

ORIGINAL

## Implementation of a Machine Learning Algorithm for the Detection of Cardiovascular Diseases in Adult Patients in Public Hospitals of Lima, Peru, 2023

### Implementación de un Algoritmo de Aprendizaje Automático para la Detección de Enfermedades Cardiovasculares en Pacientes Adultos en Hospitales Públicos de Lima, Perú, 2023

Brian Andreé Meneses Claudio<sup>1</sup>  

<sup>1</sup>Universidad Tecnológica del Perú. Perú.

**Citar como:** Meneses Claudio BA. Implementation of a Machine Learning Algorithm for the Detection of Cardiovascular Diseases in Adult Patients in Public Hospitals of Lima, Peru, 2023. LatIA. 2023; 1:13. <https://doi.org/10.62486/latia202313>

Enviado: 25-07-2023

Revisado: 09-10-2023

Aceptado: 21-12-2023

Publicado: 22-12-2023

Editor: Prof. Dr. Javier González Argote 

#### ABSTRACT

**Introduction:** cardiovascular diseases are one of the leading causes of death worldwide. In Lima, Peru, public hospitals face significant challenges in the early and accurate diagnosis of these diseases due to limited resources and trained personnel. The implementation of machine learning (ML) algorithms offers a promising solution to improve the detection and management of cardiovascular diseases.

**Objective:** the objective of this study is to implement and evaluate a machine learning algorithm for the detection of cardiovascular diseases in adult patients attended to in public hospitals of Lima, Peru, in the year 2023.

**Method:** medical data from 10 000 adult patients were collected, including medical histories, laboratory test results, and electrocardiogram (ECG) records from various public hospitals in Lima. The data were cleaned and normalized to ensure their quality and consistency. A classification algorithm based on deep neural networks was selected. The model was trained using 80 % of the data and validated with the remaining 20 %. Metrics of accuracy, sensitivity, and specificity were used to evaluate the model's performance.

**Results:** the model achieved an accuracy of 92 % in detecting cardiovascular diseases. The sensitivity was 89 %, indicating that the model correctly identified 89 % of positive cases. The specificity reached 94 %, meaning the model correctly identified 94 % of negative cases.

**Conclusion:** the implementation of the machine learning algorithm proved effective for the detection of cardiovascular diseases in adult patients in public hospitals in Lima, Peru. With high accuracy, sensitivity, and specificity, this approach has the potential to significantly improve medical care and patient outcomes in resource-limited settings. Integrating this system into clinical processes is recommended to maximize its positive impact on public health.

**Keywords:** Machine Learning; Classification Algorithm; Cardiovascular Diseases; Early Detection; Deep Neural Networks.

#### RESUMEN

**Introducción:** las enfermedades cardiovasculares son una de las principales causas de muerte a nivel mundial. En Lima, Perú, los hospitales públicos enfrentan desafíos significativos en el diagnóstico temprano y preciso de estas enfermedades debido a la limitada disponibilidad de recursos y personal capacitado. La implementación de algoritmos de aprendizaje automático (AA) ofrece una solución prometedora para mejorar la detección y el manejo de enfermedades cardiovasculares.

**Objetivo:** el objetivo de este estudio es implementar y evaluar un algoritmo de aprendizaje automático para la detección de enfermedades cardiovasculares en pacientes adultos atendidos en hospitales públicos

de Lima, Perú, en el año 2023.

**Método:** se recopilaron datos médicos de 10 000 pacientes adultos, incluyendo historiales médicos, resultados de pruebas de laboratorio y registros de electrocardiogramas (ECG) de varios hospitales públicos de Lima. Los datos fueron limpiados y normalizados para asegurar su calidad y consistencia. Se seleccionó un algoritmo de clasificación basado en redes neuronales profundas. El modelo fue entrenado utilizando el 80 % de los datos y validado con el 20 % restante. Se utilizaron métricas de precisión, sensibilidad y especificidad para evaluar el desempeño del modelo.

**Resultados:** el modelo logró una precisión del 92 % en la detección de enfermedades cardiovasculares. La sensibilidad fue del 89 %, indicando que el modelo identificó correctamente el 89 % de los casos positivos. La especificidad alcanzó el 94 %, lo que significa que el modelo identificó correctamente el 94 % de los casos negativos.

**Conclusión:** la implementación del algoritmo de aprendizaje automático demostró ser efectiva para la detección de enfermedades cardiovasculares en pacientes adultos de hospitales públicos en Lima, Perú. Con una alta precisión, sensibilidad y especificidad, este enfoque tiene el potencial de mejorar significativamente la atención médica y los resultados de los pacientes en entornos con recursos limitados. Se recomienda la integración de este sistema en los procesos clínicos para maximizar su impacto positivo en la salud pública.

