

Aprendizaje automático para predecir el diagnóstico temprano de personas con hipertensión arterial: Revisión sistemática

Machine learning to predict the early diagnosis of people with arterial hypertension: A systematic review

Christian J. Mamani^{1,a}

¹ Universidad Nacional Mayor de Marcos, Facultad de Ingeniería de Sistemas e Informática. Lima, Perú

^a E-mail: christian.mamani2@unmsm.edu.pe, ORCID: <https://orcid.org/0009-0003-6955-3711>

Resumen

El aprendizaje automático es ampliamente utilizado en el campo de la medicina y va aumentando cada vez más por la cantidad de datos almacenados. Los resultados que obtienen los modelos predictivos sirven como soporte para una buena toma de decisiones al personal médico. El objetivo fue identificar qué métodos, variables y algoritmos son utilizados para la predicción en la hipertensión arterial utilizando aprendizaje automático. Se realizó la revisión sistemática en los buscadores de PubMed, ScienceDirect, Redalyc y Scopus, estudios referentes a la predicción del diagnóstico temprano de la hipertensión arterial en personas. Para el proceso de selección se utilizó Prisma, aplicando distintos criterios de exclusión. Se encontraron 10.916 artículos, siendo incluidos 15 para la revisión. Varios autores aplican más de un modelo para comparar los resultados en sus investigaciones. El modelo más mencionado, usado y de mejor resultado fue Random Forest obtuvo una Especificidad (0.96), Precisión (0.92) y AUC(0.95). Random forest es un algoritmo de ML supervisado y es el mas usado para este tipo de investigaciones. Finalmente se logró proporcionar los modelos mayormente mencionados y utilizados en las investigaciones, así mismo identificar los modelos con un alto rendimiento predictivo. Existen pocos estudios que combinen datos demográficos, clínicos y patológicos, para implementar modelos en la predicción del diagnóstico temprano de personas con hipertensión arterial.

Palabras clave: Aprendizaje automático, modelo, hipertensión arterial, pacientes, diagnóstico temprano.

Abstract

Machine learning is widely used in the medical field and is increasing more and more because of the amount of data stored. The results obtained by the predictive models serve as support for good decision-making for medical personnel. The objective was to identify which methods, variables, and models are used for the prediction of arterial hypertension using machine learning. The systematic review was carried out in the PubMed, ScienceDirect, Redalyc and Scopus search engines, studies referring to the prediction of early diagnosis of arterial hypertension in people. For the selection process, Prisma was used, applying different exclusion criteria. 10,916 articles were found, 15 being included for the review. Several authors apply more than one model to compare the results in their research. The model most mentioned, used and with the best result was Random Forest, obtaining a Specificity (0.96), Precision (0.92) and AUC (0.95). Finally, it was possible to provide the models most mentioned and used in the investigations, as well as to identify the models with a high predictive performance. There are few studies that combine demographic, clinical, and pathological data to implement models to predict early diagnosis of people with arterial hypertension.

Keywords: Machine learning, model, arterial hypertension, patients, early diagnostics.

Recibido: 21/08/2023 - Aceptado: 23/06/2024 - Publicado: 30/06/2024

Citar como:

Mamani, C. (2024). Aprendizaje automático para predecir el diagnóstico temprano de personas con hipertensión arterial: Revisión sistemática. Revista Peruana de Computación y Sistemas, 6(1):101-109. <https://doi.org/10.15381/rpcs.v6i1.26000>

© Los autores. Este artículo es publicado por la Revista Peruana de Computación y Sistemas de la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional Mayor de San Marcos. Este es un artículo de acceso abierto, distribuido bajo los términos de la licencia Creative Commons Atribución 4.0 Internacional (CC BY 4.0) [<https://creativecommons.org/licenses/by/4.0/deed.es>] que permite el uso, distribución y reproducción en cualquier medio, siempre que la obra original sea debidamente citada de su fuente original.

1. Introducción

El aprendizaje automático y la inteligencia artificial han contribuido al desarrollo de diversas aplicaciones como el diagnóstico basado en imágenes, la predicción de resultados clínicos, el monitoreo de pacientes, entre otras. Sin embargo, este camino no ha estado exento de desafíos, comenzando por la disponibilidad de datos de calidad para entrenar modelos [1].

Actualmente se estima que en el mundo hay 1280 millones de personas con hipertensión arterial (HTA) y que la mayoría (cerca de dos tercios) viven en países de ingresos bajos y medianos, en donde el 46% de adultos hipertensos desconocen que padecen esta afección, en donde una de cada cinco personas hipertensas (21%) tiene controlado el problema. Esta enfermedad es una de las causas principales de muerte prematura en el mundo y es por ello que la Organización Mundial de la Salud tiene como una de sus metas reducir la prevalencia de la hipertensión en un 25% en 2030 [2].

En el Perú en el 2021, el 17.2% de personas mayores de 15 años presentaron presión arterial alta [3]. Según el Ministerio de Salud en su último informe la presión arterial en personas aumentó a 22.1% siendo una preocupación constante entre médicos e investigadores, constituyendo un problema de salud pública [4].

