



Modelo para la valoración de Burnout en el personal médico del Hospital Luis G Dávila – Tulcán empleando Inteligencia artificial

Model for assessing burnout in medical staff at the Luis G. Dávila Hospital in Tulcán using artificial intelligence

Modelo para avaliar o burnout na equipa médica do Hospital Luis G. Dávila em Tulcán com recurso a inteligência artificial

Luis G. Romero Mejía ^I
luisg.romero@unach.edu.ec
<https://orcid.org/0009-0006-0037-5955>

Erick P. Herrera Granda ^{II}
erick.herrera@epn.edu.ec
<https://orcid.org/0000-0002-3490-7917>

Correspondencia: luisg.romero@unach.edu.ec

Ciencias de la Salud
Artículo de Investigación

* **Recibido:** 13 de julio de 2025 * **Aceptado:** 20 de agosto de 2025 * **Publicado:** 26 de septiembre de 2025

- I. Maestrante de la Universidad Nacional de Chimborazo, Ecuador.
- II. Departamento de Informática y Ciencias de la Computación, Escuela Politécnica Nacional, Quito 170525, Laboratorio de Simulación Numérica y Acústica, LASINAC, Escuela Politécnica Nacional, Quito 170525, Av. Antonio José de Sucre, Riobamba, Ecuador.

Resumen

Este estudio desarrolló un modelo de inteligencia artificial para evaluar el síndrome de Burnout en el personal médico del Hospital Luis G. Dávila (Ecuador), recopilando datos de 165 profesionales con 20 variables categóricas y 22 ordinales. Tras preprocesar los datos con distancias de Mahalanobis y PCA, se conservaron 91 predictores codificados numéricamente. Mediante un riguroso protocolo que evaluó más de 500 arquitecturas, se eligió una red neuronal óptima de dos capas ocultas (155 y 91 neuronas), logrando una precisión superior al 90%, muy por encima de la regresión logística multinomial (11,17%). El modelo se implementó en R y Python usando TensorFlow y Keras. El análisis de correlación ajustado indicó que horas de carga laboral, volumen de pacientes y percepción emocional fueron los predictores más influyentes. Este enfoque demostró la eficacia de la IA para la detección y personalización diagnóstica del Burnout en contextos hospitalarios locales, ofreciendo una herramienta escalable y automatizada para la prevención temprana de este síndrome ocupacional.

Palabras clave: inteligencia artificial; redes neuronales; síndrome de Burnout; técnicas avanzadas de aprendizaje automático.

Abstract

This study developed an artificial intelligence model to assess burnout syndrome in the medical staff of Luis G. Dávila Hospital (Ecuador), collecting data from 165 professionals with 20 categorical and 22 ordinal variables. After preprocessing the data with Mahalanobis distances and PCA, 91 numerically coded predictors were retained. Through a rigorous protocol that evaluated more than 500 architectures, an optimal two-hidden-layer neural network (155 and 91 neurons) was chosen, achieving an accuracy greater than 90%, well above multinomial logistic regression (11.17%). The model was implemented in R and Python using TensorFlow and Keras. Adjusted correlation analysis indicated that workload hours, patient volume, and emotional perception were the most influential predictors. This approach demonstrated the effectiveness of AI for the detection and personalized diagnosis of burnout in local hospital settings, offering a scalable and automated tool for the early prevention of this occupational syndrome.

Keywords: artificial intelligence; neural networks; burnout syndrome; advanced machine learning techniques.

Resumo

Este estudo desenvolveu um modelo de inteligência artificial para avaliar a síndrome de burnout na equipa médica do Hospital Luis G. Dávila (Equador), recolhendo dados de 165 profissionais com 20 variáveis categóricas e 22 ordinais. Após o pré-processamento dos dados com as distâncias de Mahalanobis e ACP, foram retidos 91 preditores codificados numericamente. Através de um protocolo rigoroso que avaliou mais de 500 arquiteturas, foi escolhida uma rede neural ótima de duas camadas ocultas (155 e 91 neurónios), conseguindo uma precisão superior a 90%, muito acima da regressão logística multinomial (11,17%). O modelo foi implementado em R e Python usando o TensorFlow e o Keras. A análise de correlação ajustada indicou que as horas de trabalho, o volume de doentes e a perceção emocional foram os preditores mais influentes. Esta abordagem demonstrou a eficácia da IA para a deteção e diagnóstico personalizado de burnout em ambientes hospitalares locais, oferecendo uma ferramenta escalável e automatizada para a prevenção precoce desta síndrome ocupacional.

Palavras-chave: inteligência artificial; redes neuronais; síndrome de burnout; técnicas avançadas de aprendizagem automática.

Introducción

El personal médico hospitalario enfrenta alta demanda física y emocional, relegando su bienestar y exponiéndose a estrés crónico que puede derivar en el síndrome de Burnout, caracterizado por agotamiento emocional, despersonalización y baja realización personal, afectando la calidad del servicio y la seguridad del paciente. Reconocido como enfermedad laboral por la OMS desde 2022, el Burnout surge del estrés crónico mal gestionado en el entorno laboral, siendo su detección temprana esencial, especialmente en hospitales públicos donde los recursos son limitados y el diagnóstico suele depender de evaluaciones subjetivas, lo que retrasa la intervención.

Este trabajo propone un modelo automatizado basado en inteligencia artificial para valorar el Burnout en personal médico hospitalario, usando instrumentos validados y modelos como clasificadores binarios y redes neuronales profundas, lo cual facilita la identificación de factores de riesgo sin intervención directa. Se emplea un diseño mixto para lograr inferencias sólidas sobre los factores psicosociales en el entorno hospitalario. La IA representa un avance en la gestión de riesgos, aunque requiere integrarse en modelos de salud ocupacional complementarios. El valor

del estudio reside en su potencial para promover consciencia y acción en un problema que afecta la vida profesional y la calidad del sistema sanitario.

Los antecedentes investigativos recientes han fortalecido este enfoque. Diversos estudios han abordado la predicción del Burnout mediante herramientas avanzadas de análisis multivariante y aprendizaje automático. Para, Caldern-De la Cruz y Merino-Soto (2020) analizaron la estructura interna del Maslach Burnout Inventory empleando técnicas estadísticas avanzadas para validación. En el ámbito del aprendizaje automático, los primeros desarrollos incluyen aplicaciones de redes neuronales artificiales, mostrando rendimientos superiores a los métodos estadísticos convencionales, como reportan diferentes autores [1-3]. Otras investigaciones han incorporado datos fisiológicos y psicométricos a través de dispositivos wearables y análisis en tiempo real, incrementando la precisión diagnóstica [4-7].

Estudios recientes también han enfatizado la selección de características y la robustez de los modelos, empleando técnicas como el Análisis de Componentes Principales (PCA) y el algoritmo de clusterización Kamila, logrando precisiones cercanas al 97% [8-17]. El contexto de crisis, particularmente la pandemia de COVID-19, ha demostrado la importancia de modelos adaptables que consideran variables sociodemográficas, biomarcadores e información contextual [18-19]. Así, la evolución de estas técnicas refleja una tendencia hacia sistemas predictivos integrados y multidimensionales, capaces de combinar datos tradicionales de cuestionarios, señales biológicas y criterios sociodemográficos.

En este marco, el presente estudio propone e implementa un modelo automatizado basado en inteligencia artificial para la valoración del síndrome de Burnout en el personal médico del Hospital Luis G. Dávila, haciendo uso de métodos estadísticos multivariados y aprendizaje profundo, con el objetivo de atender de manera eficiente uno de los problemas más críticos en salud ocupacional actual.

Materiales y métodos

La investigación se propuso como objetivo determinar los factores de riesgo del síndrome de Burnout en el personal médico y de enfermería del Hospital Luis G. Dávila, mediante el desarrollo de un modelo automatizado de valoración basado en técnicas de inteligencia artificial y análisis multivariante. El estudio adopta un enfoque mixto (cuantitativo-cualitativo), predominando el componente cuantitativo. Se trata de una investigación no experimental y transversal, de tipo

aplicativo y explicativo. El nivel es correlacional-predictivo, orientado a identificar patrones y factores de riesgo que inciden en la presentación del Burnout y su magnitud en la población objetivo. La población estuvo compuesta por la totalidad del personal médico y de enfermería activo en el Hospital Luis G. Dávila durante el período de estudio, sumando 165 participantes, quienes constituyeron la muestra total por muestra censal.

