Score* de menor densidad de los algoritmos generados, quedando con 0.675. Este resultado refleja una eficiencia menor en el balance entre la exactitud de las predicciones y la habilidad del modelo para identificar todos los casos auténticos.

Finalmente, para la categoría de STS se demostró el rendimiento más equilibrado, alcanzando el valor de 0.893 en *F1 Score*. Esto demuestra la capacidad notable del modelo para predecir y reconocer condiciones STS de manera eficiente, manteniendo un equilibrio óptimo entre minimizar falsos positivos y detectar la mayoría de los casos verdaderos.

Tabla 5. Representación de los resultados obtenidos por las tres redes neuronales.

Table 5. Representation of the results obtained by the three neural networks.

Clase	VP	FP	FN	VN	Precisión	Recall	F1 Score
Burnout	90	1	30	63	0.989	0.750	0.853
CS	51	28	21	84	0.646	0.708	0.675
STS	100	12	12	60	0.893	0.893	0.893

En comparación, los estudios de otros autores (ver Tabla 6) han logrado métricas de rendimiento en aplicaciones especializadas utilizando técnicas como Redes Neuronales Artificiales, Redes Neuronales Convolucionales, y combinaciones de lenguaje natural con *Machine Learning*.

Es preciso destacar que, en la revisión de literatura, los autores investigados realizan la detección de estrés de forma general o únicamente de un tipo en específico; además, los datos utilizados involucran repositorios de Internet, incluyendo datos de sensores de contacto o imágenes.

Tabla 6. Resultados de otros investigadores con diversas bases de datos y métodos.**Table 6.** Results from other researchers with different databases and methods.

Autor	Clases	Modelos	Precisión	Recall	F1 Score	Datos
(Sarwar y Saadeh, 2023)	STS	Red neuronal artificial (ANN)	0.932		0.97	Fotopleetismografía
(Li y Liu, 2020)	Estrés crónico	Red neuronal convolucional (CNN)	0.995		0.9766	Repositorio de machine learning utilizando rostros en video
(Nijhawan et al., 2022)	Estrés social	Árboles de decisión (<i>decision trees</i>)	0.94			Evaluación de emociones y sentimientos expresadas mediante sitios web
(Kumari y Das, 2023)	Detección de estrés	Modelo de lenguaje natural y técnicas de <i>machine learning</i>	0.90	0.94	0.92	Análisis de datos de plataformas sociales
(Sandoval Rodríguez-Bermejo, 2019)	Detección de estrés	Redes neuronales convolucionales	0.96			Imágenes térmicas
(Navarro Cantos, 2018)	Ansiedad	Máquina de soporte vectorial K. Vecinos más cercanos. Árboles de decisión	0.80 0.80 0.75			Resistencia cutánea mediante sensor GSR

4. Conclusiones

En este artículo se presenta el desarrollo de un conjunto de tres redes neuronales mediante el lenguaje de programación Python para la detección de estrés en personal sanitario mediante una encuesta, tomando todos los factores del manual ProQOL. De acuerdo con los resultados obtenidos, se puede observar que el hecho de tener límites rígidos en la detección de los tres tipos de estrés analizados (estrés traumático secundarios, Burnout y satisfacción por la compasión) involucra que pueda existir una detección ambigua, ya que al identificar cualquier tipo de estrés con una puntuación pequeña en la escala mostrada en la Tabla 2, puede desembocar en el avance del estrés. Por lo que el presente trabajo utiliza todos los elementos relacionados con los tres tipos de estrés.

Cabe resaltar la necesidad de adquirir una mayor cantidad de datos y contemplar diferentes regiones para mejorar las métricas obtenidas.

Agradecimientos

Agradecemos a la Universidad Autónoma de Chihuahua, a la Universidad Contemporánea de Las Américas y a los creadores del repositorio de la base de datos del ISSSTE Chihuahua.

Conflicto de interés

Los autores de este artículo declaran no tener ningún conflicto de interés.