Dentro de las regiones, la costa presenta un 19.9%, la sierra un 13.7% y la selva un 10.7%, la región de Puno se ubica en el puesto 19 a nivel nacional con un 12.1% de casos con HTA. A su vez, la sierra ocupa el último lugar con un 49.9% de personas que recibieron algún tipo de tratamiento médico [3], dando a conocer que las personas no acuden a realizarse el tratamiento y seguimiento correspondiente.

Por este motivo la importancia del rápido diagnóstico de esta enfermedad conocida como el “asesino silencioso”, la detección temprana, el tratamiento apropiado y el control de la hipertensión producen importantes beneficios sanitarios y de índole económico, el tratamiento de las complicaciones de la HTA abarca intervenciones costosas o la diálisis, lo cual agotan los presupuestos del estado [5].

Este documento revisa literatura relevante de artículos publicados entre 2017 y 2023. Antes del 2017 se pudo observar en los principales buscadores que no existen muchos estudios en esta área. Se seleccionaron y estudiaron 15 artículos en donde se habla acerca de los modelos predictivos del aprendizaje automático aplicado a pacientes o personas diagnosticadas con hipertensión arterial. Dados los avances en el aprendizaje automático en las últimas décadas, se realizó la revisión con el propósito de poder conocer y entender mejor sobre cuáles son los principales buscadores que tienen mayor publicación en la producción de investigación referente al área de estudio, así mismo poder analizar las métricas que son más utilizadas para medir un modelo, conocer cuales son los algoritmos más usados para los casos de hipertensión arterial, así mismo poder identificar las variables que son consideradas para el entrenamiento

del modelo, conocer las técnicas o métodos utilizados para en entrenamiento de los modelos y finalmente identificar la cantidad de población que utilizan en sus dataset para realizar el entrenamiento del modelo.

2. Metodología

En el presente trabajo, se siguió la metodología de la revisión sistemática de la literatura propuesta [6].

Las preguntas de investigación (Research questions - RQ) para el presente estudio son:

- RQ1: ¿Cuáles son los principales buscadores con mayor publicación en la producción de investigación en el área?
- RQ2: ¿Cuáles son las métricas más usadas y mencionadas en la clasificación y medición de los algoritmos de machine learning?
- RQ3: ¿Cuáles son actualmente los algoritmos mayormente utilizados en el entorno clínico referente a la hipertensión arterial?
- RQ4: ¿Principales variables que son seleccionadas para el entrenamiento del modelamiento de predicción en hipertensión arterial?
- RQ5: ¿Qué técnicas o métodos son utilizados para las investigaciones de machine learning en pacientes con hipertensión arterial?
- RQ6: ¿Cuál es la cantidad de registros que utilizan para el modelamiento de datos?

2.1. Estrategia de búsqueda

Las fuentes de datos que se utilizaron para la búsqueda de los artículos fueron: PubMed, ScienceDirect, Redalyc y Scopus. Fueron consideradas estas fuentes de información ya que proporcionan una gran cantidad de artículos relevantes para la investigación. Se empleó las siguientes palabras claves para la estrategia de búsquedas en los repositorios de datos como se muestra en la Tabla 1.

Para la búsqueda en los repositorios se han utilizado las siguientes ecuaciones de búsqueda, tal como se muestra en la Tabla 2.

2.2. Estudios identificados

En la fig. 1, se muestran los resultados obtenidos de la búsqueda de las fuentes de datos.

2.3. Criterios de exclusión

Para la presente investigación los criterios de exclusión (CE) deben justificar que los artículos obtenidos deben estar alineados a los objetivos y propósitos de la investigación.

- CE1: Artículos que tengan mayor a 7 años de antigüedad (<2017).
- CE2: Los artículos que no estén escritos en inglés o español.

Tabla 1

Palabras claves de búsqueda

Descriptor	
Español	Inglés
Aprendizaje Automático	Machine Learning
Diagnóstico temprano de pacientes	Early diagnosis
hipertensión arterial / hipertension	Arterial hypertension / hypertension
Método / modelo / predecir	Method / Model / Predict


Tabla 2

Fuentes de datos y ecuación de búsqueda

Fuente	Ecuación de búsqueda
PubMed	(machine learning) AND ((early diagnosis) OR (arterial hypertension) OR (hypertension)) AND ((method) OR (model) OR (predict))
ScienceDirect	(machine learning) AND ((early diagnosis) OR (arterial hypertension) OR (hypertension)) AND ((method) OR (model) OR (predict))
Redalyc	machine learning AND ((early diagnosis) OR (arterial hypertension) OR (hypertension OR "hypertension arterial")) AND ((method) OR (model) OR (predict))
Scopus	"machine learning" AND ("hypertension" OR "arterial hypertension" OR "early diagnosis") AND ((method) OR (model) OR (predict))

Figura 1

Resultado de artículos relevantes y sus fuentes de datos



- CE3: Artículos cuyos campos de estudio no están relacionados a la salud y medicina en personas.
- CE4: Artículos que no estén relacionados a la hipertensión arterial.
- CE5: Artículos que no tengan disponibilidad de texto completo gratuito.
- CE6: Los artículos que no mencionan una metodología, modelo y resultados.
- CE7: Artículos que no estén alineados con el propósito de predicción de la hipertensión arterial, prevalencia o diagnóstico.