Los instrumentos de recolección de datos para la información cuantitativa, se empleó el Inventario Maslach de Burnout (MBI), con 22 ítems que evalúan las dimensiones de cansancio emocional, despersonalización y realización personal. Complementariamente, se aplicaron encuestas sociodemográficas, incorporando 20 variables categóricas (edad, género, estado civil, hijos, tiempo en la profesión, horas de trabajo). Para la obtención de los datos cualitativos y para recoger percepciones sobre el entorno laboral, estabilidad emocional y procesos de afrontamiento, se usaron entrevistas semiestructuradas y consultas abiertas con expertos del área de salud.

El análisis de los datos cuantitativos incluyó imputación de datos faltantes por K-Nearest Neighbors, detección de valores atípicos mediante distancia de Mahalanobis, reducción de dimensionalidad con Análisis de Componentes Principales (PCA), y codificación dummy de variables categóricas. Para la predicción del Burnout, se construyeron modelos de redes neuronales profundas (Deep Learning) utilizando TensorFlow y Keras en R y Python. La arquitectura óptima se seleccionó con base en precisión, error cuadrático medio y capacidad predictiva. Para el análisis de los datos cualitativos, se analizó mediante categorización temática y triangulación con los datos cuantitativos, permitiendo interpretar factores percibidos como influyentes o protectores frente al Burnout, contextualizando los resultados y validando el modelo automatizado.

Resultados

Tabla 1. Formato y ejemplo de etiquetas empleadas como variables de respuesta para el proceso de entrenamiento

Cansancio alto	Cansancio medio	Cansancio bajo	Despersonalización alta	Despersonalización media	Despersonalización baja	Realización personal alta	Realización personal media	Realización personal baja
1	0	0	1	0	0	0	0	1

La Tabla 1 ejemplifica el sistema de etiquetado utilizado en el entrenamiento del modelo de red neuronal para el síndrome de Burnout, donde cada participante recibe una etiqueta (1 = presencia, 0 = ausencia) en los niveles alto, medio o bajo de las dimensiones: cansancio emocional, despersonalización y realización personal. La codificación dummy permite clasificar simultáneamente múltiples perfiles de riesgo, por ejemplo, alguien con puntaje 1 en las tres dimensiones se considera en alto riesgo de Burnout. Este esquema favorece la precisión del diagnóstico y la personalización de intervenciones, permitiendo identificar qué dimensión crítica predomina para la toma de decisiones focalizadas en el personal de salud.

La diversidad multivariada, categórica y ordinal del instrumento impidió usar técnicas estadísticas clásicas, lo que llevó a emplear redes neuronales artificiales y Deep Learning por su alta capacidad para procesar variables no lineales. El procesamiento se realizó en R y Python (Anaconda), integrando TensorFlow 2.1 y Keras con reticulate. Se imputaron 17 datos faltantes (0.011%) usando KNN (VIM) y se analizaron observaciones atípicas con distancias de Mahalanobis (punto de corte 297.7523, chi-cuadrado, 99.9%), sin detectar casos extremos, manteniendo la base con 165 observaciones. Posteriormente, se transformaron variables categóricas y binarias a dummies (recipes, tidyverse), generando una matriz de 100 variables: 91 predictores y variables de respuesta según las etiquetas de la Tabla 2. La integridad del conjunto se verificó con ggplot2 y GGally, y los resultados se muestran en la Tabla 2.

Tabla 2. Estadísticos descriptivos de cada variable que conforma la base de datos

Variable name	n.missin g	complete.rat e	num.mean	num.sd	nu m p0	num p25	num p50	num p75	num p10 0
HaPadecidoBurnout	0	1	0.0857142 9	0.2809468 6	0	0	0	0	1
ServCentEst	0	1	0.05	0.2187275 2	0	0	0	0	1
ServCentEstAislaResp	0	1	0.0071428 6	0.0845154 3	0	0	0	0	1
ServCentObste	0	1	0.1428571 4	0.3511835 8	0	0	0	0	1
ServCentQuirurg	0	1	0.0928571 4	0.2912742 7	0	0	0	0	1
ServCirugia	0	1	0.0928571 4	0.2912742 7	0	0	0	0	1

ServConsExt	0	1	0.03571429	0.18624322	0	0	0	0	1
ServEmergencia	0	1	0.12857143	0.33592688	0	0	0	0	1
ServGinec	0	1	0.07857143	0.27003483	0	0	0	0	1
ServMedcInter	0	1	0.11428571	0.31930037	0	0	0	0	1
ServNeonato	0	1	0.08571429	0.28094686	0	0	0	0	1
ServPediat	0	1	0.05	0.21872752	0	0	0	0	1
ServUCI	0	1	0.12142857	0.32779747	0	0	0	0	1
Edad18a30	0	1	0.32857143	0.4713803	0	0	0	1	1
Edad31a45	0	1	0.60714286	0.49013915	0	0	1	1	1
Edad46a60	0	1	0.06428571	0.24614186	0	0	0	0	1
GeneroFem	0	1	0.91428571	0.28094686	0	1	1	1	1
EstadoCivCas	0	1	0.42857143	0.49664858	0	0	0	1	1
EstadoCivDiv	0	1	0.12857143	0.33592688	0	0	0	0	1
EstadoCivSolt	0	1	0.25714286	0.43862815	0	0	0	1	1
EstadoCivUniLib	0	1	0.17142857	0.37823629	0	0	0	0	1
EstadoCivViud	0	1	0.01428571	0.11909215	0	0	0	0	1
X1Hijo	0	1	0.35	0.47868224	0	0	0	1	1
X2Hijos	0	1	0.37857143	0.48677262	0	0	0	1	1
X3Hijos	0	1	0.07857143	0.27003483	0	0	0	0	1
Masde3Hijos	0	1	0.03571429	0.18624322	0	0	0	0	1
NingunHijo	0	1	0.15714286	0.36524218	0	0	0	0	1

SituLabNombra	0	1	0.6	0.49165701	0	0	1	1	1
SituLabOcas	0	1	0.08571429	0.28094686	0	0	0	0	1
SituLabTiempDet	0	1	0.31428571	0.46589767	0	0	0	1	1
TEjerceProf1a5	0	1	0.29285714	0.45670746	0	0	0	1	1
TEjerceProf10a20	0	1	0.12142857	0.32779747	0	0	0	0	1
TEjerceProf20a30	0	1	0.02142857	0.14532807	0	0	0	0	1
TEjerceProf5a10	0	1	0.55714286	0.49850754	0	0	1	1	1
TEjerceProfmas30	0	1	0.00714286	0.08451543	0	0	0	0	1
HorDTrab12h	0	1	0.53571429	0.50051361	0	0	1	1	1
HorDTrab8h	0	1	0.18571429	0.39027226	0	0	0	0	1
HorDTrabMas12h	0	1	0.26428571	0.44253544	0	0	0	1	1
HorDTrabMen8	0	1	0.01428571	0.11909215	0	0	0	0	1
NumPacient10a20	0	1	0.31428571	0.46589767	0	0	0	1	1
NumPacient5a10	0	1	0.27857143	0.44990578	0	0	0	1	1
NumPacientMas20	0	1	0.33571429	0.47393522	0	0	0	1	1
NumPacientMen5	0	1	0.07142857	0.25846412	0	0	0	0	1
DiasLib1a2	0	1	0.75714286	0.43034917	0	1	1	1	1
DiasLibMas3	0	1	0.2	0.40143627	0	0	0	0	1
DiasLiNing	0	1	0.04285714	0.20326219	0	0	0	0	1
NumComid2	0	1	0.25	0.43456751	0	0	0	0.25	1
NumComid3	0	1	0.6	0.49165701	0	0	1	1	1