5. Referencias

- Agüero-Moreira, M., Pérez-Fernández, T., & Troz-Parra, I.P. (2022). Principales patologías psíquicas que generó el estrés laboral durante la pandemia de COVID -19, en el personal de salud. *Revista Médica Sinergia*, 7(4): e793. <https://doi.org/10.31434/rms.v7i4.793>
- Barone, L., & Zakriževska-Belogradova, M. (2022). PROFESSIONAL QULAITY OF LIFE AND BURN OUT AMONG PSYSIOTHERAPISTS IN LATAVIA. *Proceedings of CBU in Social Sciences*, 3: 7-12. <https://doi.org/10.12955/pss.v3.298>
- Barral-Coral, S., & Albán-Pérez, G. (2021). Impacto de los factores de riesgo psicosociales, estrés y síndrome de burnout sobre la satisfacción laboral en personal administrativo de nivel técnico-gerencial en salud. *UDA AKADEM*, 8: 268–293. <https://doi.org/10.33324/udaakadem.vi8.444>
- Cajamarca-Chicaiza, K. M., Aimara Guaita, L. V., Sánchez Ocaña, M. E., Acosta Yansapanta, E. A., & Llanos Gaibor, J. L. (2023). Estrés y manifestaciones psicosomáticas en el personal de salud: Stress and psychosomatic manifestations in health care personnel. *LATAM Revista Latinoamericana De Ciencias Sociales Y Humanidades*, 4(1), 2569–2582. <https://doi.org/10.56712/latam.v4i1.438>
- Campanella, S., Altaleb, A., Belli, A., Pierleoni, P., & Palma, L. (2023). A Method for Stress Detection Using Empatica E4 Bracelet and Machine-Learning Techniques. *Sensors*, 23(7): 3565. <https://doi.org/10.3390/s23073565>
- Deng, Y., Li, Z., & Song, Z. (2023). Attention Scheme Inspired Softmax Regression. Cornell University <http://arxiv.org/abs/2304.10411>
- Gamero, M. (2022). SALUD MENTAL Y BIENESTAR PSICOLÓGICO EN TRABAJADORES MINEROS. UNA REVISIÓN SISTEMÁTICA. *PSICOLOGÍA UNEMI*, 6(11): 192-207. <https://doi.org/10.29076/issn.2602-8379vol6iss11.2022pp192-207p>
- García Chávez, H., & Cañedo Figueroa, C. (2021). Diseño de algoritmo compuesto por Machine Learning y un modelo probabilístico para la detección de diabetes. Vol. 8 Núm. 1: Memorias del XLIV Congreso Nacional de Ingeniería Biomédica. <https://memoriascnib.mx/index.php/memorias/article/view/828>
- Hamil, H., Zidelmal, Z., Azzaz, M. S., Sakhi, S., Kaibou, R., Djilali, S., & Ould Abdeslam, D. (2022). Design of a secured telehealth system based on multiple biosignals diagnosis and classification for IoT application. *Expert Systems (Special Issue)*, 39(4): e12765. <https://doi.org/10.1111/exsy.12765>