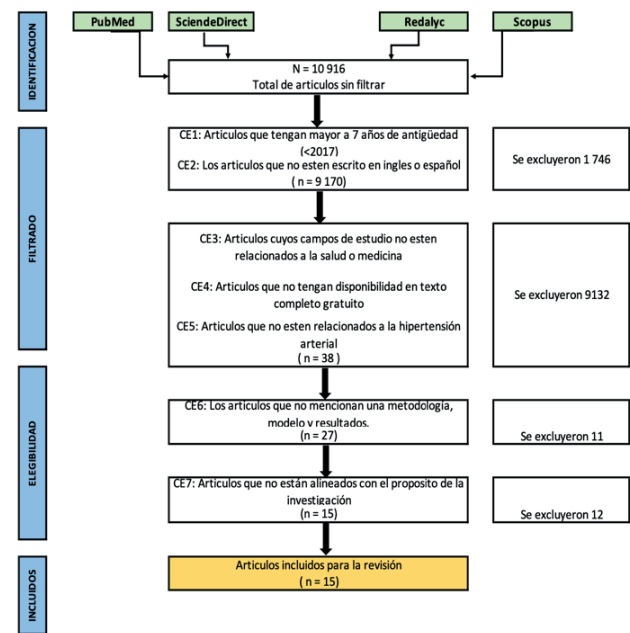
2.4. Selección de estudios

Para cumplir con el objetivo propuesto, se resume el número de artículos identificados que dentro del contenido incluyan y realzan el machine learning en la hipertensión arterial para posteriormente utilizar el diagrama de flujo Prisma [7].

Inicialmente se obtuvieron un total de 10 916 artículos en diferentes fuentes de datos utilizando las palabras claves. Se utilizaron los criterios para la selección, el filtrado y elegibilidad de los artículos. El resultado de esta etapa son 16 artículos de investigación que están directamente relacionados al tema (ver Fig. 2).

Figura 2

Proceso de selección de artículos con diagrama PRISMA



2.5. Evaluación de calidad

Se debe tomar en cuenta los criterios de calidad (Quality Assurance – QA) para poder realizar una rigurosa revisión de los artículos, para ver que cada uno cumpla con los puntos requeridos.

- QA1: ¿El artículo está disponible e indexado en los buscadores científicos?
- QA2: ¿Los modelos utilizados están explicados claramente?
- QA3: ¿El documento menciona los algoritmos empleados en la investigación?
- QA4: ¿La investigación involucra las variables y dimensiones de los datos utilizados?
- QA5: ¿Se considera útil y bien estructurado el documento?
- QA6: ¿Artículos que registran una población y datos clínicos en su investigación?

Cada uno de los artículos incluidos han sido evaluados por los QA y que a su vez cumplan con las preguntas que se pretenden responder con la revisión sistemática.

2.6. Estrategias de extracción de datos

En base a lo planteado sobre los objetivos, se utilizó los artículos para responder a las preguntas de investigación. Para lo cual, los artículos seleccionados cuentan con información relevante como son: ID del artículo, título del artículo, fuente, país, tipo de publicación, autores, números de citas, resumen, palabras clave y conclusiones. Para tener mejor organizados los documentos se utilizó la herramienta Mendeley.

2.7. Síntesis y análisis de datos

Durante la selección de artículos se realizaron cada uno de los criterios de exclusión donde PUBMED

empezó con una gran cantidad de artículos. Así mismo Redalyc es el buscador con menos publicaciones encontradas referente al estudio y llegando solo hasta el CE5. La base de datos Scopus durante todo el proceso de CE es la que se mantuvo con altos índices de artículos seleccionados y al final de los CE se mantuvo con 10 artículos relacionados altamente con el tema (ver Fig. 3).

Figura 3
Total de artículos por cada CE

	INICIO	CE1	CE2	CE3	CE4	CE5	CE6	CE7
SCOPUS	2622	2520	2507	1216	630	19	14	10
PUBMED	4529	4360	4349	801	118	7	5	2
SCIENCEDIRECT	3015	2000	1986	1712	640	9	6	3
REDALYC	805	300	291	280	56	1	0	0
TOTAL	10971	9180	9133	4009	1444	36	25	15

Existen muchas investigaciones que utilizan machine learning (ML). Para esta investigación se buscó exclusivamente artículos que estén enfocadas a la hipertensión arterial y sus diagnósticos en personas las cuales fueron seleccionados finalmente (ver Tabla 3 en apéndice).