NumComidMas3	0	1	0.15	0.3583535 5	0	0	0	0	1
EnferRiesArtrit	0	1	0.0285714 3	0.1671968 3	0	0	0	0	1
EnferRiesDiabt	0	1	0.0285714 3	0.1671968 3	0	0	0	0	1
EnferRiegCoraz	0	1	0.0142857 1	0.1190921 5	0	0	0	0	1
EnferRiegHipert	0	1	0.0785714 3	0.2700348 3	0	0	0	0	1
EnferRiegNing	0	1	0.8071428 6	0.3959585 1	0	1	1	1	1
EnferRiegCronic	0	1	0.0428571 4	0.2032621 9	0	0	0	0	1
MedProtcAvecs	0	1	0.7357142 9	0.4425354 4	0	0	1	1	1
MedProtcNunc	0	1	0.1785714 3	0.3843682 5	0	0	0	0	1
MedProtcSiempr	0	1	0.0857142 9	0.2809468 6	0	0	0	0	1
TrabAreaAisl1a3	0	1	0.5214285 7	0.5013342 9	0	0	1	1	1
TrabAreaAisl3a6	0	1	0.3071428 6	0.4629655 5	0	0	0	1	1
TrabAreaAislNunc	0	1	0.1071428 6	0.3104053 6	0	0	0	0	1
TrabAreaAisTodTiem p	0	1	0.0642857 1	0.2461418 6	0	0	0	0	1
PercTrabAngs	31	0.7785714 3	0.1926605 5	0.3962103 9	0	0	0	0	1
PercTrabAncied	0	1	0.1142857 1	0.3193003 7	0	0	0	0	1
PercTrabIncer	0	1	0.15	0.3583535 5	0	0	0	0	1
PercTrabMied	0	1	0.2571428 6	0.4386281 5	0	0	0	1	1
PercTrabNing	0	1	0.0928571 4	0.2912742 7	0	0	0	0	1
PercTrabPreoc	0	1	0.2142857 1	0.4117992 5	0	0	0	0	1
PercTrabTranq	0	1	0.0214285 7	0.1453280 7	0	0	0	0	1

p1	0	1	2.8714285 7	1.5906329 1	0	2	3	4	6
p2	0	1	2.8214285 7	1.5698043 6	0	2	3	4	6
p3	0	1	2.6571428 6	1.5857795 6	0	1	3	4	6
p4	0	1	3.4428571 4	1.6458862 1	0	2	3	5	6
p5	0	1	2.55	1.6548381 2	0	1	3	4	6
p6	0	1	2.8285714 3	1.8346891 5	0	1	3	4	6
p7	0	1	3.4571428 6	1.6506873 6	0	2	3	5	6
p8	0	1	2.85	1.6832864 4	0	1.7 5	3	4	6
p9	0	1	3.3357142 9	1.7200080 1	0	2	3	4.2 5	6
p10	0	1	2.9714285 7	1.5358678 4	0	2	3	4	6
p11	0	1	2.9214285 7	1.6881638 6	0	2	3	4	6
p12	0	1	3.75	1.6143466 5	0	3	4	5	6
p13	0	1	2.9571428 6	1.8770535 2	0	1.7 5	3	4	6
p14	0	1	3.2071428 6	1.6160010 5	0	2	3. 5	4	6
p15	0	1	2.7928571 4	1.7111417 7	0	1	3	4	6
p16	0	1	2.7142857 1	1.6150627 1	0	2	3	4	6
p17	0	1	3.0642857 1	1.7391419 1	0	2	3	4	6
p18	0	1	3.2357142 9	1.8373061 1	0	2	3	5	6
p19	0	1	3.45	1.6329564 5	0	2	4	5	6
p20	0	1	2.6142857 1	1.6946199 9	0	1	3	4	6
p21	0	1	3.2	1.6758977	0	2	3	5	6
p22	0	1	2.5	1.6728900 6	0	1	3	4	6

cansancioAlto	0	1	0.57142857	0.49664858	0	0	1	1	1
cansancioMedio	0	1	0.23571429	0.42596846	0	0	0	0	1
cansancioBajo	0	1	0.19285714	0.39595851	0	0	0	0	1
despersAlto	0	1	0.8	0.40143627	0	1	1	1	1
despersMedio	0	1	0.11428571	0.31930037	0	0	0	0	1
despersBajo	0	1	0.08571429	0.28094686	0	0	0	0	1
realizAlto	0	1	0.1	0.3010772	0	0	0	0	1
realizMedio	0	1	0.05714286	0.23294883	0	0	0	0	1
realizBajo	0	1	0.84285714	0.36524218	0	1	1	1	1

La Tabla 2 muestra que la matriz analítica final quedó sin valores atípicos ni faltantes, y todas las 100 variables conservaron varianza distinta de cero. Según la Tabla 1, el patrón de dispersión heterogéneo justificó agregar una capa de normalización en la entrada, implementada en Keras con `layer_normalization` y `adapt`, para asegurar escalas homogéneas y evitar distorsiones en los gradientes. La variable de respuesta se codificó como dummy, lo que permitió tener nueve neuronas en la capa de salida—una por cada categoría del Burnout—utilizando la función `to_categorical` de Keras, optimizando la clasificación y personalización diagnóstica.

Regresión logística multinomial. La regresión logística multinomial se aplicó como técnica clásica de contraste para evaluar el desempeño frente a métodos de machine learning. El modelo se construyó con las 91 variables regresoras y las nueve categorías de respuesta, ajustando nueve modelos GLM mediante la función `glm` de R. Solo 17 variables resultaron significativas, con valores de AIC = 423.76, Null deviance = 425.517 y Residual deviance = 87.23, logrando una precisión de 11.1713%. Estos resultados evidencian que la regresión logística presenta “limitaciones sustanciales para explicar adecuadamente la estructura compleja de relaciones entre las variables del instrumento propuesto”, lo que justifica el uso de técnicas multivariantes más avanzadas como las redes neuronales.

Arquitectura de la red neuronal. Un protocolo experimental exhaustivo suele ser un excelente recurso para la identificación de una arquitectura apropiada para la red neuronal [21], [23], [24], [25], motivo por el cual se diseñaron arquitecturas de redes neuronales poco profundas y profundas para optimizar la clasificación. La topología óptima se determinó mediante una metodología dual que combinó análisis de componentes principales (PCA) para establecer el número óptimo de capas ocultas [23], [25]; y exploración sistemática de todas las configuraciones posibles de neuronas en las capas ocultas, . El PCA, ejecutado en R con la función princomp, permitió estimar los factores mínimos para explicar la varianza y según , relacionarlos con el posible número de capas ocultas [26], [27], con resultados presentados en la Tabla 3 y la Figura 1.

Tabla 3. Resultados del análisis de componentes principales ejecutado sobre la base de datos.

Components	Comp.1	Comp.2	Comp.3	Comp.4	Comp.5	Comp.6
Standard deviation	2.4199943	1.9833445	1.5326758	1.4910753	1.1967514	1.08416893
Proportion of variance	0.3451002	0.2317997	0.1384258	0.1310134	0.0843965	0.06926446
Cumulative proportion	0.3451002	0.5768998	0.7153257	0.8463390	0.9307355	0.9999999




Fig. 1. Proporción acumulada de varianza para cada número de componentes obtenido mediante el PCA.

Como se puede observar en la Figura 1 y siguiendo las recomendaciones de [23], se puede considerar un número de capas ocultas similar al número de componentes principales hasta donde el modelo es capaz de explicar cerca del 7-% de la varianza del conjunto de datos. Por lo que en este estudio se estudiaron las arquitecturas poco profundas de una capa oculta y las arquitecturas profundas de 2 y 3 capas ocultas.


Modelo secuencial de una capa oculta. La arquitectura del modelo comenzó con una red neuronal superficial de una sola capa oculta, optimizada iterativamente para distintas configuraciones. Se empleó función de activación ReLU, regularización L2 e inicialización Glorot con distribución normal, además de Dropout (80% activas, 20% inactivas) para mitigar el desvanecimiento de gradiente. El entrenamiento se realizó con Adam (learning-rate 0.1, decaimiento 1/500, momentum 0.8, $\beta_1=0.9$, $\beta_2=0.999$, AMSGrad activado). El rango explorado fue de 49 a 198 neuronas en la capa oculta, equivalente a la mitad y el doble de las 91 entradas. Los resultados de rendimiento se detallan en la Tabla 4 y Figura 2.

