

Modelos predictivos en la clasificación de donantes a plaquetoféresis sanguínea en el Hospital Nacional Edgardo Rebagliati Martins, Lima-Perú. 2022

Jimmy Rinaldo Morales Del Pino¹ y Roger Pedro Norabuena Figueroa²

Resumen: El objetivo de la presente investigación fue determinar el mejor modelo predictivo que permita clasificar donantes a plaquetoféresis sanguínea en el Hospital Nacional Edgardo Rebagliati Martins-EsSalud, Lima-Perú 2022, empleando para ello una base de datos de donantes que acudieron a donar plaquetas por plaquetaféresis en el periodo 2015-2022. Se utilizó un diseño de investigación descriptivo, retrospectivo y no experimental. Para evaluar los modelos predictivos se empleó el lenguaje de programación Python usando Google Colab, en donde se realizaron las etapas que implicaron la construcción de un modelo de Machine Learning, encontrándose que el árbol de decisión fue el modelo con mejor desempeño tanto al usar datos no balanceados (Accuracy=0.89; F1-Score=0.91; AUC=0.90) como datos balanceados usando SMOTE (Accuracy=0.87; F1-Score=0.89; AUC=0.90), teniendo una mejor capacidad predictiva en clasificar donantes a plaquetas frente a otros modelos.

Palabras clave: Machine learning, Donante de plaquetas, Modelo predictivo.

Predictive models in the classification of donors for blood plateletpheresis at the Edgardo Rebagliati Martins National Hospital, Lima-Peru. 2022

Abstract: The objective of the present investigation was to determine the best predictive model that allows classifying donors for blood plateletpheresis at the Edgardo Rebagliati Martins-EsSalud National Hospital, Lima-Peru 2022, using a database of donors who came to donate platelets through plateletpheresis in the period 2015. -2022. A descriptive, retrospective, and non-experimental research design was used. To evaluate the predictive models, the Python programming language was used using Google Colab, where the stages that involve the construction of a Machine Learning model were carried out, finding that the decision tree was the model with the best performance both when using unbalanced data (Precision=0.89; F1-Score=0.91; AUC=0.90) as balanced data using SMOTE (Precision=0.87; F1-Score=0.89; AUC=0.90), having a better predictive capacity in the classification of platelet donors versus other models.

Keywords: Machine learning, Platelet donor, Predictive model.

Recibido: 23/09/2024 Aceptado: 05/12/2024 Publicado online: 30/12/2024

¹HNERM, Servicio de Medicina Transfusional, e-mail: jimmy.morales@essalud.gob.pe

²UNMSM, Facultad de Ciencias Matemáticas, e-mail: rnorabuena@unmsm.edu.pe

1. Introducción

La inteligencia artificial se define como la disposición que tienen las máquinas para reproducir la conducta del ser humano, permitiendo resolver problemas de salud difíciles como la predicción a tiempo de la generación de enfermedades, la predicción de la respuesta a tratamientos, etc. [2], [30]. Una de las ramas de estudio es el machine learning que comprende el análisis de datos a través de modelos que contienen algoritmos matemáticos los cuales generan predicciones [28], [30], [27]. El empleo de los modelos se ha venido desempeñando también dentro del ámbito de la salud, sobretodo en la medicina de laboratorio, donde ha sido utilizada para el desarrollo de procesos bioquímicos, evaluación e interpretación de pruebas moleculares así como en la aplicación en pruebas de detección a marcadores biológicos [11],[4], [8].

Un área médica donde la inteligencia artificial recién se viene desarrollando, es la medicina transfusional, que desde años atrás se le asocia con el uso de equipos semiautomatizados para la extracción sanguínea, el procesamiento de muestras para detectar enfermedades infecciosas y otros, los cuales se vinculan con el empleo del machine learning, el “Big data” y una serie de algoritmos que están permitiendo la predicción de transfusiones en operaciones quirúrgicas, captación de donantes, pruebas cruzadas, decisiones al uso racional de hemocomponentes, etc. con el fin de garantizar una óptima calidad y gestión de los componentes sanguíneos [22], [34], [?], [20].