3. Discusión de resultados

Está revisión demuestra que las técnicas y modelos de ML utilizadas en las investigaciones aportan un resultado favorable en la predicción del diagnóstico temprano de personas con hipertensión arterial. Los estudios incluidos han utilizado varios modelos para comparar los resultados para así elegir el del más alto rendimiento de precisión.

La presente sección responde a cada una de las preguntas formuladas.

3.1. RQ1: ¿Cuáles son los principales buscadores con mayor publicación en la producción de investigación en el área?

La cantidad de artículos es un indicador muy importante el cual permite determinar el avance de una determinada área de investigación [6].

De 10 971 artículos encontrados se consideraron 15 artículos para realizar la revisión sistemática dentro de las cuales pasaron hasta el CE7. Se tomaron en cuenta estudios publicados en los últimos 7 años (2017-2023), para lo cual del CE1 al CE4 han sido filtrados por cada uno de los buscadores seleccionados y finalmente a partir del CE5 han sido revisados minuciosamente para el respectivo análisis y extracción de la información. (Ver Fig. 4) se muestran los buscadores con mayor número de investigaciones filtradas según el área de estudio. Scopus lidera con 10 artículos y ScienceDirect con 3 artículos. Estos datos nos permiten entender dónde existen más artículos relacionados al tema de investigación.

Se muestran la cantidad de artículos que fueron seleccionados tanto por buscadores y publicaciones realizadas por año, liderando el año 2023 con 6 publicaciones (ver Fig. 5). Se observó que los años 2016 y 2021 no se encontraron publicaciones referentes al área de investigación. Se concluyó que los años 2022

Figura 4
Total de artículos por buscadores

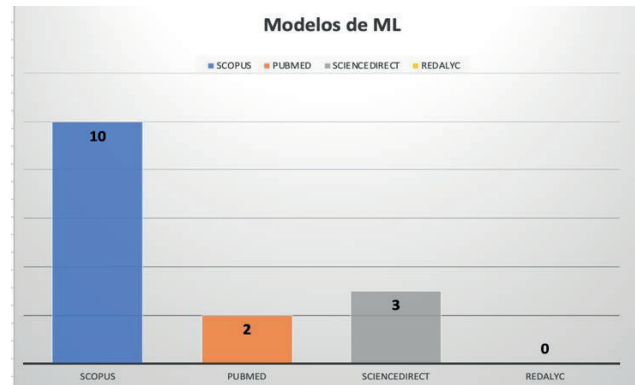


Figura 5
Cantidad de artículos publicados por año



y 2023 se están realizando más investigaciones y que van tomando mayor relevancia en los investigadores la importancia de la hipertensión arterial utilizando métodos de ML.

3.2. Q2: ¿Cuáles son las métricas más mencionadas y usadas en la clasificación y medición de los modelos de machine learning?

Para medir los resultados de un modelo existen diversas acciones y métricas que determinan si un modelo es adecuado como son: Exactitud o Accuracy, Sensibilidad o Recall, Especificidad, Precisión, F1 score y curva de característica del receptor (receiver operating characteristic curve - ROC) donde AUC=1 es lo ideal.

Dentro de la revisión sistemática encontramos algunas de las métricas y los respectivos artículos que hacen mención (Ver Tabla. 4).

Tabla 4
Métricas y los artículos revisados que los utilizan

Métricas	# Artículos	Total
Sensibilidad	P11 [8], P5 [9], P9 [10], P10 [11], P8 [12], P13 [13], P1 [16], P6 [14]	8
Especificidad	P11 [8], P9 [10], P10 [11], P12 [15]	4
Exactitud	P11 [8], P1 [16], P13 [13], P5 [9]	4
Precisión	P4 [17], P11 [8], P13 [13], P2[18], P6 [14], P5 [9], P9 [10], P8 [12], P12 [15]	9
AUC	P11 [8], P13 [13], P2[18], P6 [14], P3 [19], P5 [9], P9 [10], P8 [12], P12 [15]	9

Tabla 5*Métricas y los modelos que los utilizan*

Algoritmos	Métricas				
	Sensibilidad	Especificidad	Precisión	AUC	Exactitud
KNN	P13	P13	P4, P13	P13	
Randon Forest	P11, P5	P11, P12	P11, P5, P12	P11, P5, P12	P11, P5
Redes Neuronales	P1				P1
CatBoost			P2	P2	
Regresión Logística	P8		P8	P3, P8	P8
Redes Bayesianas	P9	P9	P9	P9	
XgBoots	P10				
ensemble	P6		P6	P6	
TOTAL	8	4	9	9	4

La Sensibilidad (9), Precisión (9) y la AUC (10) son las más mencionadas en las investigaciones para mostrar sus resultados y comparar frente a los demás modelos.

En la Tabla 5. Se muestran los algoritmos con los respectivos artículos que hacen mención a las métricas utilizadas para mostrar sus resultados. Precisión y AUC son las métricas más utilizadas con un total de 9 artículos. El modelo de Randon Forest utilizó sensibilidad, especificidad, precisión, AUC y exactitud para mostrar sus resultados [12][8][15].

