

Artículo Original de Investigación

Red neuronal multicapa para estimar disfunción sistólica en hospitalizados con insuficiencia cardíaca usando variables clínicas y biomarcadores accesibles.**Multilayer neural network to estimate systolic dysfunction in hospitalized patients with heart failure using clinical variables and accessible biomarkers.**

Alberto Guevara Tirado.

Universidad Científica del Sur, Lima, Perú

INFORMACIÓN DEL ARTÍCULO

Recibido el 31 de Julio de 2025

Aceptado después de revisión

el 22 de Octubre de 2025

www.revistafac.org.ar

El autor declara no presentar conflictos de interés.

Palabras clave:

Insuficiencia Cardíaca;

Volumen Sistólico;

Biomarcadores; Hospitalización;

Redes Neuronales de la Computación.

RESUMEN

Introducción: la evaluación de la fracción de eyección del ventrículo izquierdo (FEVI) es clave en insuficiencia cardíaca, pero su medición por ecocardiografía no siempre es accesible en entornos clínicos con recursos limitados.

Objetivo: desarrollar un modelo de red neuronal para predecir FEVI reducida usando variables clínicas y bioquímicas habituales en hospitalizados con insuficiencia cardíaca.

Materiales y método: estudio de corte utilizando una base de datos secundaria con 584 pacientes. La variable dependiente fue la FEVI. Se desarrolló un modelo de red neuronal tipo perceptrón multicapa, utilizando como variables predictoras: péptido natriurético cerebral (BNP), troponina, hemoglobina, índice de masa corporal (IMC), edad, tasa de filtrado glomerular (TFG) y creatinina. Se comparó su rendimiento con un modelo de regresión logística binaria, y ambos fueron evaluados mediante área bajo la curva (AUC), sensibilidad, especificidad, valor predictivo positivo (VPP) y negativo (VPN), y precisión global del modelo.

Resultados: la red neuronal alcanzó una precisión del 75,3 % en la prueba y 73,5 % en el entrenamiento, con sensibilidad del 72 %, especificidad del 78,2 %, AUC de 0,811 y odds ratio de 8,07. El BNP fue el predictor más influyente, seguido de hemoglobina, troponina, TFG, edad, IMC y creatinina. En comparación, la regresión logística binaria mostró menor rendimiento (exactitud: 54,8 %; sensibilidad: 44,9 %; especificidad: 62,5 %; AUC: 0,65), especialmente en el valor predictivo negativo (82,9 % en el modelo neuronal vs. 56 %).

Conclusiones: el modelo neuronal predijo eficazmente FEVI reducida usando variables clínicas comunes, superando a la regresión logística, y puede ser útil en contextos sin acceso inmediato a ecocardiografía.

Multilayer neural network to estimate systolic dysfunction in hospitalized patients with heart failure using clinical variables and accessible biomarkers.

ABSTRACT

Introduction: assessment of left ventricular ejection fraction (LVEF) is essential in heart failure, but echocardiographic measurement is not always available in resource-limited clinical settings.

Objective: to develop a neural network model to predict reduced LVEF using common clinical and biochemical variables in hospitalized patients with heart failure.

Materials and Methods: a cross-sectional study was conducted using a secondary database of 584 patients. The dependent variable was LVEF. A multilayer perceptron neural network model was developed using the following predictors: BNP, troponin, hemoglobin, BMI, age, eGFR, and creatinine. Its performance was compared to a binary logistic regression model, and both were evaluated using area under the curve (AUC), sensitivity, specificity, positive predictive value (PPV), negative predictive value (NPV), and overall accuracy.

Results: the neural network achieved an accuracy of 75.3% in the test set and 73.5% in the training set, with a sensitivity of 72%, specificity of 78.2%, AUC of 0.811, and an odds ratio of 8.07. BNP was the most influential predictor, followed by hemoglobin, troponin, eGFR, age, BMI, and creatinine. In

Keywords:

Heart Failure; Stroke Volume;

Biomarkers; Hospitalization;

Neural Networks, Computer.

comparison, the logistic regression model performed worse (accuracy: 54.8%; sensitivity: 44.9%; specificity: 62.5%; AUC: 0.65), particularly in negative predictive value (82.9% in the neural model vs. 56%).

Conclusions: the neural network model effectively predicted reduced IVEF using routine clinical variables, outperforming logistic regression and offering a practical alternative in settings lacking immediate access to echocardiography.