Tabla 4. Métricas de desempeño para diferentes configuraciones de redes neuronales con una sola capa oculta

Número de neuronas	loss	accuracy	mse	Número de neuronas	loss	accuracy	mse	Número de neuronas	loss	accuracy	mse
45	160331.328	0.2800	0.2311	91	240548.203	0.0400	0.2489	137	330961.313	0.0400	0.2311
46	140017.438	0.0800	0.2489	92	254799.188	0.1200	0.2400	138	361611.969	0.5200	0.2311
47	118626.773	0.1200	0.2490	93	243579.094	0.4400	0.2489	139	327058.031	0.2000	0.2311
48	121305.094	0.2400	0.2391	94	238771.313	0.2400	0.2311	140	347537.625	0.1600	0.2311
49	147720.578	0.1600	0.2311	95	233307.906	0.2000	0.2311	141	345846.813	0.2800	0.2568
50	133639.000	0.5200	0.2667	96	227600.188	0.1200	0.2400	142	314094.031	0.1600	0.2400
51	128572.727	0.1600	0.2489	97	242639.141	0.1600	0.2401	143	346704.969	0.2400	0.2311
52	138149.750	0.5600	0.2667	98	232196.063	0.5200	0.2489	144	333336.313	0.3600	0.2489
53	121436.820	0.4400	0.2667	99	219918.578	0.2000	0.2311	145	347330.375	0.2800	0.2400
54	130958.391	0.2000	0.2578	100	259497.844	0.4400	0.2750	146	348300.563	0.4800	0.2222
55	131380.891	0.5600	0.2391	101	241518.594	0.5200	0.2400	147	347107.375	0.4800	0.2379
56	153569.000	0.2000	0.2400	102	249220.094	0.2000	0.2311	148	358163.719	0.4800	0.2570

57	178125. 813	0.16 00	0.22 22	103	228260. 922	0.08 00	0.24 88	149	357707. 000	0.16 00	0.24 00
58	147290. 922	0.52 00	0.23 11	104	263130. 813	0.16 00	0.24 00	150	358336. 125	0.56 00	0.24 89
59	154168. 281	0.12 00	0.24 89	105	259715. 688	0.16 00	0.24 89	151	348004. 094	0.36 00	0.24 00
60	172128. 141	0.36 00	0.26 67	106	255264. 984	0.12 00	0.23 33	152	357371. 750	0.16 00	0.24 00
61	162998. 391	0.48 00	0.26 67	107	286147. 125	0.76 00	0.24 00	153	378329. 688	0.12 00	0.23 11
62	166027. 703	0.12 00	0.24 00	108	269276. 375	0.12 00	0.23 02	154	347288. 000	0.60 00	0.24 89
63	180733. 906	0.48 00	0.24 00	109	261327. 547	0.20 00	0.23 83	155	407395. 875	0.84 00	0.24 00
64	173817. 281	0.08 00	0.24 00	110	253157. 594	0.32 00	0.24 00	156	365895. 969	0.24 00	0.24 88
65	151692. 359	0.76 00	0.24 00	111	268693. 375	0.12 00	0.24 00	157	376147. 969	0.16 00	0.24 00
66	186751. 906	0.16 00	0.23 11	112	298651. 250	0.44 00	0.24 00	158	400106. 250	0.12 00	0.24 00
67	194191. 906	0.40 00	0.24 00	113	275406. 625	0.24 00	0.23 11	159	398384. 281	0.08 00	0.24 00
68	166839. 375	0.48 00	0.24 89	114	259389. 500	0.08 00	0.23 11	160	397585. 375	0.24 00	0.24 00
69	199718. 313	0.52 00	0.24 82	115	274496. 531	0.52 00	0.24 00	161	353684. 594	0.24 00	0.23 11
70	189264. 188	0.08 00	0.24 89	116	295861. 250	0.40 00	0.24 00	162	401619. 875	0.56 00	0.24 89
71	187359. 453	0.24 00	0.24 00	117	288668. 594	0.48 00	0.23 83	163	421932. 875	0.52 00	0.24 89
72	168157. 188	0.08 00	0.24 00	118	262933. 656	0.52 00	0.23 91	164	412344. 563	0.32 00	0.24 89
73	163023. 250	0.08 00	0.24 89	119	290336. 906	0.24 00	0.24 82	165	404491. 750	0.28 00	0.24 00
74	171470. 234	0.28 00	0.24 88	120	270585. 125	0.32 00	0.23 11	166	376811. 250	0.32 00	0.23 11
75	188804. 453	0.32 00	0.24 00	121	302180. 125	0.68 00	0.24 89	167	401754. 969	0.56 00	0.24 89
76	190678. 953	0.48 00	0.24 89	122	284531. 125	0.20 00	0.24 89	168	381489. 188	0.40 00	0.24 00
77	195812. 406	0.08 00	0.22 98	123	309503. 375	0.32 00	0.24 00	169	384815. 688	0.08 00	0.24 00

78	199594. 781	0.32 00	0.22 90	124	317697. 031	0.28 00	0.25 78	170	445795. 750	0.40 00	0.24 00
79	220475. 047	0.00 00	0.24 00	125	307946. 875	0.24 00	0.23 11	171	379352. 031	0.44 00	0.24 89
80	196039. 313	0.12 00	0.24 00	126	307225. 969	0.16 00	0.23 99	172	420531. 094	0.20 00	0.23 11
81	196831. 922	0.12 00	0.24 89	127	314118. 844	0.64 00	0.26 67	173	409312. 313	0.16 00	0.23 11
82	191969. 047	0.48 00	0.23 97	128	293358. 750	0.40 00	0.24 89	174	388220. 875	0.52 00	0.24 89
83	209771. 594	0.24 00	0.23 89	129	300699. 281	0.20 00	0.23 11	175	412753. 375	0.12 00	0.24 89
84	206976. 594	0.44 00	0.24 89	130	336299. 375	0.12 00	0.24 89	176	448422. 281	0.16 00	0.23 11
85	201061. 547	0.16 00	0.24 89	131	332458. 281	0.40 00	0.23 78	177	398471. 875	0.44 00	0.24 89
86	201443. 406	0.44 00	0.26 66	132	322649. 313	0.20 00	0.23 11	178	444766. 406	0.20 00	0.24 00
87	196024. 766	0.52 00	0.23 02	133	322849. 875	0.12 00	0.24 89	179	433758. 844	0.64 00	0.24 77
88	218906. 453	0.08 00	0.23 91	134	320437. 281	0.20 00	0.22 93	180	461970. 031	0.36 00	0.24 89
89	212657. 781	0.16 00	0.24 00	135	297572. 344	0.48 00	0.24 89	181	443249. 688	0.40 00	0.22 92
90	209209. 313	0.08 00	0.24 89	136	335196. 844	0.20 00	0.23 11	182	462344. 000	0.20 00	0.24 00






Fig. 2. Accuracy, Loss y MSE para cada uno de los 137 modelos de una sola capa oculta entrenado considerando diversas alternativas de número de neuronas en la primera capa oculta.

El análisis de la Tabla 4 y Figura 2 mostró que la arquitectura con 155 neuronas en la primera capa oculta logró la mejor precisión (84%), por lo cual fue utilizada como modelo óptimo y base para transferencia de aprendizaje en modelos con dos capas ocultas. La Figura 2 evidenció que el incremento de neuronas usualmente eleva el “Loss” y reduce el “MSE”, pero no siempre mejora la precisión, subrayando que una mayor cantidad de neuronas no garantiza un mejor desempeño. El entrenamiento iterativo y la arquitectura final se ilustran en las Figuras 3 y 4.




Fig. 3. Proceso de entrenamiento de la red neuronal propuesta de una capa oculta

Model: "sequential_387"

Layer (type)	Output Shape	Param #	Trainable
normalization (Normalization)	(None, 91)	183	Y
dropout_386 (Dropout)	(None, 91)	0	Y
dense_774 (Dense)	(None, 155)	14260	Y
dense_773 (Dense)	(None, 9)	1404	Y

Total params: 15,847
Trainable params: 15,664
Non-trainable params: 183

Fig. 4. Arquitectura de la red neuronal propuesta de una capa oculta

Modelo secuencial de dos capas ocultas. Se evaluó un modelo secuencial de dos capas ocultas (Deep Learning) buscando superar el desempeño del de una capa. Se exploraron múltiples configuraciones con algoritmo iterativo, utilizando ReLU, regularización L2, inicialización Glorot ($\sigma=1$, $\mu=0$) y Dropout (80% neuronas activas), y se entrenó con Adam (learning-rate 0.1, decaimiento 1/500, momentum 0.8, $\beta_1=0.9$, $\beta_2=0.999$, AMSGrad). El número óptimo de neuronas para la segunda capa se buscó exhaustivamente entre 77 y 310 (la mitad a doble de las 155 entradas). El rendimiento de cada configuración está detallado en la Tabla 5 y Figura 5.

Tabla 5. Métricas de desempeño para diferentes configuraciones de redes neuronales con dos capas ocultas.