A nivel mundial se han realizado estudios como el de [35] en Taiwán, quienes desarrollan modelos predictivos como una ayuda en la toma de decisiones en la regulación del suministro de sangre o el llevado a cabo en Norteamérica por [41], quienes examinaron la eficacia de las redes neuronales (ANN) en la predicción de transfusiones para las operaciones de los pacientes hospitalizados, encontrando un modelo que predice en más del 75 % de los pacientes que solicitan transfusión. En China, [17] emplearon modelos de aprendizaje automatizado para predecir uso racional de glóbulos rojos a transfundir en una cirugía cardiaca, evidenciando que el XGBOOST obtuvo buen rendimiento (AUROC: 0.90). Así mismo en otras regiones, se han venido realizando estudios sobre la predicción en la intención de las personas por donar sangre, lo cual es una parte importante del proceso de donación y que aún necesita de más estudios [14], [19], [40].

En nuestro país son escasas las investigaciones realizadas empleando inteligencia artificial y el machine learning, siendo más vinculadas al ámbito económico y finanzas pero en lo mínimo al plano médico [24], [10], [1], [42]. En el Hospital Nacional Edgardo Rebagliati Martins (HNERM) acuden donantes a donar sangre total y/o plaquetas por aféresis, siendo este último un procedimiento ventajoso, pues es realizado varias veces en cortos periodos de tiempo siempre y cuando el donante califique como apto en el proceso de evaluación [33]. El empleo de las donaciones ha permitido contar siempre con un stock adecuado por un largo tiempo excepto algunos hemocomponentes como las plaquetas por aféresis, las cuales vencen rápidamente y pierden su capacidad funcional en poco tiempo, sumándose a ellos la desventaja de que califican pocos donantes para el proceso de extracción de plaquetas (Aféresis) y su uso constante para los casos de emergencia hospitalaria, en donde son solicitadas en enormes volúmenes dejando muchas veces sin stock y viéndose el hospital desabastecido de este producto.

El objetivo del presente trabajo de investigación fue determinar el mejor modelo predictivo que permita clasificar donantes a plaquetoféresis sanguínea en el Hospital Nacional Edgardo Rebagliati Martins-EsSalud, Lima-Perú 2022, con el fin de aportar al conocimiento médico una forma diferente en optimizar recursos humanos, tiempo e insumos destinados a la donación por aféresis así como contar de manera inmediata con una reserva confiable de este hemocomponente, acortando las brechas de escasez y permitiendo su uso en el tratamiento de trombocitopatías,

trombopenias y/o cirugías de gran complejidad. Por otro lado, permitirá incentivar su aplicación en estudios de las diversas áreas del ámbito de la medicina transfusional como es la captación de donantes, el tamizaje serológico, etc.

2. Materiales y Métodos

Estudio de tipo descriptivo, retrospectivo y no experimental, realizado en el servicio de medicina transfusional del HNERM de donde se incluyeron donantes que acudieron a donar plaquetas por aféresis entre los años 2015-2022, excluyéndose aquellos que habían donado sangre total. Se empleó el análisis documental para recolectar información del sistema informático y con lo cual se creó una base de datos en donde se emplearon las etapas para construir modelos usados en machine learning. Las etapas incluyeron desde la colecta de datos, preparación de datos, elección del modelo, entrenamiento del modelo, evaluación del modelo, ajuste de parámetros y uso del modelo [?], [5], [13], [38].

Los modelos que contenían a los algoritmos más empleados en el ámbito de la medicina transfusional fueron del aprendizaje supervisado y comprenden a la Regresión logística, Árboles de decisión, Random Forest; Máquina de soporte vectorial (SVM), Nearest Neighbors (KNN), Gaussian Naive Bayes (GNB) y el Análisis Discriminante Lineal (LDA) [6], [23], [12], [15], [?], [9], [?], [16].