INTRODUCCIÓN

La insuficiencia cardíaca es un síndrome clínico complejo, caracterizado por alteraciones estructurales y funcionales del miocardio, que comprometen la capacidad del corazón para bombear sangre de manera eficaz, provocando síntomas de congestión y bajo gasto¹. Uno de los parámetros fundamentales en su evaluación es la fracción de eyección del ventrículo izquierdo (FEVI), cuya reducción refleja disfunción sistólica y tiene implicancias pronósticas relevantes^{2,3}. No obstante, la determinación precisa de la FEVI requiere estudios de imagen como la ecocardiografía, los cuales pueden no estar disponibles en todos los contextos clínicos, especialmente en sistemas con recursos limitados o en momentos de alta demanda hospitalaria.

En los últimos años, los avances en inteligencia artificial han permitido explorar nuevas formas de estimar o predecir parámetros clínicos relevantes a partir de datos disponibles con relativa accesibilidad. Entre estas herramientas, las redes neuronales tipo perceptrón multicapa han demostrado una capacidad notable para modelar relaciones no lineales complejas entre múltiples variables, superando a menudo a los métodos estadísticos tradicionales en tareas de clasificación y predicción médica⁴.

El presente estudio tuvo como objetivo desarrollar un modelo predictivo de FEVI (conservada o reducida) mediante una red neuronal simple tipo perceptrón multicapa, utilizando únicamente variables clínicas y bioquímicas de uso común en la atención hospitalaria de pacientes hospitalizados con insuficiencia cardíaca. Esta aproximación busca ofrecer una herramienta práctica y potencialmente accesible para la estimación indirecta de la disfunción sistólica, apoyando la toma de decisiones clínicas en entornos donde los recursos diagnósticos especializados pueden ser limitados.

MATERIAL Y MÉTODOS

Diseño y población

Se realizó un estudio de corte a partir de una base de datos secundaria obtenida del repositorio público PhysioNet, correspondiente al conjunto de datos "*Hospitalized patients with heart failure: integrating electronic healthcare records and external outcome data*" (versión 1.3). Este dataset comprende información clínica de 2008 pacientes hospitalizados entre diciembre de 2016 y junio de 2019 en un hospital terciario especializado en enfermedades cardiovasculares. La inclusión original de los pacientes se basó en los criterios diagnósticos de insuficiencia cardíaca establecidos por la Sociedad Europea de Cardiología (ESC), que exigen la presencia de síntomas o signos clínicos compatibles, niveles elevados de péptidos natriuréticos (BNP >35 pg/mL o NT-proBNP >125 pg/mL), y evidencia ecocardiográfica de disfunción cardíaca⁵. Para el presente análisis, se seleccionó una submuestra de 584 pacientes que contaban

con registros completos de variables clínicas, bioquímicas y ecocardiográficas, incluyendo la FEVI.

Variables y mediciones

La fracción de eyección del ventrículo izquierdo (FEVI) se utilizó como variable dependiente. Aunque clínicamente la FEVI se clasifica en tres categorías según la Sociedad Europea de Cardiología: preservada (HFpEF ≥ 50 %), levemente reducida (HFmrEF 41–49 %) y reducida (HFrEF ≤ 40 %), en este estudio se dicotomizó para el análisis en FEVI preservada (≥ 50 %) y FEVI reducida (< 50 %), conforme al valor ecocardiográfico registrado durante la hospitalización.

Las variables independientes incluyeron parámetros clínicos y bioquímicos recolectados al ingreso hospitalario: niveles plasmáticos de péptido natriurético tipo B (BNP), troponina ultrasensible, hemoglobina, índice de masa corporal (IMC), edad, tasa de filtración glomerular (TFG) y creatinina sérica. Estas variables fueron seleccionadas por su relevancia fisiopatológica y su disponibilidad como parte del protocolo clínico institucional.

Según información de la base de datos secundaria, todas las mediciones fueron obtenidas a partir de registros electrónicos hospitalarios, en laboratorios certificados y mediante procedimientos estandarizados, garantizando la calidad y consistencia de los datos empleados en el análisis predictivo.

Análisis estadístico

Para la predicción de la FEVI, se empleó un modelo de red neuronal tipo perceptrón multicapa, una técnica de aprendizaje supervisado adecuada para problemas de clasificación no lineal. El modelo fue entrenado utilizando una arquitectura con una sola capa oculta compuesta por cuatro neuronas, configurada para procesar patrones complejos entre las variables clínicas.