Número de neuronas	loss	accuracy	mse	Número de neuronas	loss	accuracy	mse	Número de neuronas	loss	accuracy	mse

77	461226432	0.0200	0.2578	156	1085371264	0.0200	0.2578	234	4015490560	0.0200	0.2311
78	682906432	0.0200	0.2311	157	1211634304	0.0200	0.2578	235	2327937024	0.0200	0.2311
79	675465408	0.0200	0.2311	158	2108609792	0.6600	0.2667	236	1964288256	0.9000	0.2489
80	786607360	0.0200	0.2578	159	1373789312	0.0200	0.2578	237	2514120448	0.0200	0.2578
81	959129088	0.0200	0.2311	160	859744064	0.0200	0.2311	238	1513218688	0.0200	0.2400
82	838318720	0.0200	0.2578	161	1475894272	0.7400	0.2756	239	1354733312	0.0200	0.2311
83	884130368	0.0200	0.2311	162	1146163072	0.7400	0.2400	240	2269755392	0.0200	0.2667
84	923788928	0.7800	0.2489	163	2194995712	0.1400	0.2400	241	2687774720	0.1400	0.2400
85	686267584	0.7800	0.2756	164	1130860288	0.0200	0.2311	242	3209204480	0.0200	0.2578
86	824570368	0.6200	0.2400	165	1692652288	0.1400	0.4089	243	3310731520	0.0200	0.2578
87	807156800	0.0600	0.2667	166	1690757632	0.0200	0.2578	244	2721489408	0.7800	0.2667
88	757983616	0.0200	0.2311	167	1846704896	0.0200	0.2311	245	2028221568	0.0200	0.2311
89	908966400	0.0200	0.2311	168	2008100864	0.7800	0.2489	246	2661361920	0.0200	0.2311
90	982737472	0.0200	0.2578	169	2240966400	0.6600	0.2489	247	3776602880	0.1400	0.2400
91	733493248	0.9000	0.2489	170	1399959680	0.0200	0.2578	248	3626732032	0.0200	0.2311
92	635991360	0.7800	0.2756	171	1002119936	0.0200	0.2667	249	1428394368	0.7800	0.2756
93	896551808	0.0200	0.2578	172	929481920	0.0200	0.2578	250	2702489856	0.7800	0.2756
94	683144256	0.0200	0.2578	173	1477961472	0.7800	0.2756	251	2516691968	0.0200	0.2578
95	802126912	0.0200	0.2311	174	1212232064	0.7800	0.2667	252	2663391744	0.1400	0.2400
96	721303744	0.0200	0.2578	175	2315693568	0.0200	0.2311	253	1878613888	0.0200	0.2311
97	867044224	0.0200	0.2311	176	1481996160	0.0200	0.2578	254	2732382208	0.6600	0.2667

98	1075117 440	0.78 00	0.27 56	177	2503875 584	0.02 00	0.23 11	255	3094408 448	0.78 00	0.27 56
99	9058067 20	0.02 00	0.23 11	178	1426538 368	0.02 00	0.23 11	256	3489663 488	0.14 00	0.24 00
100	8937504 00	0.14 00	0.24 00	179	2749524 992	0.02 00	0.23 11	257	1811200 256	0.14 00	0.24 00
101	9932142 72	0.02 00	0.26 67	180	1726754 816	0.02 00	0.25 78	258	1803159 680	0.06 00	0.29 33
102	1304240 256	0.14 00	0.24 00	181	1877660 416	0.02 00	0.25 78	259	2734603 008	0.90 00	0.24 89
103	1104542 976	0.86 00	0.24 89	182	1526548 864	0.02 00	0.25 78	260	2825677 312	0.02 00	0.23 11
104	1077406 848	0.02 00	0.26 67	183	2283027 968	0.02 00	0.23 11	261	3754883 072	0.02 00	0.25 78
105	1220503 552	0.02 00	0.23 11	184	1413663 488	0.02 00	0.25 78	262	2613221 632	0.02 00	0.25 78
106	7972560 64	0.74 00	0.26 67	185	2002471 680	0.02 00	0.26 67	263	2414769 408	0.66 00	0.24 89
107	1200109 824	0.02 00	0.23 11	186	2111089 920	0.14 00	0.24 00	264	1972816 896	0.06 00	0.25 78
108	1138200 064	0.14 00	0.24 00	187	2561611 520	0.02 00	0.24 00	265	4383285 760	0.66 00	0.26 67
109	9055916 80	0.02 00	0.26 67	188	1632701 440	0.02 00	0.25 78	266	3464828 416	0.02 00	0.23 11
110	9991400 96	0.02 00	0.25 78	189	9980505 60	0.78 00	0.24 00	267	2144262 528	0.02 00	0.23 11
111	7821230 72	0.02 00	0.23 11	190	1510327 552	0.66 00	0.24 00	268	2135241 088	0.78 00	0.27 33
112	1383675 392	0.78 00	0.27 56	191	1538661 888	0.02 00	0.25 78	269	2414384 896	0.02 00	0.23 11
113	1096519 040	0.90 00	0.24 89	192	1867064 832	0.02 00	0.25 78	270	3379794 688	0.78 00	0.27 56
114	1517624 960	0.02 00	0.23 11	193	2190209 280	0.78 00	0.26 67	271	2773599 744	0.02 00	0.23 11
115	8144293 76	0.02 00	0.23 11	194	1968277 632	0.66 00	0.24 00	272	4135514 624	0.14 00	0.24 00
116	8623021 44	0.02 00	0.23 11	195	1486846 976	0.78 00	0.27 56	273	2099440 896	0.02 00	0.23 11
117	1085444 736	0.02 00	0.25 78	196	1947679 232	0.02 00	0.23 11	274	2336878 592	0.66 00	0.26 67
118	1217903 488	0.02 00	0.25 78	197	1722581 760	0.66 00	0.24 00	275	2112489 088	0.22 00	0.38 22

119	8589879 04	0.02 00	0.25 78	198	1780040 064	0.02 00	0.23 11	276	2513719 040	0.02 00	0.25 78
120	9977433 60	0.02 00	0.23 11	199	1594577 408	0.14 00	0.24 00	277	1949217 920	0.02 00	0.23 11
121	1276742 400	0.02 00	0.25 78	200	2144631 680	0.14 00	0.24 00	278	2142377 600	0.02 00	0.23 11
122	1102353 024	0.78 00	0.27 56	201	2223122 176	0.02 00	0.25 78	279	2836992 512	0.14 00	0.24 00
123	1254277 888	0.02 00	0.25 78	202	2273109 248	0.02 00	0.23 11	280	2514979 584	0.90 00	0.24 89
124	1467956 096	0.02 00	0.23 11	203	1262979 072	0.02 00	0.23 11	281	2121766 656	0.74 00	0.27 56
125	1118123 264	0.14 00	0.24 00	204	1750645 760	0.78 00	0.27 56	282	1469228 032	0.14 00	0.24 89
126	7032981 76	0.02 00	0.23 11	205	2026617 856	0.02 00	0.25 78	283	2237297 664	0.02 00	0.25 78
127	1041300 992	0.78 00	0.27 56	206	1524459 392	0.02 00	0.23 11	284	2723442 432	0.02 00	0.23 11
128	1186793 984	0.02 00	0.25 78	207	1914281 216	0.78 00	0.27 56	285	2061232 384	0.14 00	0.41 78
129	1707588 608	0.02 00	0.23 11	208	2052387 584	0.66 00	0.26 67	286	4096406 272	0.14 00	0.24 00
130	1197914 880	0.14 00	0.24 00	209	2308007 168	0.86 00	0.24 89	287	2200782 080	0.66 00	0.26 67
131	1134746 880	0.02 00	0.23 11	210	1493044 480	0.78 00	0.27 56	288	4462642 688	0.02 00	0.26 67
132	1671448 960	0.02 00	0.23 11	211	1653532 800	0.02 00	0.25 78	289	4635218 432	0.02 00	0.25 78
133	9520892 16	0.14 00	0.24 00	212	1853659 648	0.02 00	0.25 78	290	1907252 480	0.78 00	0.24 89
134	1495386 368	0.02 00	0.23 11	213	2003286 400	0.02 00	0.23 11	291	2566333 184	0.14 00	0.24 00
135	1402537 216	0.78 00	0.27 56	214	3524072 448	0.62 00	0.26 67	292	2573009 408	0.02 00	0.23 11
136	1070168 256	0.02 00	0.26 67	215	1212783 104	0.02 00	0.25 78	293	2672307 968	0.02 00	0.23 11
137	1570465 664	0.66 00	0.27 56	216	1640945 152	0.78 00	0.27 56	294	3064024 832	0.02 00	0.23 11
138	1050173 440	0.02 00	0.23 11	217	2401485 824	0.74 00	0.24 00	295	2667590 912	0.02 00	0.23 11
139	1590534 912	0.02 00	0.23 11	218	2813272 832	0.02 00	0.23 11	296	2991909 888	0.02 00	0.26 67