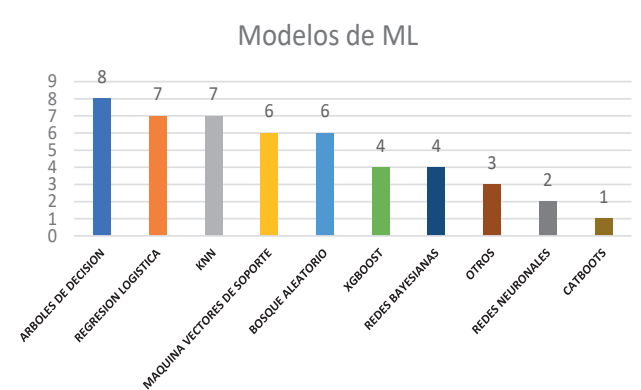

3.3. RQ3: ¿Cuáles son actualmente los algoritmos mayormente utilizados en el entorno clínico referente a la hipertensión arterial?

Existen diversos algoritmos de Machine learning para determinar el mejor algoritmo suele ser muy variable ya que depende de las métricas y distintos factores. En los artículos revisados se encontró que en las investigaciones utilizaron más de un algoritmo para luego ser probados y comparar los resultados, la investigación [10] [11] utilizaron solamente 1 modelo para su investigación como son Redes Bayesianas y Xgboost respectivamente, por otro lado la investigación [15] utilizó 2 algoritmos como arboles de decisión y maquina de vectores de soporte, mientras que [16][14] [19][9] utilizaron 3 algoritmos de la misma manera los artículos [17][12] compararon 4 algoritmos y finalmente [8] [18] [20] compararon 5 modelos para su investigación. En promedio se tomaron de 3 a 4 modelos para realizar la comparación de modelos y ver cuál obtiene un mejor resultado de acuerdo a sus datos y al objetivo planteado en cada una de sus investigaciones.

Los modelos más mencionados y seleccionados para realizar las comparaciones en sus investigaciones, para así poder obtener y seleccionar el modelo con el mejor resultado. Árboles de decisión fue utilizado en 8 artículos, regresión logística y KNN en 7 artículos (ver Fig. 6).

Se realizó la revisión sistemática de las investigaciones y los modelos que fueron elegidos, se seleccionó aquellos que dieron un buen resultado con respecto a los demás algoritmos que compararon en

sus investigaciones, en los artículos [8][9][15] Randon Forest fue seleccionado por obtener el mejor resultado, en los artículos [17][13] eligieron el modelo KNN por obtener un mejor resultado, en los artículos [16] [21] Redes neuronales arrojó un mejor resultado y finalmente en [19][12] el mejor modelo fue Regresión Logística (ver Fig. 7).

Figura 6*Algoritmos más usados en las investigaciones***Figura 7***Total, de modelos con mejores resultados*

Existen diversas métricas para medir un buen modelo para las investigaciones, en la revisión sistemática realizada la métrica más usada fue la Precisión tal como se vio en la RQ2. Se seleccionaron los 3 modelos más usados y se comparó con el resultado que obtuvo la métrica más usada que fue la de precisión. El resultado más alto fue el que obtuvo una precisión de 92% con el modelo Randon Forest. Se muestran los 3 mejores modelos y sus comparaciones con sus respectivas métricas de precisión (ver Tabla 6).

Tabla 6
Algoritmo con mejores resultados

N°	# Artículos	Algoritmos	Precisión
1	P12[15]	Randon Forest	92%
2	P8[12]	Regresión Logística	89.8%
3	P13[13]	KNN	84%

3.4. RQ4: ¿Principales variables que son seleccionadas para el entrenamiento del modelamiento de predicción en hipertensión arterial?

Para determinar las principales variables que son utilizadas en las investigaciones se analizaron los artículos de la revisión sistemática, para la cual se identificó las características principales usadas en las investigaciones las cuales fueron tomadas en cuenta para cargar su dataset y así poder aplicar el nivel de significancia de cada variable. Tenemos datos demográficos, datos clínicos y datos patológicos tal como se ve en la Tabla 7 con sus respectivas cantidades.

Dentro de cada tipo existen diversas variables las cuales se detallan a continuación:

Las variables que conforman los Datos Demograficos son: Edad, sexo, raza, estado civil, cod. Postal, Índice de Masa Corporal (IMC), Superficie Corporal, Altura, Peso y nivel estudio.

Las variables que conforman los datos Clínicos son: Antecedentes de HTA, historial médico, Sístole, diástole, síntomas, medicamentos, consumo de tabaco, depresión, problema del corazón, diabetes, dolor de cabeza, consumo de alcohol y problemas renales.

Las variables que conforman los datos Patológicos son: Colesterol, glucosa, urea, creatinina, hemoglobina, triglicéridos tal como se observa en la Tabla 8.

Algunas investigaciones mencionan las cantidades de columnas(variables) que utilizaron para el entrenamiento de su modelo, las cantidades fueron: 7, 9, 20, 53 y 37 columnas.