La función de activación seleccionada para la capa oculta fue la tangente hiperbólica, que permite transformar las entradas en valores continuos entre -1 y 1, favoreciendo la convergencia del aprendizaje. En la capa de salida se utilizó la función *softmax*, apropiada para problemas de clasificación binaria al generar probabilidades normalizadas para cada clase (FEVI disminuida o preservada). Como función de error, se aplicó la entropía cruzada, que mide la discrepancia entre las probabilidades predichas y las observadas, optimizando la precisión del modelo durante el entrenamiento.

El entrenamiento del modelo se realizó mediante retropropagación del error, ajustando iterativamente los pesos sinápticos para minimizar la función de pérdida. Para validar el rendimiento del modelo, la base de datos fue dividida aleatoriamente en dos subconjuntos: uno de entrenamiento y otro de prueba, lo cual permitió evaluar su capacidad de generalización en datos no vistos. Se calcularon métricas de desempeño diagnóstico

TABLA 1.

Características de la muestra y estadísticos descriptivos de las variables incluidas en el modelo neuronal

A. Distribución de pacientes según la fracción de eyección del ventrículo izquierdo (FEVI)				
Categoría de FEVI	N		%	
Preservada	320		54,8 %	
Disminuida	264		45,2 %	
B. Estadísticos descriptivos de variables clínicas y bioquímicas A.				
	Mínimo	Máximo	Media	Desviación estándar
Filtrado glomerular (TFG) (ml/min)	5	150	68,7	25,6
Hemoglobina (mg/dL)	8	16	11,5	2,5
Troponina ultrasensible (ng/mL)	0,008	10	0,28	1,92
Índice de masa corporal (IMC) (kg/m²)	14	45	26	5,2
Creatinina (μmol/L)	44	350	110	65
Péptido natriurético cerebral (BNP) (pg/mL)	20	5000	1280,4	1354,2

como sensibilidad, especificidad, valores predictivos positivo y negativo, Odds Ratio y el área bajo la curva (AUC), así como la importancia relativa de cada variable según su contribución sináptica a la clasificación final.

De manera complementaria, se aplicó una regresión logística binaria utilizando las mismas variables clínicas y bioquímicas predictoras. Este modelo permitió estimar la probabilidad de presentar FEVI reducida en función de cada predictor. La regresión logística fue utilizada como técnica comparativa de referencia debido a su amplia aplicabilidad en estudios clínicos, y su capacidad para modelar relaciones entre variables categóricas y continuas con un desenlace dicotómico⁶. Al igual que con el modelo de red neuronal, se calcularon medidas de rendimiento diagnóstico para evaluar su utilidad predictiva y contrastar sus resultados frente al modelo no lineal. Esta comparación permitió valorar el aporte de métodos tradicionales frente a enfoques más avanzados en el contexto clínico de insuficiencia cardíaca. Los resultados de la regresión logística binaria se adjuntan como material suplementario.

Todos los análisis se realizaron en SPSS *statistics* (versión 27) y se consideró un valor de $p < 0,05$ como criterio de significancia estadística.

Consideraciones éticas

Este estudio se fundamentó en el análisis de una base de datos secundaria obtenida del repositorio PhysioNet, empleada conforme a los términos establecidos por la licencia *PhysioNet Restricted Health Data License 1.5.0*. Dado que los datos fueron previamente recolectados, anonimizados y desprovistos de información identificatoria, no fue necesario solicitar consentimiento informado a los participantes. La investigación se llevó a cabo en cumplimiento de los principios éticos establecidos en la Declaración de Helsinki y otras normativas internacionales aplicables al uso de datos secundarios con fines de investigación científica.

La base de datos y sus archivos complementarios están disponibles públicamente a través del siguiente enlace:

<https://doi.org/10.13026/wd7p-qy77>

RESULTADOS

La muestra incluyó 584 pacientes con insuficiencia cardíaca, de los cuales el 54,8 % presentaba FEVI preservada y 45,2 % reducida. El filtrado glomerular promedio fue 68,7 ml/min, y la hemoglobina 11,5 mg/dL. La troponina ultrasensible mostró una media de 0,28 ng/mL, con alta variabilidad. El IMC se ubicó en 26 kg/m², y la creatinina en 110 μmol/L. Los niveles de BNP fueron elevados (media: 1280,4 pg/mL), lo que indica sobrecarga cardíaca. En conjunto, estos parámetros reflejan perfiles clínicos y bioquímicos compatibles con insuficiencia cardíaca en diversos grados de severidad (*Tabla 1*).