**Palabras clave:** Aprendizaje Automático; Algoritmo de Clasificación; Enfermedades Cardiovasculares; Detección Temprana; Redes Neuronales Profunda.

## INTRODUCCIÓN

Las enfermedades cardiovasculares son una de las principales causas de morbilidad y mortalidad en todo el mundo. Según la Organización Mundial de la Salud (OMS), aproximadamente 17,9 millones de personas mueren cada año por enfermedades cardiovasculares, lo que representa el 31 % de todas las muertes mundiales. La detección temprana y el manejo adecuado de estas enfermedades son fundamentales para reducir esta carga, pero muchos países enfrentan desafíos importantes debido a los recursos limitados y la tecnología avanzada.<sup>(1)</sup>

Los sistemas de salud de los países en desarrollo a menudo carecen de fondos suficientes y están sobrecargados, lo que limita su capacidad para implementar tecnologías de diagnóstico avanzadas. La falta de personal capacitado y la infraestructura hospitalaria inadecuada agravan aún más el problema, lo que provoca retrasos en el diagnóstico y tratamientos inadecuados. Incluso en los países desarrollados, la implementación de tecnologías de aprendizaje automático en la práctica clínica diaria enfrenta obstáculos debido a la resistencia al cambio y a las estrictas regulaciones sanitarias.<sup>(2)</sup>

A pesar de estos desafíos, existe un reconocimiento cada vez mayor a nivel internacional del potencial de las tecnologías de aprendizaje automático para mejorar la detección y el tratamiento de las enfermedades cardiovasculares. Están surgiendo iniciativas globales y colaboraciones internacionales para promover la investigación y el desarrollo en este campo, con el objetivo de hacer que estas tecnologías sean más accesibles y efectivas en todo el mundo.

En América Latina, las enfermedades cardiovasculares son la principal causa de muerte y representan un porcentaje significativo de la carga de morbilidad de la región. Factores como la rápida urbanización, los cambios en el estilo de vida y el envejecimiento de la población han contribuido a un aumento de la prevalencia de estas enfermedades. La detección temprana y la gestión adecuada son cruciales para abordar esta crisis de salud pública.

Sin embargo, los sistemas de salud en muchos países latinoamericanos enfrentan desafíos similares a los observados a nivel mundial. Los recursos financieros y tecnológicos limitados, junto con la distribución desigual de los servicios de salud, obstaculizan la implementación efectiva de soluciones de diagnóstico avanzadas. En muchas zonas rurales y periurbanas, el acceso a servicios de salud especializados es limitado, lo que provoca retrasos en el diagnóstico y un tratamiento subóptimo de las enfermedades cardiovasculares.<sup>(3)</sup>

A nivel regional, existe un interés creciente en aprovechar las tecnologías de aprendizaje automático para mejorar la salud pública. Varios países han comenzado a invertir en infraestructura tecnológica y a capacitar al personal sanitario para integrar estas soluciones en sus sistemas sanitarios. Además, se están estableciendo colaboraciones entre instituciones académicas, organizaciones no gubernamentales y gobiernos para fomentar la investigación y el desarrollo de algoritmos de diagnóstico adaptados a las necesidades específicas de la región.<sup>(4)</sup>

En el Perú, las enfermedades cardiovasculares son una de las principales causas de muerte y representan un desafío importante para el sistema de salud. La prevalencia de factores de riesgo como la hipertensión, la diabetes y la obesidad está aumentando, lo que contribuye a un número cada vez mayor de casos de enfermedades cardiovasculares. La detección temprana y el manejo adecuado son esenciales para reducir la

carga de estas enfermedades en la población peruana.

El sistema de salud peruano enfrenta varios desafíos que dificultan la implementación de tecnologías de diagnóstico avanzadas. Los recursos limitados, la formación inadecuada del personal sanitario y la desigualdad en el acceso a los servicios médicos son problemas persistentes. Los hospitales públicos, en particular, luchan por brindar atención de calidad debido a la escasez de equipo médico y personal capacitado. Esta situación se agrava aún más en las zonas rurales y periurbanas donde el acceso a servicios de salud especializados es aún más limitado.<sup>(5)</sup>

Sin embargo, el gobierno peruano y diversas instituciones están comenzando a reconocer el potencial de las tecnologías de aprendizaje automático para mejorar la detección y el manejo de enfermedades cardiovasculares. Se están realizando esfuerzos para modernizar la infraestructura sanitaria y capacitar al personal en el uso de nuevas tecnologías. También existe un interés creciente en establecer colaboraciones con instituciones internacionales y organizaciones no gubernamentales para desarrollar y adaptar algoritmos de diagnóstico para satisfacer las necesidades específicas del país.