140	1385644 032	0.02 00	0.23 11	219	1955955 456	0.02 00	0.24 00	297	2412551 424	0.02 00	0.23 11
141	9737674 24	0.02 00	0.23 11	220	1728384 640	0.02 00	0.23 11	298	3165929 472	0.82 00	0.26 67
142	1451272 704	0.14 00	0.24 00	221	1450348 032	0.02 00	0.23 11	299	3392272 128	0.78 00	0.26 67
143	1366630 016	0.14 00	0.24 00	222	1824955 648	0.02 00	0.23 11	300	3076950 528	0.78 00	0.27 56
144	1727674 624	0.02 00	0.23 11	223	2479154 176	0.78 00	0.27 56	301	2982249 216	0.78 00	0.27 56
145	1439511 296	0.02 00	0.26 67	224	2508442 624	0.02 00	0.25 78	302	2697619 968	0.02 00	0.26 67
146	9339246 08	0.02 00	0.26 67	225	2293861 632	0.02 00	0.25 78	303	3376791 808	0.02 00	0.26 67
147	1507511 040	0.74 00	0.24 00	226	3501507 840	0.78 00	0.27 56	304	2241086 464	0.02 00	0.25 78
148	1488259 584	0.02 00	0.25 78	227	2349230 848	0.02 00	0.23 11	305	3647111 424	0.02 00	0.25 78
149	1214323 712	0.02 00	0.23 11	228	2497970 176	0.78 00	0.24 89	306	2559231 232	0.02 00	0.23 11
150	1067621 632	0.02 00	0.23 11	229	2002175 488	0.02 00	0.23 11	307	2253571 328	0.02 00	0.23 11
151	1728514 560	0.02 00	0.26 67	230	2284056 320	0.02 00	0.26 67	308	4546513 920	0.02 00	0.24 00
152	2220696 576	0.78 00	0.27 56	231	1623934 464	0.02 00	0.25 78	309	3752149 760	0.66 00	0.26 67
153	2287865 344	0.14 00	0.41 78	232	1795008 128	0.02 00	0.25 78	310	3562893 568	0.86 00	0.25 78
154	1043880 256	0.78 00	0.27 56	232	1795008 128	0.02 00	0.25 78				
155	1726681 216	0.02 00	0.23 11	233	2005602 816	0.02 00	0.25 78				






Fig. 5. Accuracy, Loss y MSE para cada uno de los 233 modelos de dos capas ocultas entrenados considerando diversas alternativas de número de neuronas en la primera capa oculta.

El análisis sistemático, según la Tabla 5 y Figura 5, identificó que la configuración óptima fue de 91 neuronas en la segunda capa oculta, logrando una precisión de aproximadamente 90% y sirviendo como base para transferencia de aprendizaje en modelos de mayor profundidad. La evaluación reveló que aumentar el número de neuronas eleva el Loss y el MSE, mientras el Accuracy tiende a incrementarse, aunque sin garantías de mejora adicional significativa. El entrenamiento iterativo y la arquitectura final de dos capas ocultas (155 y 91 neuronas) se presentan en las Figuras 6.y 7.




Fig. 6. Proceso de entrenamiento de la red neuronal propuesta de dos capas ocultas

Model: "sequential_534"

Layer (type)	Output Shape	Param #	Trainable
normalization (Normalization)	(None, 91)	183	Y
dropout_559 (Dropout)	(None, 91)	0	Y
dense_1183 (Dense)	(None, 155)	14260	N
dropout_558 (Dropout)	(None, 155)	0	Y
dense_1182 (Dense)	(None, 91)	14196	Y
dense_1181 (Dense)	(None, 9)	828	Y

Total params: 29,467
Trainable params: 15,024
Non-trainable params: 14,443

Fig. 7. Arquitectura de la red neuronal propuesta de dos capas ocultas

Modelo secuencial de tres capas ocultas. El modelo secuencial de tres capas ocultas fue evaluado para determinar si superaba las métricas de la arquitectura de dos capas. Se entrenaron diversas configuraciones manteniendo la función ReLU, regularización L2, inicialización Glorot y Dropout (80% activas). El optimizador fue Adam (learning-rate 0.1, decaimiento 1/500, momentum 0.8, $\beta_1=0.9$, $\beta_2=0.999$, AMSGrad). El rango de búsqueda de neuronas para la tercera capa fue de 45 a 182 neuronas, acorde a la mitad y el doble de las 91 entradas. Los resultados comparativos se muestran en la Tabla 6 y la Figura 6, destacando el impacto de la arquitectura en el rendimiento del modelo.

Tabla 6. Métricas de desempeño para diferentes configuraciones de redes neuronales con tres capas ocultas

Número	loss	accura	mse	Número	loss	accura	mse	Número	loss	accura	mse
o de		cy		o de		cy		o de		cy	

neuron as				neuron as				neuron as			
45	7.0535E+12	0.02	0.44	91	1.5312E+12	0.78	0.28	137	1.6788E+13	0.02	0.26
46	4.0409E+12	0.02	0.23	92	1.004E+13	0.02	0.26	138	1.7192E+12	0.02	0.26
47	3.696E+12	0.02	0.23	93	4.2581E+12	0.02	0.23	139	2.0188E+12	0.78	0.28
48	3.696E+12	0.02	0.23	94	1.1847E+13	0.02	0.23	140	1.6509E+13	0.02	0.23
49	5.7268E+12	0.14	0.42	95	3.3478E+12	0.14	0.42	141	1.4861E+13	0.02	0.26
50	4.1493E+12	0.02	0.23	96	1.1863E+13	0.78	0.28	142	3.7655E+12	0.02	0.26
51	4.829E+12	0.78	0.28	97	9.5812E+12	0.02	0.26	143	1.6171E+13	0.02	0.26
52	6.0936E+12	0.78	0.28	98	4.6867E+12	0.02	0.2	144	2.036E+13	0.02	0.2
53	6.012E+12	0.02	0.2	99	4.432E+12	0.02	0.2	145	1.4588E+13	0.02	0.2
54	4.13E+12	0.14	0.4	100	1.2003E+13	0.78	0.2	146	1.6788E+13	0.02	0.2
55	6.8255E+12	0.02	0.2	101	1.1165E+13	0.02	0.2	147	8.3741E+12	0.02	0.2
56	1.77E+12	0.02	0.2	102	1.2715E+13	0.02	0.2	148	1.5736E+13	0.78	0.2
57	5.3943E+12	0.78	0.2	103	1.0972E+13	0.02	0.2	149	1.5737E+13	0.02	0.2
58	5.3113E+12	0.14	0.4	104	9.0342E+12	0.78	0.2	150	1.5962E+13	0.02	0.2
59	7.2062E+12	0.78	0.2	105	1.0827E+13	0.02	0.2	151	1.6843E+13	0.14	0.4
60	6.7915E+12	0.02	0.2	106	3.0308E+12	0.02	0.2	152	1.4812E+13	0.14	0.4
61	7.5949E+12	0.02	0.2	107	9.4338E+12	0.02	0.2	153	6.1738E+12	0.02	0.2
62	1.0152E+13	0.02	0.2	108	1.9213E+12	0.02	0.2	154	1.4517E+13	0.02	0.2
63	8.02E+12	0.14	0.4	109	1.1029E+13	0.02	0.2	155	1.4688E+13	0.78	0.2
64	4.5622E+12	0.02	0.2	110	1.117E+13	0.78	0.2	156	2.9031E+12	0.02	0.2
65	7.1167E+12	0.02	0.2	111	9.9605E+12	0.02	0.2	157	1.8454E+13	0.02	0.2
66	5.8011E+12	0.02	0.2	112	1.3908E+13	0.02	0.2	158	5.8812E+12	0.78	0.2
67	6.5718E+12	0.02	0.2	113	2.6052E+12	0.02	0.2	159	1.7281E+13	0.02	0.2
68	8.7676E+12	0.78	0.2	114	1.3853E+13	0.02	0.2	160	1.7867E+13	0.78	0.2