Se desarrolló un modelo de red neuronal multicapa para predecir la FEVI en 584 pacientes hospitalizados por insuficiencia cardíaca, utilizando como predictores BNP, troponina ultrasensible, IMC, TFG, creatinina, edad y hemoglobina. La arquitectura incluyó una capa oculta con cuatro neuronas, función de activación tangente hiperbólica y softmax en la salida, empleando entropía cruzada como función de error. El modelo alcanzó una precisión de clasificación del 73,5% en entrenamiento y 75,3% en prueba, con mejor desempeño en la identificación de FEVI preservada (81,1% y 78,2%) frente a FEVI reducida (64,0% y 72,0%). El área bajo la curva ROC fue 0,811 para ambas fases. En términos de importancia relativa, el BNP fue el predictor más relevante (100%), seguido de hemoglobina (53,9%), troponina (41%), TFG (39,9%), edad (33,5%), IMC (24,4%) y creatinina (16,7%), evidenciando un adecuado rendimiento diagnóstico del modelo (*Tabla 2*).

Los pesos sinápticos del modelo neuronal revelan que el BNP ejerció mayor influencia en la activación de la neurona H(1:1), con un peso de 1,335, mientras que su efecto es inhibitor en otras unidades ocultas. La hemoglobina también muestra un patrón mixto, con contribuciones positiva y negativa en distintas neuronas, lo que sugiere un rol modulador relevante. Edad y creatinina se asocian predominantemente con pesos negativos, en especial hacia H(1:4), lo que podría indicar un efecto inhibitor en el proceso de clasificación. En la capa de salida, H(1:1) y H(1:3) aportan positivamente a la predicción de FEVI reducida, en tanto que H(1:2) y H(1:4) parecen favorecer la clase contra-

TABLA 2.

Arquitectura del modelo de red neuronal multicapa y desempeño predictivo en hospitalizados con insuficiencia cardíaca

Característica	Detalle
Muestra total válida	584 casos
División de muestra	72,3% entrenamiento, 27,7% prueba
Variables independientes (input)	BNP, troponina, IMC, TFG, creatinina, edad, hemoglobina
Variable dependiente (output)	FEVI (disminuida vs. preservada)
Arquitectura de la red	1 capa oculta con 4 neuronas
Función de activación capa oculta	Tangente hiperbólica
Función de activación de salida	Softmax
Función de error	Entropía cruzada
Tiempo de entrenamiento	0:00:00.04
Error de entropía cruzada (entrenamiento)	223,78
Error de entropía cruzada (prueba)	85,37
Clasificación correcta (entrenamiento)	73,50%
Clasificación correcta (prueba)	75,30%
Clasificación correcta FEVI preservada (entrenamiento/prueba)	81,1% / 78,2%
Clasificación correcta FEVI disminuida (entrenamiento/prueba)	64,0% / 72,0%
Área bajo la curva ROC (AUC)	0,811 (entrenamiento y prueba)
Importancia de las variables predictoras	BNP (100%), hemoglobina (53,9%), troponina ultrasensible (41%), TFG (39,9%), edad (33,5%), IMC (24,4%) y creatinina (16,7%).

ria. En conjunto, la arquitectura refleja una estructura no lineal donde BNP, hemoglobina e IMC actúan como principales determinantes del desempeño diagnóstico del modelo (Tabla 3).

Se presenta una arquitectura de red neuronal artificial diseñada para estimar la FEVI como variable dicotómica. La estructura incluyó una capa de entrada con ocho variables predictoras: BNP, troponina, IMC, TFG, creatinina, edad y hemoglobina, además de un nodo adicional de sesgo. Estas variables alimentan una capa oculta compuesta por cuatro nodos o neuronas intermedias que utilizan la función de activación tangente hiperbólica para transformar la información. Las conexiones entre las capas están moduladas por pesos sinápticos, representados visualmente en azul (positivos) y gris (negativos). La capa de salida emplea la función *Softmax*, apropiada para tareas de clasificación binaria, permitiendo distinguir entre pacientes con FEVI reducida y conservada. Esta configuración permite integrar múltiples parámetros clínicos y bioquímicos, favoreciendo la detección de patrones complejos en el pronóstico funcional cardíaco (Figura 1).

Durante la fase de entrenamiento, el modelo clasificó correctamente el 81,1 % de los casos con FEVI preservada y el 64 % de

TABLA 3.