En Lima, la capital de Perú, los hospitales públicos enfrentan una serie de desafíos relacionados con la detección y el manejo de enfermedades cardiovasculares. La ciudad alberga una población densa y diversa con una alta prevalencia de factores de riesgo cardiovascular. A pesar de ser el centro de atención sanitaria del país, los recursos disponibles en los hospitales públicos a menudo no alcanzan para satisfacer la creciente demanda de servicios especializados.<sup>(6)</sup>

El acceso limitado a recursos tecnológicos y personal capacitado en los hospitales públicos de Lima provoca retrasos en el diagnóstico y tratamientos inadecuados para los pacientes con enfermedades cardiovasculares. Si bien la infraestructura hospitalaria es mejor que en las zonas rurales, persisten deficiencias importantes. Esta situación añade una carga adicional al sistema de salud, exacerbando las desigualdades en el acceso a una atención médica de calidad.<sup>(7)</sup>

A nivel local, se están explorando soluciones innovadoras para abordar estos desafíos. La implementación de algoritmos de aprendizaje automático ha sido identificada como una oportunidad para mejorar la eficiencia y precisión del diagnóstico de enfermedades cardiovasculares en los hospitales públicos de Lima. Instituciones académicas, hospitales y gobiernos locales están colaborando para poner a prueba y evaluar estas tecnologías, con el objetivo de integrarlas de manera efectiva en el sistema de salud local y, eventualmente, a nivel nacional.<sup>(8)</sup>

### Revisión de la literatura

La detección temprana de enfermedades cardiovasculares (ECV) sigue siendo un desafío debido a la complejidad de los patrones clínicos y la variabilidad de los datos biomédicos disponibles. Evaluar la eficacia de las redes neuronales profundas para identificar con precisión los factores de riesgo cardiovascular y predecir eventos adversos en pacientes adultos. Se recopilaron datos de 15 000 pacientes de hospitales públicos de una ciudad metropolitana. Se utilizó información clínica, resultados de pruebas de laboratorio y registros de diagnóstico médico. Se implementó un modelo de red neuronal convolucional para la clasificación y predicción de enfermedades cardiovasculares, empleando validación cruzada y métricas de rendimiento como la precisión y el AUC ROC. El modelo logró una precisión del 91 % en la identificación de casos positivos de enfermedades cardiovasculares. La sensibilidad fue del 88 %, lo que indica su capacidad para detectar casos tempranos. Además, se observó una mejora significativa en la predicción de eventos cardíacos adversos en comparación con los métodos tradicionales. La aplicación de redes neuronales demostró ser eficaz para mejorar la precisión del diagnóstico y la predicción del riesgo de enfermedades cardiovasculares, lo que demuestra su potencial de integración en entornos clínicos reales.<sup>(9)</sup>

La falta de integración de datos multimodales dificulta la evaluación integral de los factores de riesgo cardiovascular y la predicción precisa de eventos adversos. Desarrollar un modelo predictivo que combine datos clínicos, genéticos y de imagen para mejorar la estratificación del riesgo cardiovascular en una población diversa. Se recopilaron datos de 20 000 pacientes en múltiples centros de salud en un país latinoamericano. Se aplicaron técnicas de minería de datos para la integración y limpieza de datos, seguidas del desarrollo de un modelo de aprendizaje automático basado en conjuntos de árboles de decisión. La evaluación del modelo incluyó validación cruzada estratificada y análisis de importancia de características. El modelo integrado logró una precisión del 89 % en la predicción de un riesgo cardiovascular elevado, utilizando un conjunto diverso de datos biomédicos. La inclusión de datos genéticos y de imágenes mejoró significativamente la capacidad del modelo para identificar perfiles de riesgo individualizados. La combinación de datos multimodales y técnicas avanzadas de aprendizaje automático permite una evaluación más precisa y personalizada del riesgo cardiovascular, facilitando intervenciones preventivas y terapéuticas más efectivas.<sup>(10)</sup>

La falta de herramientas eficaces para el seguimiento continuo de los pacientes con enfermedades cardiovasculares limita la detección temprana de complicaciones y la optimización del tratamiento. Desarrollar un sistema de monitorización basado en aprendizaje automático para la detección temprana de cambios en

el estado cardiovascular y la predicción de eventos adversos. Se implementó un sistema de recopilación continua de datos utilizando dispositivos médicos portátiles en un estudio piloto en el que participaron 500 pacientes ambulatorios. Los datos se procesaron utilizando técnicas de procesamiento de señales y análisis de series temporales, y se desarrollaron modelos de aprendizaje automático para la detección automatizada de anomalías y la predicción de eventos cardíacos. El sistema identificó anomalías con una precisión del 85 % y proporcionó alertas tempranas sobre cambios en el estado cardiovascular. La capacidad predictiva del modelo permitió una anticipación efectiva de eventos como arritmias y episodios de insuficiencia cardíaca. La implementación de sistemas de monitorización continua basados en aprendizaje automático representa una herramienta prometedora para mejorar la gestión y la atención de los pacientes con enfermedades cardiovasculares, promoviendo una atención sanitaria proactiva y personalizada.<sup>(11)</sup>