Los análisis empleados para el modelaje fueron realizados con Google Colab, en donde se usó el lenguaje de programación Python y se utilizaron las librerías Pandas, Numpy, Matplotlib, Seaborn y Scikit-learn. Los resultados se desarrollaron en dos fases: la primera, donde se realizó el entrenamiento del modelo (70 %) y la segunda, donde se realizó la validación real con los datos del Set de Test (30 %); se empleó la matriz de confusión que es una herramienta que permite hallar el rendimiento o la performance de un modelo de clasificación con salida binaria (Tabla 1) para un conjunto de datos; está diseñada a base de una matriz de $n \times n$ donde las columnas están conformadas por los valores reales y las filas conforman a los valores predichos por el algoritmo de un modelo de machine learning [25], [36], [21], [18], [13], [39].

Tabla 1. Matriz de confusión Binaria.

		Valores reales	
		Positivo	Negativo
Valores predichos	Positivo	TP	FP
	Negativo	FN	TN

Fuente: Elaboración propia.

A partir de la matriz resultan 4 tipos de salidas [36], [21], [18], [13], [39], que se describen como:

- Verdadero Positivo (TP): Obtenido cuando un valor real es positivo y el modelo lo predice como positivo.
- Verdadero Negativo (TN): Obtenido cuando un valor real es negativo y el modelo lo predice como negativo.
- Falso Negativo (FN): Obtenido cuando un valor real que era positivo, el modelo lo predice como negativo.

- Falso Positivo (FP): Obtenido cuando un valor real que era negativo, el modelo lo predice como positivo.

A partir de estas salidas se pueden generar métricas que se evaluarán para visualizar el desempeño de cada modelo, tales como:

Exactitud (“Accuracy”). Es una de las primeras métricas con el que se evalúa el desempeño de un modelo, está definida como el número de predicciones definidas como correctas entre la cantidad total de predicciones [36], [21], [18], [39].

$$\text{Accuracy} = \frac{(\text{TP} + \text{TN})}{(\text{TP} + \text{TN} + \text{FP} + \text{FN})} \quad (1)$$

Precisión. Considerada como otra métrica empleada para evaluar un modelo predictivo, la precisión es definida como la cantidad de valores identificados correctamente como positivos entre la cantidad total de datos predichos como positivos [36], [21], [18], [39].

$$\text{Precisión} = \frac{\text{TP}}{(\text{TP} + \text{FP})} \quad (2)$$

Sensibilidad (“Recall”). Mide la proporción de datos identificados correctamente como positivos entre el número total de valores reales positivos [36], [21], [18], [39].

$$\text{Recall} = \frac{\text{TP}}{(\text{TP} + \text{FN})} \quad (3)$$

Especificidad. Mide la proporción de datos identificados correctamente como negativos entre el número total de valores reales negativos [36], [21], [13], [39].

$$\text{Especificidad} = \frac{(\text{TN})}{(\text{TN} + \text{FP})} \quad (4)$$

F1-Score. Es una métrica muy empleada cuando se desea combinar la precisión y sensibilidad de un modelo; y se define como la media armónica de la precisión y sensibilidad, de esta manera se evita su variación frente a valores grandes [36], [21], [13], [39].

$$\text{F1-Score} = \frac{(2 \times \text{Precisión} \times \text{Recall})}{(\text{Precisión} + \text{Recall})} \quad (5)$$

Adicionalmente se empleó la curva ROC, el cual evalúa la proporción entre el valor de los verdaderos positivos (“Recall” ó “Sensibilidad”) y el valor de los falsos positivos (“1-Especificidad”), empleando un sistema de coordenadas cartesianas para establecer puntos que hacen de equilibrio entre ambos valores y forman una recta de donde se obtiene el área bajo la curva (AUC) el cual se usa para comparar los modelos de aprendizaje y también representa el rendimiento general del modelo, el cual va entre los rangos de 0 a 1, siendo 1 considerado como un desempeño excelente del modelo [25], [13], [36], [21]. Finalmente se procedió a comparar modelos empleando datos no balanceados como balanceados.