Estimaciones de parámetros del modelo de red neuronal multicapa para FEVI reducida

A. Pesos desde la capa de entrada hacia la capa oculta 1				
Variable (Capa de entrada)	H(1:1)	H(1:2)	H(1:3)	H(1:4)
(Sesgo)	0,550	0,136	-0,338	0,544
PNB	1,335	-0,525	-0,772	-0,057
Troponina	0,070	0,300	-0,025	0,324
IMC	0,305	0,181	-0,032	-0,457
TFG	-0,600	0,094	-0,096	0,483
Creatinina (Cr)	-0,003	-0,205	-0,006	-0,194
Edad	-0,114	-0,010	-0,322	-1,043
Hemoglobina (Hb)	0,562	-0,567	0,149	-0,203
B. Pesos desde la capa oculta 1 hacia la capa de salida (clasificación FEVI)				
Unidad en Capa Oculta 1	[FEVI = 0]	[FEVI = 1]		
(Sesgo)	0,778	-0,055		
H(1:1)	-0,574	0,780		
H(1:2)	0,134	-0,330		
H(1:3)	0,797	-0,028		
H(1:4)	-0,603	0,240		




FIGURA 1.

Arquitectura de la red neuronal artificial para la estimación dicotómica de la fracción de eyección del ventrículo izquierdo (FEVI)

aquellos con fracción disminuida. En la fase de prueba, mantuvo una buena capacidad discriminativa, identificando correctamente el 78,2 % de los casos con FEVI preservada y el 72 % con FEVI reducida, lo que resultó en una precisión global del 75,3 %. En esta misma fase, la red neuronal demostró una sensibilidad de 79,41 % y una especificidad de 73,91 %, indicando que el modelo fue eficaz tanto para detectar casos positivos como para

reconocer adecuadamente los negativos. Además, el valor predictivo negativo fue de 82,93 %, lo que sugiere que, cuando el modelo predice una FEVI preservada, es poco probable que se trate de un falso negativo. La *Odds Ratio* de 8,07 respalda la utilidad diagnóstica del modelo, con una asociación sólida entre sus predicciones y la condición real (Tabla 4).

En la comparación entre modelos, la red neuronal mostró un rendimiento diagnóstico mayor al de la regresión logística binaria para predecir FEVI reducida. Su exactitud global fue mayor (75,3 % vs. 54,8 %), presentó mejor sensibilidad (72 % vs. 44,9 %) y especificidad (78,2 % vs. 62,5 %), evidenciando una mayor capacidad para identificar correctamente tanto a los pacientes con disfunción como a aquellos con función preservada. Asimismo, los valores predictivos fueron más altos en la red neuronal, especialmente el valor predictivo negativo (82,9 % frente a 56 %), lo que reduce la probabilidad de falsos negativos. La *Odds Ratio* fue mayor en el modelo neuronal (8,07 vs. 1,25), indicando una asociación mucho más sólida entre las predicciones y el estado real de la FEVI. Finalmente, el AUC estimado fue considerablemente más alto en la red neuronal (0,811 frente a 0,65), reflejando una mejor discriminación global del modelo (Tabla 5).

DISCUSIÓN

La red neuronal multicapa desarrollada para estimar la FEVI en hospitalizados por insuficiencia cardíaca demostró un rendimiento diagnóstico sólido y clínicamente relevante, con un AUC de 0,811 y una precisión global del 75,3 % en la fase de prueba. Este modelo superó a la regresión logística en todas las métricas evaluadas y logró capturar relaciones no lineales complejas entre variables clínicas y biomarcadores bioquímicos de relativa ac-

cesibilidad, muchas de las cuales podrían pasar inadvertidas en modelos tradicionales. Estudios previos han utilizado redes neuronales convolucionales aplicadas a ecocardiogramas, logrando AUC de hasta 0,98 para predecir FEVI reducida⁷. Otros trabajos emplearon electrocardiogramas como entrada, alcanzando AUC de 0,961 con algoritmos de inteligencia artificial para detectar insuficiencia cardíaca con FEVI disminuida⁸. A diferencia de estos enfoques basados en imágenes o señales eléctricas, este estudio se centró en datos fácilmente disponibles, lo que facilita su aplicabilidad en hospitales generales y regiones con infraestructura limitada. Aunque el rendimiento fue inferior al de modelos reportados más complejos como ResNet o Transformers, el balance entre simplicidad, accesibilidad y desempeño diagnóstico convierte a esta propuesta en una herramienta viable para la detección oportuna de disfunción ventricular sistólica en contextos clínicos reales⁹. Además, el hecho de estimar una clasificación ya disponible en la base de datos mediante variables rutinarias representa un aporte operativo más que etiopatogénico, proponiendo una vía de triage clínico donde la ecocardiografía aún no está disponible al ingreso.