3.5. RQ5: ¿Qué técnicas o métodos son utilizados para las investigaciones de machine learning en pacientes con hipertensión arterial?

En las investigaciones de machine learning referente a la HTA de las investigaciones seleccionadas, muchas de ellas mencionan el porcentaje (%) que utilizan para su entrenamiento, prueba y validación de los modelos, la

Tabla 7
Modelos con mejores resultados

N°	Tipo Variable	Variables
1	Datos Demográficos	11 variables
2	Datos Clínicos	13 variables
3	Datos patológicos	6 variables

Tabla 8
Variables utilizadas en los artículos

Variables	# Artículos	Cantidad
Edad	P4, P11, P1, P13, P2, P6, P3, P5, P9, P10, P7, P8, P14	13
Sexo	P4, P11, P1, P13, P2, P6, P5, P9, P10, P8, P14	11
Imc	P11, P2, P6, P10, P8, P14	6
Peso	P4, P11, P1, P13, P6, P3, P5, P14	8
Sístole	P4, P13, P6, P3, P11, P5, P9, P10, P7, P8, P14	11
Diástole	P4, P13, P6, P3, P11, P5, P9, P10, P7, P8, P14	11
Consumo Cigarrillo	P4, P11, P6, P5, P8, P14	6
Diabetes	P11, P2, P6, P5, P9, P8, P14	7
Consumo Alcohol	P11, P1, P6, P8	4
Colesterol	P4, P13, P5, P9, P8	5
Glucosa	P4, P13, P2, P6, P3	5
Creatinina	P13, P2, P3, P9	4

más frecuente y utilizada en estas investigaciones es 80% entrenamiento y 20 % de testing [11][15], también utilizaron 80% entrenamiento 10% prueba y 10% validación [17][18] son los más comúnmente usadas en los modelos, tal como se muestra en la Tabla 9.

Tabla 9
Distribucion de datos para el procesamiento

Artículos	Entrenamiento	Prueba	Validación
P4	80%	10%	10%
P11	70%	30%	
P13	90%	10%	
P2	80%	10%	10%
P6	75%		25%
P9	70%		30%
P12	80%	20%	


El tipo de algoritmo utilizado en las investigaciones se basa en los modelos de aprendizaje supervisados, estos aprenden funciones a partir de un conjunto de ejemplos. Existen modelo de aprendizaje no supervisado las cuales son poco usados para este tipo de investigaciones.

3.6. RQ6: ¿Cuál es la cantidad de registros que utilizan para el modelamiento de datos?

Los criterios y el tamaño de los dataset utilizados en las investigaciones realizadas son importantes para el proceso de ML y la utilización de los modelos. En las investigaciones revisadas para la población de los modelos de Machine Learning, los principales criterios que se tomaron en cuenta se muestran en la Tabla 10. Los artículos mencionan que utilizaron de 1 a 3 criterios para la selección y cargado de datasets, el criterio más utilizado en los dataset fueron pacientes diagnosticados con HTA en sus historias clínicas.

Tabla 10*Total de criterios utilizados en los datasets*

N°	Criterios	# Artículos	Total
CR1	Pacientes con hipertensión	P4, P1, P13, P2, P6, P3, P5, P9, P10, P7, P8, P12, P14	13
CR2	Recién diagnosticadas con HTA	P4, P11, P2, P3, P5	5
CR3	Pacientes mayores a 130 de diastólica	P4	1
CR4	No hipertensos	P13, P10, P7, P8, P12, P14	6

Figura 8*Rango de años y cantidad de dataset seleccionados*

En el Figura 8 se tiene la cantidad de registros con sus respectivos años los cuales consideraron para su investigación, se tiene un rango de 2005 al 2020 a pesar de tener artículos del 2023 este gráfico nos muestra que solo se tomó muestra hasta el 2020. El mayor rango de años fue de 11 años con 18 258 registros clínicos [14], también se observa que el artículo con mayor registro es de 42 752 con un rango de 8 años[17], esto implica que no necesariamente a mayor rango de años mayor registro.

Dentro de la revisión sistemática también se encontró detalles en los dataset como son: El rango de años que se tomó en los dataset así como la cantidad de registros. Los dataset utilizados tienen un promedio de 5 a 6 años, el de mayor rango de años fue del 2005 al 2016(11) [14], también se tienen dataset con rango de 1 año[12][11]. Con respecto a la cantidad de registros en los dataset, el artículo con mayor cantidad es de 42 752 registros[17] y el de menor cantidad es de 987 registros[9].

Finalmente se pudo verificar que existen artículo del 2023 como lo muestra la Figura 5, sin embargo, para el dataset solamente se tomó en cuenta hasta el 2020 (ver Fig. 8).