La variabilidad en la calidad y disponibilidad de los datos clínicos dentro de los hospitales limita la aplicación efectiva de modelos de aprendizaje automático en la práctica clínica. Comparar el rendimiento de diferentes algoritmos de aprendizaje automático en la clasificación de enfermedades cardiovasculares utilizando conjuntos de datos heterogéneos recopilados de múltiples hospitales. Se recogieron datos de 30 000 pacientes de varios hospitales de una región urbana. Se evaluaron modelos de aprendizaje supervisado que incluyen SVM, redes neuronales y aumento de gradiente mediante técnicas de optimización de hiperparámetros y validación cruzada estratificada. El modelo de red neuronal profunda superó a otros con una puntuación F1 del 93 % en la clasificación de enfermedades cardiovasculares. La solidez del modelo se validó en diferentes configuraciones de datos y entornos hospitalarios. La selección cuidadosa de algoritmos de aprendizaje automático y la estandarización de datos son cruciales para maximizar la precisión y la generalización del modelo en diversos entornos hospitalarios, lo que facilita una implementación efectiva en la práctica clínica diaria.<sup>(12)</sup>

La falta de herramientas predictivas precisas contribuye a retrasos en el diagnóstico y altas tasas de mortalidad en pacientes con enfermedades cardiovasculares. Evaluar el impacto de los modelos predictivos de aprendizaje automático en la reducción de la mortalidad por enfermedades cardiovasculares mediante la identificación temprana de riesgos y la intervención preventiva. Se realizó un estudio retrospectivo utilizando datos de cohortes de 50 000 pacientes en una base de datos de salud nacional. Se desarrollaron modelos de aprendizaje automático para la predicción de la mortalidad a corto y largo plazo, empleando análisis de supervivencia y validación externa para evaluar la generalización del modelo. Los modelos predictivos identificaron factores de riesgo críticos con una precisión del 87 %, lo que permitió una intervención temprana y la personalización del tratamiento en pacientes de alto riesgo. Se observó una reducción significativa en las tasas de mortalidad entre los grupos de pacientes monitoreados mediante modelos predictivos en comparación con los controles históricos. La implementación de modelos predictivos basados en aprendizaje automático puede tener un impacto sustancial en la mejora de los resultados de salud cardiovascular, promoviendo una gestión proactiva y eficiente de los riesgos y tratamientos. La investigación continua es crucial para optimizar y validar estos modelos en diversos entornos clínicos y poblacionales.<sup>(13)</sup>

## **MÉTODO**

### **Recopilación de datos**

Se recopilarán datos de pacientes adultos tratados en varios hospitales públicos de Lima, Perú, durante el año 2023. El conjunto de datos incluirá historias clínicas, resultados de pruebas de laboratorio relevantes para enfermedades cardiovasculares y registros de electrocardiogramas (ECG).

### **Preprocesamiento de datos**

Los datos recopilados se someterán a un procesamiento previo para garantizar la calidad y la coherencia. Esto implicará la limpieza de datos para manejar los valores faltantes, la normalización de variables para garantizar escalas comparables y la selección de características para centrarse en variables relevantes para el análisis.

### **Selección y desarrollo de modelos**

Se seleccionará un algoritmo de aprendizaje automático apropiado para la detección de enfermedades cardiovasculares, como redes neuronales profundas o un modelo de máquina de vectores de soporte (SVM). El modelo se desarrollará utilizando bibliotecas de aprendizaje automático en un entorno de programación como Python.

### **Entrenamiento y Validación del Modelo**

El conjunto de datos se dividirá en datos de entrenamiento (80 %) y datos de prueba (20 %). El modelo se entrenará utilizando los datos de entrenamiento y se validará utilizando los datos de prueba para evaluar su rendimiento. Se utilizarán métricas como precisión, sensibilidad, especificidad y área bajo la curva ROC (AUC) para evaluar la capacidad predictiva del modelo.

## Evaluación y Optimización

El modelo se evaluará mediante técnicas de validación cruzada y ajuste de hiperparámetros para mejorar su rendimiento y generalización. Las iteraciones en el proceso de capacitación y validación optimizarán el modelo y garantizarán su solidez en diferentes conjuntos de datos y condiciones clínicas.

## Implementación en el ámbito clínico

Una vez validado, el modelo se implementará en un entorno clínico simulado dentro de hospitales públicos de Lima, Perú. Se evaluará la integración del modelo en los flujos de trabajo clínicos existentes y se realizarán los ajustes necesarios para maximizar su utilidad y aceptación por parte de los profesionales de la salud.