Desde la comprensión de la disfunción orgánica, la primacía del BNP como predictor absoluto es esperable, dado su estrecho vínculo con la sobrecarga de presión y volumen en el ventrículo izquierdo¹⁰. La sobreexpresión de BNP refleja distensión miocárdica, lo que lo convierte en un marcador sensible para disfunción ventricular, incluso antes de que se manifiesten cambios ecocardiográficos significativos¹¹. La hemoglobina, el segundo predictor más importante, podría estar actuando como marcador indirecto de perfusión tisular y estado de oxigenación, mientras que sus efectos divergentes en diferentes neuronas ocultas sugieren una interacción no lineal con otras variables,

TABLA 4.
Matriz de clasificación y métricas de desempeño de la red neuronal

A. Matriz de clasificación			
Tipo de muestra	FEVI observada	FEVI pronosticada	Casos correctos (%)
Entrenamiento	Preservada	189/233	81,10%
	Disminuida	121/189	64%
	Global	—	73,50%
Prueba	Preservada	68/87	78,20%
	Disminuida	54/75	72%
	Global	—	75,30%
B. Indicadores de desempeño diagnóstico del modelo en fase de prueba			
Indicador	Valor	IC95%	
Sensibilidad	79,41%	68,00% – 88,44%	
Especificidad	73,91%	63,00% – 83,00%	
Valor Predictivo Positivo	69,23%	57,02% – 79,50%	
Valor Predictivo Negativo	82,93%	72,11% – 90,66%	
Odds Ratio	8,07	3,34 – 19,50	

TABLA 5.
Comparación de desempeño diagnóstico: red neuronal vs. regresión logística para estimar FEVI reducida

Métrica	Red neuronal	Regresión logística binaria
Muestra de prueba	162 (27,7% de 584)	584 (modelo completo, sin validación cruzada)
Exactitud global	75,30%	54,80%
Sensibilidad (FEVI disminuida)	72,0% (IC95%: 60,1–82,3)	44,9% (IC95%: 36,8–53,2)
Especificidad (FEVI preservada)	78,2% (IC95%: 67,6–86,9)	62,5% (IC95%: 54,2–70,2)
Valor predictivo positivo	69,2% (IC95%: 57,0–79,5)	51,7% (IC95%: 43,4–59,9)
Valor predictivo negativo	82,9% (IC95%: 72,1–90,7)	56,0% (IC95%: 48,3–63,4)
Odds Ratio	8,07 (IC95%: 3,34–19,50)	1,25 (IC95%: 1,01–1,55)
AUC ROC	0,811	0,65 (estimado desde R ² Nagelkerke = 0,32)

Los IC95% para sensibilidad y especificidad en el modelo logístico fueron calculados manualmente a partir de proporciones observadas sobre el total de la muestra. El OR de la regresión logística corresponde a la razón de momios para BNP como predictor continuo, estimado desde el coeficiente B del modelo univariado.

posiblemente modulada por comorbilidades como enfermedad renal crónica o hipoxia tisular¹². La troponina ultrasensible, reflejo directo de daño miocárdico subclínico, también tuvo un papel relevante, lo cual refuerza la idea de que la disfunción ventricular en insuficiencia cardíaca no siempre se manifiesta exclusivamente por dilatación o hipoquinesia, sino que puede estar mediada por necrosis o estrés celular¹³.

Variables como TFG, creatinina y edad mostraron efectos predominantemente inhibidores en la activación de ciertas neuronas ocultas, lo que podría interpretarse como factores que interfieren o distorsionan la relación lineal entre biomarcadores clásicos y la FEVI. Esto es consistente con el hecho de que tanto el envejecimiento como la disfunción renal alteran la producción, depuración y sensibilidad tisular a biomarcadores cardíacos¹⁴. El IMC también influyó en el modelo, lo cual es relevante dado la conocida “paradoja de la obesidad” en insuficiencia cardíaca, donde un mayor índice de masa corporal no siempre se asocia con peor pronóstico, sino que podría modular la expresión de síntomas o la respuesta neurohormonal¹⁵.