69	7.7679E+ 12	0.78	0.2 8	115	1.0313E+ 13	0.02	0.4 1	161	1.8385E+ 13	0.02	0.2 3
70	7.0425E+ 12	0.02	0.4 4	116	1.212E+1 3	0.78	0.2 8	162	3.879E+1 2	0.02	0.2 6
71	9.0507E+ 11	0.02	0.2 3	117	1.0593E+ 13	0.78	0.2 8	163	1.7032E+ 13	0.02	0.2 6
72	7.4678E+ 12	0.02	0.2 3	118	1.1276E+ 13	0.02	0.2 6	164	1.6118E+ 13	0.02	0.2 3
73	9.0304E+ 12	0.02	0.2 6	119	1.1781E+ 13	0.78	0.2 8	165	1.6216E+ 13	0.78	0.2 8
74	8.6438E+ 12	0.02	0.2 6	120	1.2392E+ 13	0.02	0.2 2	166	1.8872E+ 13	0.78	0.2 8
75	4.2447E+ 12	0.02	0.2 3	121	1.0412E+ 13	0.02	0.2 3	167	1.3251E+ 13	0.02	0.2 3
76	9.8742E+ 12	0.02	0.2 6	122	4.7435E+ 12	0.02	0.2 6	168	1.759E+1 3	0.02	0.2 6
77	9.9887E+ 12	0.02	0.2 6	123	1.3334E+ 13	0.78	0.2 8	169	1.6664E+ 13	0.02	0.2 6
78	1.9025E+ 12	0.02	0.2 6	124	1.2339E+ 13	0.78	0.2 8	170	1.6708E+ 13	0.02	0.4 4
79	9.4601E+ 12	0.78	0.2 8	125	5.6641E+ 12	0.78	0.2 8	171	1.5353E+ 13	0.02	0.2 6
80	6.9649E+ 12	0.02	0.2 3	126	1.3984E+ 13	0.78	0.2 8	172	1.6881E+ 13	0.02	0.2 6
81	9.6588E+ 12	0.78	0.2 8	127	1.4169E+ 13	0.02	0.2 6	173	1.6789E+ 13	0.02	0.2 3
82	1.0224E+ 13	0.02	0.2 3	128	1.0506E+ 13	0.02	0.2 6	174	1.8267E+ 13	0.78	0.2 8
83	7.4756E+ 11	0.02	0.2 3	129	1.5788E+ 13	0.78	0.2 8	175	1.7919E+ 13	0.02	0.2 6
84	8.5131E+ 12	0.02	0.2 3	130	1.4811E+ 13	0.02	0.2 6	176	2.3796E+ 13	0.02	0.2 3
85	2.2614E+ 12	0.02	0.2 3	131	1.4825E+ 13	0.02	0.2 3	177	2.2147E+ 12	0.02	0.2 3
86	7.9832E+ 12	0.78	0.2 8	132	1.297E+1 3	0.02	0.2 6	178	1.7563E+ 13	0.78	0.2 8
87	8.4811E+ 12	0.02	0.2 3	133	1.6285E+ 13	0.78	0.2 8	179	1.6999E+ 13	0.78	0.2 8
88	4.6499E+ 12	0.78	0.2 8	134	1.7304E+ 13	0.78	0.2 8	180	9.0775E+ 12	0.14	0.4 2
89	4.6769E+ 12	0.02	0.2 3	135	1.0764E+ 13	0.78	0.2 8	181	1.7525E+ 13	0.78	0.2 8

90	1.1152E+13	0.02	0.23	136	1.4732E+13	0.02	0.23	182	2.0201E+13	0.78	0.28
----	------------	------	------	-----	------------	------	------	-----	------------	------	------




Fig. 8. Accuracy, Loss y MSE para cada uno de los 138 modelos de tres capas ocultas entrenados considerando diversas alternativas de número de neuronas en la primera capa oculta.

El análisis sistemático reflejado en la Tabla 6 y la Figura 8 mostró que la configuración con 52 neuronas en la tercera capa oculta logró una precisión de casi 90%, aunque no superó el desempeño del modelo de dos capas ocultas (155 y 91 neuronas), por lo que este último fue elegido como arquitectura final. Además, la Figura 8 reporta que agregar más neuronas llevó a descensos en precisión y aumentos en Loss y MSE, indicando sobreajuste. La estructura y entrenamiento del modelo de tres capas se ilustran en las Figuras 9 y 10.




Fig. 9. Proceso de entrenamiento de la red neuronal propuesta de tres capas ocultas

Model: "sequential_1238"

Layer (type)	Output Shape	Param #	Trainable
normalization_3 (Normalization)	(None, 91)	183	Y
dropout_1528 (Dropout)	(None, 91)	0	Y
dense_2856 (Dense)	(None, 155)	14260	N
dropout_1527 (Dropout)	(None, 155)	0	Y
dense_2855 (Dense)	(None, 91)	14196	N
dropout_1526 (Dropout)	(None, 91)	0	Y
dense_2854 (Dense)	(None, 52)	4784	Y
dense_2853 (Dense)	(None, 9)	477	Y

Total params: 33,900
Trainable params: 5,261
Non-trainable params: 28,639

Fig. 10. Arquitectura de la red neuronal propuesta de tres capas ocultas

Análisis de correlación. Para evaluar el aporte individual de cada predictor en el modelo de Deep Learning para Burnout, se realizó un análisis de correlación usando `corr` en R, centrando y normalizando las variables. Los resultados, mostrados en las Figuras 11, 12 y 13, permitieron identificar el impacto específico de cada predictor sobre cansancio emocional alto, despersonalización alta y realización personal baja, facilitando así la interpretación de los factores más influyentes en el síndrome de Burnout.




Fig. 11. Análisis de correlación de cada predictor respecto a la variable cansancio emocional alto obtenido mediante el modelo de Deep Learning de dos capas ocultas.




Fig. 12. Análisis de correlación de cada predictor respecto a la variable despersonalización alta obtenido mediante el modelo de Deep Learning de dos capas ocultas




Fig. 13. Análisis de correlación de cada predictor respecto a la variable realización personal baja obtenido mediante el modelo de Deep Learning de dos capas ocultas.

Discusión

El estudio presenta una innovación metodológica significativa en la evaluación automatizada del síndrome de Burnout en el contexto hospitalario de Tulcán, Ecuador, mediante una red neuronal profunda optimizada con regularización avanzada y transferencia de aprendizaje. A diferencia de investigaciones previas como el de [20], que analizaron solo el cansancio emocional, el modelo propuesto evalúa integralmente las tres dimensiones del Inventario Maslach de Burnout (MBI): agotamiento emocional, despersonalización y realización personal, permitiendo así una valoración más representativa del estado psicoemocional del personal médico.

Una de las principales novedades es la ampliación del cuestionario de Burnout al incluir 20 variables categóricas adicionales de tipo cualitativo y demográfico (por ejemplo, estado civil, número de hijos, percepción emocional, frecuencia de contagios por COVID-19, tipo de servicio hospitalario), logrando un modelo altamente personalizado cuyos resultados diagnósticos superan los enfoques generalistas. Esta estrategia responde a críticas en la literatura [12], [19], sobre la limitada validez universal del MBI en diferentes contextos.

El modelo alcanzó una precisión superior al 90%, utilizando una arquitectura de dos capas ocultas con 155 y 91 neuronas respectivamente, seleccionada tras evaluar más de 500 configuraciones. La aplicación de regularización L2, dropout y transfer learning mejoró la capacidad predictiva frente a métodos convencionales. En contraste, el estudio de [20] empleó una red con cinco capas ocultas solo para agotamiento emocional, logrando un 86% de precisión y sin abarcar otras dimensiones ni realizar un análisis multivariable profundo. El modelo desarrollado aquí integra nueve neuronas de salida que representan la combinación de intensidades en las tres dimensiones del burnout, capturando la complejidad inherente al fenómeno y produciendo predicciones matizadas.

El uso de PCA y la distancia de Mahalanobis para la selección de variables y exclusión de valores atípicos aporta una base estadística robusta, enriqueciendo la validez de los resultados mediante la integración de estadística avanzada con inteligencia artificial. Por último, este trabajo enfatiza la importancia de adaptar los modelos de machine learning al contexto local, pues asumir la validez universal de una sola herramienta diagnóstica ha resultado insuficiente [5], [18]. El modelo propuesto demuestra que integrar datos específicos del entorno social, laboral y sanitario permite desarrollar herramientas más precisas, equitativas y útiles para prevenir y gestionar el síndrome de Burnout en escenarios hospitalarios.

Conclusión

El estudio confirmó la eficacia de un modelo de inteligencia artificial para la valoración del síndrome de Burnout en el personal médico del Hospital Luis G. Dávila, utilizando redes neuronales profundas (DNN) y métodos estadísticos multivariantes como PCA y distancia de Mahalanobis. La arquitectura óptima, con dos capas ocultas (155 y 91 neuronas), logró una precisión del 90%, superando ampliamente a la regresión logística multinomial (11.17%). El uso de regularización L2, dropout y el optimizador Adam con AMSGrad evitó el sobreajuste y optimizó el entrenamiento. La implementación en R y Python con TensorFlow y Keras favoreció la integración tecnológica. El análisis de correlación identificó variables clave, como horas de trabajo y percepción emocional, que influyen en las dimensiones del Burnout. Además, el modelo incorporó 20 variables categóricas específicas del personal de salud de Tulcán, ofreciendo un método más preciso y potente que el test tradicional en este contexto específico. Estos resultados resaltan la importancia de enfoques innovadores y sistemáticos en el abordaje del Burnout con

inteligencia artificial y validan la utilidad de combinar técnicas estadísticas y de aprendizaje profundo en contextos clínicos y ocupacionales.