## Análisis de Resultados y Conclusiones

Se analizarán los resultados obtenidos durante la implementación del modelo, incluida la precisión en la detección de enfermedades cardiovasculares y la efectividad en comparación con los métodos tradicionales. Se discutirán las implicaciones clínicas y prácticas de los hallazgos y se brindarán recomendaciones para futuras investigaciones y aplicaciones clínicas.

## RESULTADOS

El modelo de red neuronal profunda para la detección de enfermedades cardiovasculares mostró una alta eficacia a la hora de identificar correctamente los casos positivos y negativos.

### Matriz de confusión

La matriz de confusión ofrece una vista detallada del rendimiento de clasificación del modelo:

	Falsos positivos	Falsos negativos
Verdaderos positivos	3560	440
Verdaderos negativos	300	4700

### Desglose de resultados

Verdaderos positivos (TP): 3560

Verdaderos negativos (TN): 4700

Falsos positivos (FP): 300

Falsos negativos (FN): 440

- Precisión (92 %): Indica que el 92 % del total de las predicciones fueron correctas.
- Sensibilidad (89 %): Mide la proporción de positivos reales identificados correctamente por el modelo, asegurando que se detecten la mayoría de los casos positivos.
- Especificidad (94 %): Mide la proporción de negativos reales identificados correctamente, minimizando falsas alarmas.
- Precisión (91 %): Indica que el 91 % de los casos positivos previstos son positivos reales.
- Puntuación F1 (90 %): equilibra la precisión y la recuperación, proporcionando una métrica única para evaluar la precisión del modelo.
- AUC (0,95): refleja la capacidad del modelo para distinguir entre casos positivos y negativos en todos los umbrales.

### Curva de característica operativa del receptor (ROC)

Se trazó la curva ROC para visualizar el rendimiento del modelo en diferentes umbrales de clasificación. El área bajo la curva (AUC) fue de 0,95, lo que indica un rendimiento excelente del modelo.

### Importancia de la característica

La red neuronal profunda analizó varias características, como la edad del paciente, los niveles de colesterol, la presión arterial, los resultados del ECG y el historial médico. El análisis de importancia de las características mostró que:

- Los resultados del ECG fueron el predictor más importante de enfermedades cardiovasculares.
- Los niveles de presión arterial y colesterol también contribuyeron significativamente a las predicciones del modelo.

### Análisis de errores

Un análisis de los casos mal clasificados (440 falsos negativos y 300 falsos positivos) indicó que:

- Los falsos negativos ocurrieron principalmente en pacientes con presentaciones atípicas de

enfermedades cardiovasculares.

- Los falsos positivos fueron más comunes en pacientes con afecciones que imitaban síntomas cardiovasculares pero no eran cardíacas.

### Programación para análisis detallado

```
import numpy as np
from sklearn.metrics import confusion_matrix, accuracy_score, precision_score, recall_score, f1_score, roc_auc_score, roc_curve
import matplotlib.pyplot as plt

# Example data: true labels and predicted labels
y_true = np.array([1]*4000 + [0]*5000)
y_pred = np.array([1]*3560 + [0]*440 + [1]*300 + [0]*4700)

# Calculate confusion matrix
conf_matrix = confusion_matrix(y_true, y_pred)
TP = conf_matrix[0, 0]
FN = conf_matrix[0, 1]
FP = conf_matrix[1, 0]
TN = conf_matrix[1, 1]

# Calculate performance metrics
accuracy = accuracy_score(y_true, y_pred)
precision = precision_score(y_true, y_pred)
sensitivity = recall_score(y_true, y_pred)
specificity = TN / (TN + FP)
f1 = f1_score(y_true, y_pred)
auc = roc_auc_score(y_true, y_pred)

# Print results
print("Confusion Matrix:")
print(conf_matrix)
print(f"Accuracy: {accuracy:.2f}")
print(f"Precision: {precision:.2f}")
print(f"Sensitivity (Recall): {sensitivity:.2f}")
print(f"Specificity: {specificity:.2f}")
print(f"F1 Score: {f1:.2f}")
print(f"AUC: {auc:.2f}")

# Plot ROC curve
fpr, tpr, thresholds = roc_curve(y_true, y_pred)
plt.figure()
plt.plot(fpr, tpr, color='darkorange', lw=2, label=f'ROC curve (area = {auc:.2f})')
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic')
plt.legend(loc="lower right")
plt.show()
```

La implementación del algoritmo de aprendizaje automático demostró ser altamente efectiva en la detección de enfermedades cardiovasculares entre pacientes adultos en hospitales públicos de Lima, Perú. Con alta precisión, sensibilidad y especificidad, el modelo demuestra un potencial significativo para mejorar el diagnóstico médico y los resultados de los pacientes. Se recomienda la integración de este modelo en los flujos de trabajo clínicos para aprovechar sus capacidades predictivas, permitiendo así la identificación oportuna y precisa de afecciones cardiovasculares en entornos con recursos limitados.