3. Resultados y Discusiones

3.1. Resultados

Durante el periodo de 8 años (2015-2022) hubo un total de 63281 donantes a donar plaquetas por aféresis sanguínea, de los cuales el 57.4 % (36322/63281) fueron considerados como APTOS a la donación mientras que el 42.6 % (26959/63281) fueron NO APTOS (Tabla 6). Así mismo, podemos observar en la figura 1 la distribución de donantes APTOS según los años de estudio, siendo el año 2021 el de mayor presencia a donantes APTOS (69.6 %) y el 2016 como el año de menor presencia (47.9 %).

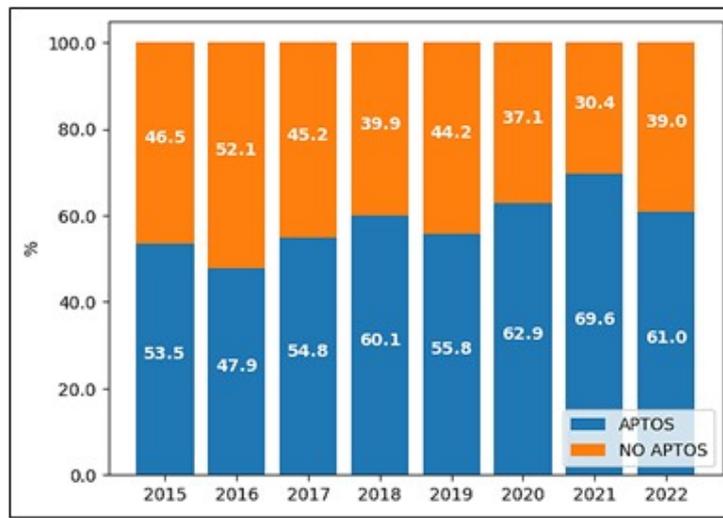


Figura 1: Condición del donante según año de estudio (2015-2022).

Por otro lado, las variables binarias empleadas son mostradas en la tabla 2, observándose que un 83.3 % del total de donantes fueron del género masculino y un 16.7 % fueron del género femenino; el 99.9 % no presentaron reacción vaso vagal, mientras que solo un 0,1 % si lo presentó; el 76.1 % de los donantes tuvieron grupo O+ mientras que el 23.9 % fueron de otros grupos sanguíneos; 91.4 % no tuvieron tamizaje positivo a enfermedades infecciosas pero solo un 8.6 % si tuvo positividad; un 77.3 % pudo pasar la entrevista médica mientras que el 22.7 % no pasaron; finalmente, la gran mayoría, ósea el 99.6 % tuvieron un acceso venoso adecuado y solo un 0.4 % tuvieron acceso inadecuado de vena.

Tabla 2. Variables binarias de los donantes a plaquetas por aféresis.

Variables de estudio		n	%
Tipo de donante	Apto	36322	57.4
	No apto	26959	42.6
Género	Femenino	10545	16.7
	Masculino	52736	83.3
Reacción vaso vagal	No	63212	99.9
	Si	69	0.1
Grupo sanguíneo	O+	48148	76.1
	Otros grupos	15133	23.9
Tamizaje a enfermedades infecciosas	Negativo	57836	91.4
	Positivo	5445	8.6
Entrevista médica	No pasa	14377	22.7
	Si pasa	48904	77.3
Acceso venoso	Adecuado	63038	99.6
	Inadecuado	243	0.4

Fuente: Elaboración propia.

En cuanto a las variables cuantitativas, podemos mencionar que el promedio de la edad fue 34.9 ± 10.4 años, el nivel medio de hemoglobina fue 14.5 ± 1.02 mg/dl, el peso tuvo una media de 69.6 ± 13.03 y la media del número de donaciones anuales fue $1,6 \pm 1.5$.