4. Conclusiones y trabajos futuros

Este trabajo presentó una revisión acerca de las técnicas de Machine learning para predecir el diagnóstico temprano de hipertensión arterial, teniendo 15 artículos alineados al tema. Se encontraron diversos modelos predictivos en los artículos, muchos de ellos utilizan más de 1 modelo para realizar la comparación y ver cual obtiene un alto rendimiento predictivo. Random forest es un algoritmo de ML supervisado y obtuvo un alto rendimiento predictivo en 3 investigaciones, el

P12 obtuvo una Especificidad (0.96), Precisión (0.92) y AUC (0.95), fue el que obtuvo un mejor resultado frente a las demás y es el más utilizado para este tipo de investigaciones. En cuanto a la población se tomaron datos mayormente de personas diagnosticadas con hipertensión arterial teniendo como variables principales: edad, sexo, imc, peso, sistole, diastole, alcohol y cigarrillo. Estos están altamente asociados con la hipertensión arterial.

Se pudo comprobar que existen pocas investigaciones que combinan datos demográficos, clínicos y patológicos para predecir o detectar la hipertensión arterial y saber su diagnóstico futuro. De la misma manera se pudo verificar la preocupación de los investigadores por esta enfermedad ya que en los últimos años se han publicado 6 investigaciones referentes al tema, pero ninguno tomó datos después del 2020.

Referencias

- [1] K.-H. Yu, A. L. Beam, and I. S. Kohane, "Artificial intelligence in healthcare," *Nat Biomed Eng*, vol. 2, no. 10, pp. 719–731, 2018, doi: 10.1038/s41551-018-0305-z.
- [2] "Organización Mundial de Salud," Mar. 16, 2023. <https://www.who.int/es/news-room/fact-sheets/detail/hypertension> (accessed Jul. 14, 2023).
- [3] INEI, "ENFERMEDADES_ENDES_2021," Enfermedades no transmisibles y transmisibles, 2021, May 2022, Accessed: Oct. 18, 2022. [Online]. Available: https://proyectos.inei.gob.pe/endes/2021/SALUD/ENFERMEDADES_ENDES_2021.pdf
- [4] Ministerio de Salud, "En el Perú, existen 5.5 millones de personas mayores de 15 años que sufren de hipertensión arterial," May 18, 2022. <https://www.gob.pe/institucion/minsa/noticias/607500-en-el-peru-existen-5-5-millones-de-personas-mayores-de-15-anos-que-sufren-de-hipertension-arterial> (accessed Jul. 14, 2023).
- [5] Organización Mundial de la Salud, "Información general sobre la HIPERTENSIÓN en el mundo," Suiza, 2013. Accessed: May 09, 2023. [Online]. Available: https://apps.who.int/iris/bitstream/handle/10665/87679/WHO_DCO_WHD_2013.2_spa.pdf?sequence=1
- [6] B. Kitchenham, "Guidelines for performing Systematic Literature Reviews in Software Engineering," 2007. [Online]. Available: <https://www.researchgate.net/publication/302924724>
- [7] A. Liberati et al., "The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: Explanation and elaboration," *PLoS Medicine*, vol. 6, no. 7, Jul. 2009. doi: 10.1371/journal.pmed.1000100.
- [8] S. Montagna et al., "Machine Learning in Hypertension Detection: A Study on World Hypertension Day Data," *J Med Syst*, vol. 47, no. 1, Dec. 2023, doi: 10.1007/s10916-022-01900-5.
- [9] L. A. AlKaabi, L. S. Ahmed, M. F. Al Attiyah, and M. E. Abdel-Rahman, "Predicting hypertension using machine learning: Findings from Qatar Biobank Study," *PLoS One*, vol. 15, no. 10 October 2020, Oct. 2020, doi: 10.1371/journal.pone.0240370.
- [10] W. Lin et al., "Online prediction model for primary aldosteronism in patients with hypertension in Chinese population: A two-center retrospective study," *Front Endocrinol (Lausanne)*, vol. 13, Aug. 2022, doi: 10.3389/fendo.2022.882148.
- [11] E. A. Martin, A. G. D'Souza, S. Lee, C. Doktorchik, C. A. Eastwood, and H. Quan, "Hypertension identification using inpatient clinical notes from electronic medical records: an explainable, data-driven algorithm study," *CMAJ Open*, vol. 11, no. 1, pp. E131–E139, Jan. 2023, doi: 10.9778/cmajo.20210170.
- [12] R. Kurniawan et al., "Hypertension prediction using machine learning algorithm among Indonesian adults," *IAES International Journal of*