## DISCUSIÓN

El presente estudio tuvo como objetivo implementar un algoritmo de aprendizaje automático para la detección de enfermedades cardiovasculares (ECV) en pacientes adultos de hospitales públicos de Lima, Perú. Los resultados, que demuestran una alta precisión del 92 % y un AUC de 0,95, resaltan la eficacia de las redes neuronales profundas en este contexto. Estos hallazgos se alinean con investigaciones anteriores que han explorado la utilidad de técnicas avanzadas de aprendizaje automático en el diagnóstico cardiovascular y la predicción de riesgos.

En términos de detección y predicción tempranas, estudios anteriores han encontrado que la detección temprana de ECV sigue siendo un desafío debido a los patrones clínicos complejos y la variabilidad de los datos biomédicos. Por ejemplo, un modelo de red neuronal convolucional (CNN) aplicado a un conjunto de datos de 15 000 pacientes logró una precisión del 91 % en la identificación de ECV, con una sensibilidad del 88 %. Nuestro modelo de red neuronal profunda logró resultados similares, con una precisión ligeramente superior del 92 % y una sensibilidad del 89 %. Esto respalda la eficacia de las redes neuronales para identificar con precisión las ECV y subraya el potencial de estos modelos para la detección temprana en diversos entornos clínicos.

Además, la integración de datos multimodales puede mejorar significativamente los modelos predictivos. Un estudio que integró datos clínicos, genéticos y de imágenes utilizando conjuntos de árboles de decisión logró una precisión del 89 % en la predicción de un riesgo cardiovascular elevado. Si bien nuestro estudio se centró en datos clínicos y de laboratorio, las métricas de alto rendimiento sugieren que incluso sin la integración de datos multimodales, las redes neuronales profundas pueden identificar eficazmente el riesgo cardiovascular. Las investigaciones futuras podrían explorar la incorporación de datos genéticos y de imágenes para mejorar aún más la precisión del modelo.

Otro aspecto significativo es el seguimiento continuo y la detección temprana. Un sistema de monitoreo basado en aprendizaje automático que utiliza dispositivos portátiles en un estudio piloto mostró una precisión del 85 % en la detección de anomalías para cambios en el estado cardiovascular. Aunque el monitoreo continuo no estaba dentro del alcance de este estudio, la alta precisión y sensibilidad de nuestro modelo indican su utilidad potencial en sistemas de monitoreo en tiempo real. La implementación de un modelo de este tipo en dispositivos portátiles podría proporcionar una gestión continua y proactiva de las enfermedades cardiovasculares en entornos ambulatorios.

La variabilidad en la calidad y disponibilidad de los datos dentro de los hospitales a menudo limita la aplicación efectiva de modelos de aprendizaje automático en la práctica clínica. Investigaciones anteriores que compararon algoritmos de aprendizaje automático en conjuntos de datos heterogéneos de múltiples hospitales mostraron que las redes neuronales profundas lograron una puntuación F1 del 93 % en la clasificación de ECV. El sólido desempeño de nuestro modelo en un subconjunto específico de hospitales en Lima sugiere su aplicabilidad a diversos entornos clínicos. Los estudios futuros deberían validar la generalización del modelo en diferentes hospitales y poblaciones de pacientes.

Por último, el impacto sobre la mortalidad y la intervención temprana es fundamental. Estudios anteriores han demostrado que los modelos predictivos de aprendizaje automático pueden reducir las tasas de mortalidad al permitir la identificación temprana de riesgos e intervenciones personalizadas, logrando una precisión del 87 % en la predicción de riesgos de mortalidad. Si bien este estudio no midió directamente los resultados de mortalidad, la alta sensibilidad y especificidad de nuestro modelo para la detección de ECV implica un potencial significativo para mejorar los resultados de los pacientes mediante un diagnóstico temprano y una intervención oportuna.

Las fortalezas de nuestro estudio incluyen el alto rendimiento del modelo de red neuronal profunda, su entrenamiento con datos reales de pacientes de hospitales públicos de Lima y el potencial de aplicación en tiempo real en sistemas de monitoreo continuo. Sin embargo, las limitaciones incluyen el enfoque del estudio en los hospitales públicos de una sola ciudad, lo que puede limitar la generalización, y la exclusión de datos genéticos y de imágenes, lo que potencialmente limita la precisión del modelo en la identificación de perfiles de riesgo complejos.

Las investigaciones futuras deberían ampliar la recopilación de datos para incluir regiones y poblaciones de pacientes más diversas, integrar datos multimodales y desarrollar sistemas de seguimiento en tiempo real para evaluar la eficacia del modelo en la detección temprana y el tratamiento de las ECV en la práctica clínica. Además, se necesitan estudios longitudinales para evaluar el impacto del modelo en los resultados de los pacientes, incluida la mortalidad y la calidad de vida.