En cuanto al análisis de pesos sinápticos, la activación positiva de la unidad H(1:1) por el BNP, y su posterior conexión directa con la salida correspondiente a FEVI reducida (peso positivo), refuerza el rol central de este biomarcador en la clasificación correcta. Otras unidades ocultas mostraron interacciones complejas, como H(1:3), donde la troponina y la hemoglobina ejercieron un efecto mixto. La combinación de activaciones positivas y negativas entre neuronas refleja la flexibilidad del modelo para captar patrones no lineales y compensar la presencia de factores confusores o moduladores.

El modelo mostró una mayor sensibilidad (79,4 %) y especificidad (73,9 %) que la regresión logística (44,9 % y 62,5 %, respectivamente), con valores predictivos también superiores, especialmente en el valor predictivo negativo (82,9 %), lo cual es clínicamente relevante para minimizar falsos negativos y evitar subdiagnóstico de disfunción ventricular. La Odds Ratio de 8,07 indica una fuerte asociación entre las predicciones del modelo neuronal y la realidad clínica, a diferencia de la regresión logística, cuya razón de momios fue apenas significativa (1,25). Estos resultados confirman que los modelos neuronales, aun con arquitecturas simples, ofrecen ventajas sustanciales en escenarios clínicos complejos donde las relaciones entre variables no son estrictamente lineales ni independientes.

Respecto a las implicancias, podría utilizarse como herramienta complementaria en la evaluación inicial de pacientes durante su ingreso hospitalario, permitiendo estimar rápidamente el perfil funcional cardíaco incluso antes de contar con estudios ecocardiográficos. Este enfoque de predicción anticipada adquiere especial valor en hospitales generales, donde la ecocardiografía puede demorarse varias horas o no estar disponible en turnos de emergencia. Podría integrarse en sistemas clínicos informatizados para monitorear de manera continua la evolución del paciente, identificando cambios relevantes en el estado funcional cardíaco a partir de biomarcadores rutinarios y accesibles en el contexto de la hospitalización. También podría contribuir a la estratificación pronóstica al ingreso, ayudando a priorizar intervenciones terapéuticas o decisiones sobre ubicación hospi-

talaria, especialmente en contextos donde la disponibilidad de recursos diagnósticos es limitada. En ese sentido, su integración en sistemas electrónicos hospitalarios permitiría automatizar alertas tempranas mediante reglas simples tipo semáforo (por ejemplo, probabilidad alta de FEVI reducida = activación automática de ecocardiografía prioritaria), favoreciendo una implementación pragmática sin necesidad de interfaces complejas. Finalmente dado que los biomarcadores utilizados son parte de la analítica estándar y la ejecución del modelo no requiere intervención manual compleja, su integración implicaría una mínima curva de adaptación para el personal clínico.

Los hallazgos obtenidos plantean múltiples interrogantes que merecen ser explorados en investigaciones futuras. ¿Puede este modelo mantenerse robusto al ser aplicado en poblaciones más heterogéneas o ambulatorias con insuficiencia cardíaca? ¿Cuál es su desempeño comparado con otros métodos de inteligencia artificial, como máquinas de soporte vectorial o árboles de decisión? ¿Es posible integrar estos modelos predictivos en tiempo real dentro de los sistemas clínicos electrónicos para optimizar la toma de decisiones al ingreso hospitalario? Además, ¿cómo podrían influir factores comórbidos, como enfermedad renal crónica o anemia, en la precisión del modelo? ¿Y qué papel tendrían los biomarcadores emergentes o parámetros ecocardiográficos adicionales en mejorar su rendimiento? Estas preguntas abren nuevas líneas de investigación orientadas a validar, adaptar y expandir el uso clínico de modelos predictivos en la atención de pacientes hospitalizados por insuficiencia cardíaca. En esta línea, una validación externa multicéntrica en diferentes sistemas de salud constituye el siguiente paso necesario antes de plantear su adopción clínica, especialmente para evaluar su estabilidad y reproducibilidad fuera del entorno original del modelo.