- Artificial Intelligence, vol. 12, no. 2, pp. 776–784, Jun. 2023, doi: 10.11591/ijai.v12.i2.pp776-784.
- [13] Y. Sakka, D. Qarashai, and A. Altarawneh, “Predicting Hypertension using Machine Learning: A Case Study at Petra University,” *International Journal of Advanced Computer Science and Applications*, vol. 14, no. 3, pp. 586–591, 2023, doi: 10.14569/IJACSA.2023.0140368.
- [14] H. Kanegae, K. Suzuki, K. Fukatani, T. Ito, N. Harada, and K. Kario, “Highly precise risk prediction model for new-onset hypertension using artificial intelligence techniques,” *J Clin Hypertens*, vol. 22, no. 3, pp. 445–450, Mar. 2020, doi: 10.1111/jch.13759.
- [15] . S. Reel et al., “Machine learning for classification of hypertension subtypes using multi-omics: A multi-centre, retrospective, data-driven study Articles,” *www.thelancet.com*, vol. 84, 2022, doi: 10.1016/j.
- [16] A. Chaturvedi, S. Srivastava, A. Rai, A. S. Cheema, D. Chelimela, and R. Aravindakshan, “Questionnaire based Prediction of Hypertension using Machine Learning,” 2020, doi: 10.1101/2020.06.18.20133397.
- [17] Y. Hu, J. Huerta, N. Cordella, R. G. Mishuris, and I. C. Paschalidis, “Personalized hypertension treatment recommendations by a data-driven model,” *BMC Med Inform Decis Mak*, vol. 23, no. 1, Dec. 2023, doi: 10.1186/s12911-023-02137-z.
- [18] H. Hae et al., “Machine Learning-Based prediction of Post-Treatment ambulatory blood pressure in patients with hypertension,” *Blood Press*, vol. 32, no. 1, 2023, doi: 10.1080/08037051.2023.2209674.
- [19] B. M. Heo and K. H. Ryu, “Prediction of prehypertension and hypertension based on anthropometry, blood parameters, and spirometry,” *Int J Environ Res Public Health*, vol. 15, no. 11, Nov. 2018, doi: 10.3390/ijerph15112571.
- [20] V. S. Kublanov, A. Y. Dolganov, D. Belo, and H. Gamboa, “Comparison of machine learning methods for the arterial hypertension diagnostics,” *Appl Bionics Biomech*, vol. 2017, 2017, doi: 10.1155/2017/5985479.
- [21] A. Semakova and N. Zvartau, “Data-Driven Identification of Hypertensive Patient Profiles for Patient Population Simulation,” in *Procedia Computer Science*, Elsevier B.V., 2018, pp. 433–442. doi: 10.1016/j.procs.2018.08.269.
- [22] V. Silva, V. S. Souza, R. G. Da Cruz, N. Jazdi, and V. F. De Lucena, “Mobi health: A system to improve medication adherence in hypertensive patients,” in *Procedia Computer Science*, Elsevier B.V., 2018, pp. 366–373. doi: 10.1016/j.procs.2018.10.188.

Apéndice

Tabla 3

Artículos seleccionados

Item	Año	Nombre	Autores	Fuente de datos
P1	2020	Questionnaire based Prediction of Hypertension using Machine Learning [16]	A. Chaturvedi, S. Srivastava, A. Rai	SCOPUS
P2	2023	Machine Learning-Based prediction of Post-Treatment ambulatory blood pressure in patients with hypertension [18]	H. Hae, S. Kang, T. Kim et al.	SCOPUS
P3	2018	Prediction of Prehypertension and Hypertension Based on Anthropometry, Blood Parameters, and Spirometry [19]	B. Heo, K. Ryu	SCOPUS
P4	2023	Personalized hypertension treatment recommendations by a data – driven model [17]	Y. Hu, J. Huerta, N. Cordella et al.	SCOPUS
P5	2020	Predicting hypertension using machine learning: Findings from Qatar Biobank Study [9]	L. Id, L. Id, M. Al et al.	PUBMED
P6	2019	Highly precise risk prediction model for new-onset hypertension [14]	H. Kanegae, K. Suzuki, B. Kyohei	SCOPUS
P7	2017	Comparison of Machine Learning Methods for the Arterial Hypertension Diagnostics [20]	V. Kublanov, A. Dolganiv, D. Belo	SCOPUS
P8	2023	Hypertension prediction using machine learning algorithm among Indonesian adults [12]	R. Kurniawan, B. Utoma, K. Siregar	SCOPUS
P9	2022	Online prediction model for primary aldosteronism in patients with hypertension in Chinese population : A two – center retrospective study [10]	W. Lin, W. Gan, P. Feng	PUBMED
P10	2023	Hypertension identification using inpatient clinical notes from electronic medical records: an explainable, data-driven algorithm study [11]	E. Martin, A. Souza, S. Mph	SCOPUS
P11	2023	Machine Learning in Hypertension Detection: A Study on World Hypertension Day Data [8]	S. Montagna, M. Francesco, S. Ferretti	SCOPUS
P12	2022	Machine learning for classification of hypertension subtypes using multi-omics : A multi-centre, retrospective, data-driven study [15]	P. Reel, S. Reel, J. Kralingen	SCIENCE DIRECT
P13	2023	Predicting Hypertension using Machine Learning: A Case Study at Petra University [13]	Y. Sakka, D. Qarashai, A. Altarawneh	SCOPUS
P14	2018	Data-Driven Identification of Hypertensive Patient Profiles for Patient Population Simulation [21]	A. Semakova, N. Zvartau	SCIENCE-DIRECT
P15	2018	MobiHealth: a System to improve Medication Adherence in Hypertensive Patients [22]	V. Souza, V. Silva, V.	SCIENCE-DIRECT