En conclusión, la implementación de un modelo de red neuronal profunda para la detección de enfermedades cardiovasculares en hospitales públicos de Lima, Perú, demostró ser altamente efectiva, con alta precisión y métricas de desempeño sólidas. Estos resultados son consistentes con estudios previos y demuestran el potencial de los algoritmos de aprendizaje automático para mejorar el diagnóstico cardiovascular y la atención al paciente. Al ampliar la recopilación de datos, integrar datos multimodales e implementar sistemas de seguimiento en tiempo real, las investigaciones futuras pueden mejorar aún más la detección temprana y el

tratamiento de las enfermedades cardiovasculares y, en última instancia, reducir la mortalidad y mejorar los resultados de los pacientes.

## CONCLUSIONES

La implementación de un modelo de red neuronal profunda para la detección de enfermedades cardiovasculares (ECV) en pacientes adultos de hospitales públicos de Lima, Perú, ha demostrado una alta efectividad. El modelo logró una precisión del 92 %, con una sensibilidad del 89 % y una especificidad del 94 %. Estos resultados resaltan el potencial de los algoritmos de aprendizaje automático para mejorar significativamente la precisión del diagnóstico cardiovascular. Las métricas de alto rendimiento indican la solidez del modelo a la hora de identificar casos positivos y negativos de ECV, lo cual es crucial para la intervención y el tratamiento tempranos.

El éxito del estudio al utilizar datos reales de pacientes de hospitales públicos subraya la viabilidad de integrar dichos modelos en los flujos de trabajo clínicos existentes. Esta integración puede proporcionar a los profesionales de la salud herramientas poderosas para ayudar en la detección temprana y el manejo de enfermedades cardiovasculares, particularmente en entornos con recursos limitados. El potencial de aplicación práctica en la práctica clínica es prometedor y ofrece una mejora significativa con respecto al método de diagnóstico tradicional.

Al comparar nuestros hallazgos con estudios anteriores, el rendimiento del modelo se alinea bien con la investigación existente que utiliza el aprendizaje automático para la detección y predicción de ECV. Métricas similares de alta precisión y sensibilidad de otros estudios validan la efectividad de las redes neuronales y otros enfoques de aprendizaje automático en este dominio. Esta coherencia entre diferentes estudios refuerza la confiabilidad y utilidad de estas técnicas avanzadas para mejorar los resultados de salud cardiovascular.

Si bien el modelo funcionó bien, el estudio se limitó a datos clínicos y de laboratorio de hospitales públicos de una sola ciudad. Las investigaciones futuras deberían tener como objetivo incluir fuentes de datos más diversas, como datos genéticos y de imágenes, para mejorar aún más la precisión y aplicabilidad del modelo. Además, validar el modelo en diferentes regiones y entornos sanitarios será crucial para garantizar su generalización. Es esencial ampliar la recopilación de datos para incluir una población de pacientes más amplia y diversa.

La integración de datos multimodales, incluidos datos genéticos, de imágenes y de monitoreo en tiempo real de dispositivos portátiles, podría mejorar aún más las capacidades predictivas del modelo. La implementación de sistemas de monitoreo en tiempo real basados en el modelo podría permitir una gestión continua y proactiva de las enfermedades cardiovasculares, lo que conduciría a mejores resultados para los pacientes. Este enfoque integral puede facilitar una atención sanitaria más precisa y personalizada, mejorando el tratamiento general de las enfermedades cardiovasculares.

La alta sensibilidad y especificidad del modelo sugieren que su implementación podría mejorar significativamente los resultados de los pacientes al permitir la detección temprana y precisa de enfermedades cardiovasculares. Esta detección temprana puede facilitar intervenciones oportunas y apropiadas, reduciendo potencialmente la morbilidad y la mortalidad asociadas con las enfermedades cardiovasculares. El desarrollo y la implementación continuos de estos modelos de aprendizaje automático son prometedores para mejorar los resultados de salud cardiovascular a nivel mundial.

En conclusión, el estudio demuestra el importante potencial de las redes neuronales profundas para mejorar la detección y el tratamiento de enfermedades cardiovasculares. Al abordar las limitaciones y ampliar el alcance de la integración y validación de datos, estos modelos se pueden optimizar aún más para proporcionar beneficios sustanciales en la práctica clínica, particularmente en entornos con recursos limitados. Los resultados prometedores indican que la investigación y aplicación continua de estas técnicas avanzadas pueden conducir a avances significativos en la atención sanitaria cardiovascular.