Este estudio presenta limitaciones importantes. Se utilizó una base de datos retrospectiva de pacientes hospitalizados por insuficiencia cardíaca, lo que restringe la generalización a otros contextos, como pacientes ambulatorios o en etapas tempranas. La falta de validación externa impide confirmar la estabilidad del modelo en otras poblaciones. Aunque la red neuronal superó a la regresión logística en desempeño diagnóstico, su implementación requiere infraestructura y conocimientos técnicos que podrían no estar disponibles en todos los entornos. Además, no se incluyeron variables clínicas relevantes como comorbilidades, medicación o etiología de la insuficiencia cardíaca, que podrían influir en la fracción de eyección. Estas limitaciones deben ser abordadas en futuras investigaciones. No obstante, la disponibilidad de los biomarcadores empleados en la mayoría de los hospitales generales sugiere que la fase de implementación podría realizarse mediante integración en sistemas HIS con mínima carga operativa, lo que facilita su potencial escalabilidad.

En conclusión, este estudio demuestra que es posible estimar la fracción de eyección del ventrículo izquierdo utilizando solo biomarcadores clínicos rutinarios, posicionando al modelo como herramienta operativa de triage más que como aporte etiopatogénico. La red neuronal superó a la regresión logística y permite anticipar la probabilidad de disfunción sistólica antes de disponer de ecocardiografía, lo que resulta especialmente

útil en hospitales con recursos limitados. Más que reemplazar estudios de imagen, esta aproximación puede integrarse en sistemas informáticos hospitalarios como filtro automatizado para priorizar ecocardiogramas. No obstante, la falta de validación externa obliga a considerar estos resultados como una fase preliminar que requiere replicación en distintos entornos clínicos. Su potencial utilidad refuerza la necesidad de combinar biomarcadores cardíacos, renales y hematológicos dentro de modelos de inteligencia artificial aplicables a la práctica hospitalaria.

BIBLIOGRAFIA

- Schwinger RHG. Pathophysiology of heart failure. *Cardiovasc Diagn Ther* **2021**; 11: 263 - 276.
- Rosano GMC, Teerlink JR, Kinugawa K, et al. The use of left ventricular ejection fraction in the diagnosis and management of heart failure. *Eur J Heart Fail* **2025**; 27: 1174 - 1187.
- Nakagawa A, Yasumura Y, Yoshida C, et al. Predictors and outcomes of Heart Failure with Preserved Ejection Fraction in patients with a left ventricular ejection fraction above or below 60. *J Am Heart Assoc* **2022**; 11: e025300.
- Sridhar GR, Yarabati V, Gumpeny L. Predicting outcomes using neural networks in the intensive care unit. *World J Clin Cases* **2025**; 13: 100966.
- McDonagh TA, Metra M, Adamo M, et al. 2021 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure. *Eur Heart J* **2021**; 42: 3599 - 3726.
- Schober P, Vetter TR. Logistic regression in medical research. *Anesth Analg* **2021**; 132: 365 - 366.
- Zhang Y, Liu B, Bunting KV, et al. Development of automated neural network prediction for echocardiographic left ventricular ejection fraction. *Front Med (Lausanne)* **2024**; 11: 1354070.
- Cho J, Lee B, Kwon J-M, et al. Artificial intelligence algorithm for screening heart failure with reduced ejection fraction using electrocardiography. *ASAIO J* **2021**; 67: 314 - 321.
- Devkota A, Prajapati R, El-Wakeel A, et al. AI analysis for ejection fraction estimation from 12-lead ECG. *Sci Rep* **2025**; 15: 13502.
- Hayashida H, Haruyama N, Fukui A, et al. Plasma B-type natriuretic peptide is independently associated with cardiovascular events and mortality in patients with chronic kidney disease. *Sci Rep* **2024**; 14: 16542.
- Mouzarou A, Hadjigeorgiou N, Melanarkiti D, et al. The role of NT-proBNP levels in the diagnosis of hypertensive heart disease. *Diagnostics (Basel)* **2025**; 15: 113.
- Kosyakovskiy LB, Earle WB, Wichern C, et al. Macrovascular hemodynamics and peripheral perfusion in cardiogenic shock: Exploring current targets and future directions. *JACC Adv* **2025**; 101964: 101964.
- Jarabíková I, Horváth C, Hrdlička J, et al. Necrosis-like cell death modes in heart failure: the influence of aetiology and the effects of RIP3 inhibition. *Basic Res Cardiol* **2025**; 120: 373 - 392.
- Kanasaki K, Kitada M, Koya D. Pathophysiology of the aging kidney and therapeutic interventions. *Hypertens Res* **2012**; 35: 1121 - 1128.
- Hamzeh N, Ghadimi F, Farzaneh R, et al. Obesity, heart failure, and obesity paradox. *J Tehran Heart Cent* **2017**; 12: 1 - 5.