- Hinderer, K. A., VonRueden, K. T., Friedmann, E., McQuillan, K. A., Gilmore, R., Kramer, B., & Murray, M. (2014). Burnout, compassion fatigue, compassion satisfaction, and secondary traumatic stress in trauma nurses. *Journal of Trauma Nursing*, 21(4): 160–169. <https://doi.org/10.1097/JTN.0000000000000055>
- Kumari, K., & Das, S. (2023). Stress Detection System using Natural Language Processing and Machine Learning Techniques. *CEUR Workshop Proceedings*, 3416, 45–55. https://ceur-ws.org/Vol-3416/paper_6.pdf
- Li, R., & Liu, Z. (2020). Stress detection using deep neural networks. *BMC Medical Informatics and Decision Making*, 20(11): 285. <https://doi.org/10.1186/s12911-020-01299-4>
- Magaña-Salazar, M. Y., Méndez de Robles, S. J., & Martínez-Díaz, S. (2023). Estrés laboral y salud mental del personal de primera línea en la atención de la COVID-19. *Alerta, Revista Científica Del Instituto Nacional de Salud*. <https://api.semanticscholar.org/CorpusID:256490428>
- Meadors, P., Lamson, A., Swanson, M., White, M., & Sira, N. (2010). Secondary traumatization in pediatric healthcare providers: compassion fatigue, burnout, and secondary traumatic stress. *OMEGA - Journal of Death and Dying*, 60(2): 103–128. <https://doi.org/10.2190/om.60.2.a>
- Nath Mohalder, R., Alam Hossain, M., & Hossain, N. (2024). Classifying the Supervised Machine Learning and Comparing the Performances of the Algorithms. *International Journal of Advanced Research*, 12(01), 422–438. <https://doi.org/10.21474/ijar01/18138>
- Navarro Cantos, C. (2018). Detección de los niveles de estrés y ansiedad en pilotos aplicando técnicas de Machine Learning. (Trabajo Fin de Grado Inédito). Universidad de Sevilla, Sevilla. <https://idus.us.es/handle/11441/84880>
- Nijhawan, T., Attigeri, G., & Ananthakrishna, T. (2022). Stress detection using natural language processing and machine learning over social interactions. *Journal of Big Data*, 9: 33. <https://doi.org/10.1186/s40537-022-00575-6>
- Sandoval Rodríguez-Bermejo, D. (2019). Diseño E Implementación De Un Sistema Para La Detección Del Estrés Mediante Redes Neuronales Convolucionales a Partir De Imágenes Térmicas. Tesis de maestría Ingeniería de Telecomunicación. UPM. <https://oa.upm.es/57804/>
- Sarwar, M. A., & Saadeh, W. (2023). Monitoring Blood Volume Decomposition State for Traumatic Stress-Induced Hemorrhage via Wearable Sensing and Ensemble Learning. 2023 IEEE International Symposium on Circuits and Systems (ISCAS), 1–5. <https://doi.org/10.1109/ISCAS46773.2023.10181387>
- Siam, A. I., Gamel, S. A., & Talaat, F. M. (2023). Automatic stress detection in car drivers based on non-invasive physiological signals using machine learning techniques. *Neural Computing and Applications*, 35(17): 12891–12904. <https://doi.org/10.1007/s00521-023-08428-w>
- Stamm, B. H. (2010). The concise ProQOL manual. Pocatello, ID: ProQOL. Org, 78. <https://www.illinoisworknet.com/WIOA/Resources/Documents/The-Concise-ProQOL-Manual.pdf>
- Suárez-Carreño, F. M., & Dionisio-Rosales, L. (2019). Algoritmo para la evaluación del modelo dinámico del estrés. *Espiraes Revista Multidisciplinaria De investigación*, 3(31), 37–49. <https://doi.org/10.31876/er.v3i31.691>

- Valdez Hernández, K., Cano Villalobos, J., Castro Reyes, A., Gutiérrez Jurado, A., Moreno Terrones, S., Cañedo Figueroa, C. E., Guzmán Pando, A., & Sámano Lira, G. (2022). Design and Comparison of Artificial Intelligent Algorithms for Breast Cancer Classification. In: Trujillo-Romero, C.J., et al. XLV Mexican Conference on Biomedical Engineering. CNIB 2022. IFMBE Proceedings, vol 86: 46-54. Springer, Cham. https://doi.org/10.1007/978-3-031-18256-3_5
- Zhu, L., Spachos, P., Ng, P. C., Yu, Y., Wang, Y., Plataniotis, K., & Hatzinakos, D. (2023). Stress Detection Through Wrist-Based Electrodermal Activity Monitoring and Machine Learning. *IEEE Journal of Biomedical and Health Informatics*, 27(5), 2155–2165. <https://doi.org/10.1109/JBHI.2023.3239305>

2024 TECNOCENCIA CHIHUAHUA.

Esta obra está bajo la Licencia Creative Commons Atribución No Comercial 4.0 Internacional.



<https://creativecommons.org/licenses/by-nc/4.0/>