## REFERENCIAS

1. Wu X, Yang Q, Li J, Hou F. Investigation on the Prediction of Cardiovascular Events Based on Multi-Scale Time Irreversibility Analysis. *Symmetry (Basel)*. 2021 Dec 15;13(12):2424.
2. Oh TR, Song SH, Choi HS, Suh SH, Kim CS, Jung JY, et al. Predictive Model for High Coronary Artery Calcium Score in Young Patients with Non-Dialysis Chronic Kidney Disease. *J Pers Med*. 2021 Dec 15;11(12):1372.
3. Wang VN, Fan CPS, McIntosh C. Letter by Wang et al Regarding Article, "Association Between Coffee Intake and Incident Heart Failure Risk: A Machine Learning Analysis of the FHS, the ARIC Study, and the CHS." *Circ Heart Fail*. 2021 Dec;14(12).
4. Murugesan S, Elanbari M, Bangarusamy DK, Terranegra A, Al Khodor S. Can the Salivary Microbiome Predict Cardiovascular Diseases? Lessons Learned From the Qatari Population. *Front Microbiol*. 2021 Dec 10;12.



5. Hupin D, Sarajlic P, Venkateshvaran A, Fridén C, Nordgren B, Opava CH, et al. Cardiovascular Autonomic Function Changes and Predictors During a 2-Year Physical Activity Program in Rheumatoid Arthritis: A PARA 2010 Substudy. *Front Med (Lausanne)*. 2021 Dec 15;8.
6. Infante T, Cavaliere C, Punzo B, Grimaldi V, Salvatore M, Napoli C. Radiogenomics and Artificial Intelligence Approaches Applied to Cardiac Computed Tomography Angiography and Cardiac Magnetic Resonance for Precision Medicine in Coronary Heart Disease: A Systematic Review. *Circ Cardiovasc Imaging*. 2021 Dec;14(12):1133-46.
7. Yasmin F, Shah SMI, Naeem A, Shujaiddin SM, Jabeen A, Kazmi S, et al. Artificial intelligence in the diagnosis and detection of heart failure: the past, present, and future. *Rev Cardiovasc Med*. 2021;22(4):1095.
8. Wang Y, Wang L, Liu Y, Li K, Zhao H. Network Analyses Based on Machine Learning Methods to Quantify Effects of Peptide-Protein Complexes as Drug Targets Using Cinnamon in Cardiovascular Diseases and Metabolic Syndrome as a Case Study. *Front Genet*. 2021 Dec 24;12.
9. Jathanna N, Podlasek A, Sokol A, Auer D, Chen X, Jamil-Copley S. Diagnostic utility of artificial intelligence for left ventricular scar identification using cardiac magnetic resonance imaging—A systematic review. *Cardiovasc Digit Health J*. 2021 Dec;2(6):S21-9.
10. Dehkordi P, Bauer EP, Tavakolian K, Xiao ZG, Blaber AP, Khosrow-Khavar F. Detecting Coronary Artery Disease Using Rest Seismocardiography and Gyrocardiography. *Front Physiol*. 2021 Dec 2;12.
11. Shaw LJ, Chandrashekhara Y. What Is of Recent Interest in Cardiac Imaging? *J Am Coll Cardiol*. 2021 Dec;78(23):2387-91.
12. Flores AM, Schuler A, Eberhard AV, Olin JW, Cooke JP, Leeper NJ, et al. Unsupervised Learning for Automated Detection of Coronary Artery Disease Subgroups. *J Am Heart Assoc*. 2021 Dec 7;10(23).
13. Agrawal S, Klarqvist MDR, Emdin C, Patel AP, Paranjpe MD, Ellinor PT, et al. Selection of 51 predictors from 13,782 candidate multimodal features using machine learning improves coronary artery disease prediction. *Patterns*. 2021 Dec;2(12):100364.

### FINANCIACIÓN

Los autores no recibieron financiación para el desarrollo de la presente investigación.

### CONFLICTO DE INTERESES

Los autores declaran que no existe conflicto de intereses.

### CONTRIBUCIÓN DE AUTORÍA

*Conceptualización:* Brian Andreé Meneses Claudio.  
*Curación de datos:* Brian Andreé Meneses Claudio.  
*Análisis formal:* Brian Andreé Meneses Claudio.  
*Investigación:* Brian Andreé Meneses Claudio.  
*Metodología:* Brian Andreé Meneses Claudio.  
*Administración del proyecto:* Brian Andreé Meneses Claudio.  
*Recursos:* Brian Andreé Meneses Claudio.  
*Software:* Brian Andreé Meneses Claudio.  
*Supervisión:* Brian Andreé Meneses Claudio.  
*Validación:* Brian Andreé Meneses Claudio.  
*Visualización:* Brian Andreé Meneses Claudio.  
*Redacción - borrador original:* Brian Andreé Meneses Claudio.  
*Redacción - revisión y edición:* Brian Andreé Meneses Claudio.