Referencias

1. G. A. Calderón-De la Cruz and C. Merino-Soto, "Analysis of the Internal Structure of the Maslach Burnout Inventory (Human Service Survey) in Peruvian Physicians," *Rev. Ciencias la Salud*, vol. 18, no. 2, pp. 1–17, 2020.
2. F. Ladstätter, E. Garrosa, C. Badea, and B. Moreno, "Application of artificial neural networks to a study of nursing burnout," *Ergonomics*, vol. 53, no. 9, pp. 1085–1096, 2010.
3. V. Costa et al., "A deep learning algorithm to prevent burnout risk in Family Caregivers of patients undergoing dialysis treatment," in *2018 9th IEEE International Conference on Cognitive Infocommunications (CogInfoCom)*, IEEE, Aug. 2018, pp. 000299–000304. doi: 10.1109/CogInfoCom.2018.8639894.
4. A. R. Wilton et al., "The Burnout PRedictiON Using Wearable aNd Artificial IntelligEnce (BROWNIE) study: a decentralized digital health protocol to predict burnout in registered nurses," *BMC Nurs.*, vol. 23, no. 1, p. 114, Feb. 2024, doi: 10.1186/s12912-024-01711-8.
5. M. D. Gupta et al., "Design and rationale of an intelligent algorithm to detect BuRnoUt in HeaLthcare workers in COVID era using ECG and artificiaL intelligence: The BRUCEE-LI study," *Indian Heart J.*, vol. 73, no. 1, pp. 109–113, Jan. 2021, doi: 10.1016/j.ihj.2020.11.145.
6. P. Gebhard, T. Schneeberger, M. Dietz, E. André, and N. Bajwa, "Designing a Mobile Social and Vocational Reintegration Assistant for Burn-out Outpatient Treatment," in *Proceedings of the 19th ACM International Conference on Intelligent Virtual Agents (IVA '19)*, 2019, pp. 13–15.
7. A. Cho, C. Cha, and G. Baek, "Development of an Artificial Intelligence–Based Tailored Mobile Intervention for Nurse Burnout: Single-Arm Trial (Preprint)," *JMIR Preprints*, no. 54029. Nov. 02, 2023. doi: 10.2196/preprints.54029.
8. W. Almayyan, "Developing a Machine Learning Model for Detecting Job Burnout During the COVID-19 Pandemic Among Front-line Workers in Kuwait," *Int. J. Comput. Sci. Inf. Secur.*, vol. 19, no. 10, pp. 19–33, 2021, doi: 10.5281/zenodo.5668888.
9. A. Zamudio-Sosa, S. Rojo-López, F. Fuentes-Gallegos, and J. I. Fletes-Gutiérrez, "Burnout en profesionales de la salud en contexto de pandemia: una propuesta metodológica para la

- detección de patrones basada en inteligencia artificial,” *Rev. Digit. Int. Psicol. y Cienc. Soc.*, vol. 7, no. 2, pp. 241–257, Jul. 2021, doi: 10.22402/j.rdi.2021.354.241-257.
10. P. L. Tito Huamaní, M. Torres Pecho, and E. E. Pérez Palacios, “Predictores del síndrome de burnout en docentes universitarios: Un análisis factorial exploratorio,” *Enfermería Glob.*, 2022.
 11. B. Moreno Jiménez, M. Gálvez Herrera, E. Garrosa Hernández, and J. C. Mingote Adán, “Nuevos planteamientos en la evaluación del burnout. La evaluación específica del desgaste profesional médico,” *Atención Primaria*, vol. 38, no. 10, pp. 544–549, 2006.
 12. H. Liu et al., “Artificial Intelligence and Radiologist Burnout,” *JAMA Netw. Open*, vol. 7, no. 11, p. e2448714, Nov. 2024, doi: 10.1001/jamanetworkopen.2024.48714.
 13. J. J. B. Gutiérrez and A. Arias-Herrera, “Síndrome de burnout en personal de enfermería: asociación con estresores del entorno hospitalario, Andalucía, España,” *Enfermería Univ.*, vol. 15, no. 1, pp. 30–44, Mar. 2018, doi: 10.22201/eneo.23958421e.2018.1.62903.
 14. F. López-Soriano and L. Bernal, “Prevalencia y factores asociados con el síndrome de burnout en enfermería de atención hospitalaria,” *Rev. Calid. Asist.*, vol. 17, no. 4, pp. 201–205, 2002.
 15. W. L. Arias Gallegos and A. Muñoz del Carpio Toia, “Síndrome de burnout en personal de enfermería de Arequipa,” *Rev. Cuba. Salud Pública*, vol. 42, no. 4, pp. 559–575, 2016.
 16. M. N. V Thomaé, E. A. Ayala, M. S. Sphan, and M. A. Stortti, “Etiología y prevención del síndrome de burnout en los trabajadores de la salud,” *Rev. Posgrado la VIa Cátedra Med.*, no. 153, pp. 18–21, 2006.
 17. L. Saborío Morales and L. F. Hidalgo Murillo, “Síndrome de Burnout,” *Med. Leg. Costa Rica*, vol. 32, no. 1, pp. 119–124, 2015.
 18. K. Cifuentes-Casquete and K. F. Escobar-Segovia, “Factores de riesgos psicosociales y Síndrome de Burnout en un hospital de Guayaquil, ante la emergencia sanitaria por COVID-19,” *Rev. CIENCIAS PEDAGÓGICAS E INNOVACIÓN*, vol. 9, no. 1, pp. 43–50, Jun. 2021, doi: 10.26423/rcpi.v9i1.411.
 19. J. Lovo, “Síndrome de burnout: Un problema moderno,” *Entorno*, vol. 70, no. 70, pp. 110–120, Dec. 2020, doi: 10.5377/entorno.v0i70.10371.
 20. J. Velasco-Benavides and E. Herrera, “Factores de riesgo asociados al síndrome de burnout en docentes de la provincia del Carchi,” *Innov. Dev. Eng. Appl. Sci.*, vol. 7, no. 1, p. 20, Jan. 2025, doi: 10.53358/ideas.v7i1.1015.
 21. M. J. Aza-Espinosa, E. P. Herrera-Granda, and M. Ibarra-Rosero, “DeepBrucel: A Deep Learning Approach for Automated Risk Detection of Brucellosis in Cattle Farms in Ecuador,”

- Ingénierie des systèmes d'Inf., vol. 28, no. 4, pp. 897–920, Aug. 2023, doi: 10.18280/isi.280411.
22. V. R. Benalcázar-Rojas, W. J. Yambay-Vallejo, and E. P. Herrera-Granda, “Multivariate Analysis for Prediction of Splitting Tensile Strength in Concrete Paving Blocks,” *Appl. Sci.*, vol. 13, no. 19, p. 10956, Oct. 2023, doi: 10.3390/app131910956.
 23. M. Ibnu Choldun R., J. Santoso, and K. Surendro, “Determining the Number of Hidden Layers in Neural Network by Using Principal Component Analysis,” in *Intelligent Systems and Applications*, Y. Bi, R. Bhatia, and S. Kapoor, Eds., Cham: Springer International Publishing, 2020, pp. 490–500.
 24. A. U. Khan et al., “Seroprevalence and Molecular Identification of *Brucella* spp. in Bovines in Pakistan—Investigating Association With Risk Factors Using Machine Learning,” *Front. Vet. Sci.*, vol. 7, p. 980, Dec. 2020, doi: 10.3389/fvets.2020.594498.
 25. M. I. C. Rachmatullah, J. Santoso, and K. Surendro, “Determining the number of hidden layer and hidden neuron of neural network for wind speed prediction,” *PeerJ Comput. Sci.*, vol. 7, no. e724, p. e724, Sep. 2021, doi: 10.7717/peerj-cs.724.
 26. H. B. Demuth, M. H. Beale, O. De Jess, and M. T. Hagan, *Neural Network Design*, 2nd ed. Stillwater, OK, USA: Martin Hagan, 2014.
 27. I. D. Herrera-Granda et al., “Artificial Neural Networks for Bottled Water Demand Forecasting: A Small Business Case Study,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 11507 LNCS, Springer Verlag, 2019, pp. 362–373. doi: https://doi.org/10.1007/978-3-030-20518-8_31.
 28. S. J. Reddi, S. Kale, and S. Kumar, “On the Convergence of Adam and Beyond.” 2019. doi: <https://doi.org/10.48550/arXiv.1904.09237>.