Para la fase de entrenamiento se utilizó el 70% del total de datos, correspondiendo un total de 44296 donantes a plaquetas, de los cuales 25486 están clasificados como APTO y 18810 como NO APTO; mientras que para la fase de prueba (30%) se tuvo un total de 18985, de los cuales 10836 están clasificados como APTO y 8149 como NO APTO donde el ratio entre donantes clasificados como APTO entre el total se mantiene como en el total inicial, siendo lo mismo con aquellos donantes clasificados como NO APTO. En la primera parte, los modelos evaluados no emplearon datos balanceados y se obtuvieron métricas para los datos de entrenamiento y prueba (Tabla 3), resultando en los datos de entrenamiento que el Random Forest tiene mayor exactitud (0.95), precisión (0.92), F1-Score (0.96) y un AUC = 0.99 frente a los valores bajos de los demás modelos, pero con sensibilidad de 0.99, la cual es mayor al 0.97 del K-NN pero menor al mismo valor obtenido por los demás modelos (1.00); mientras que con los datos de prueba, el árbol de decisión obtuvo mayor exactitud (0.89) y buen F1-Score (0.91) frente a los otros 6 modelos, no siendo así la precisión (0.83) la cual fue menor que el del Random Forest (0.84) pero superior ó igual a los modelos restantes. De igual manera, el árbol de decisión como el GNB presentaron un mismo valor de AUC=0.90 frente a los valores bajos de AUC de los modelos restantes.

Tabla 3. Métricas del rendimiento estadístico de cada modelo empleando datos no balanceados.

Tipo de modelo	Entrenamiento					Prueba				
	Accuracy	Precision	Recall	F1-Score	AUC	Accuracy	Precision	Recall	F1-Score	AUC
Regresión Logística	0.88	0.83	1.00	0.90	0.89	0.88	0.82	1.00	0.90	0.89
Árbol de decisión	0.89	0.84	1.00	0.91	0.90	0.89	0.83	1.00	0.91	0.90
K-NN	0.87	0.83	0.97	0.90	0.94	0.83	0.79	0.95	0.86	0.85
GNB	0.88	0.83	1.00	0.90	0.90	0.88	0.82	1.00	0.90	0.90
SVM	0.88	0.83	1.00	0.91	0.89	0.88	0.83	1.00	0.90	0.89
Random Forest	0.95	0.92	0.99	0.96	0.99	0.86	0.84	0.94	0.89	0.89
LDA	0.88	0.83	1.00	0.90	0.89	0.87	0.82	1.00	0.90	0.89

Fuente:Elaboración propia.

En la figura 2 observamos las gráficas de curvas ROC de los modelos evaluados con los datos de prueba no balanceados, donde se muestra la similitud entre las áreas bajo la curva (AUC) para el árbol de decisión y el Gaussian Naive Bayes.

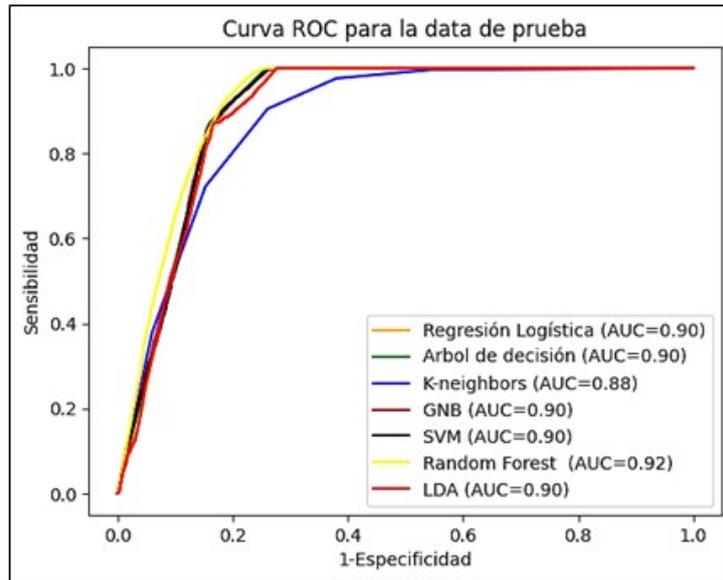


Figura 2: Curvas ROC de cada modelo predictivo empleando datos de prueba no balanceados.

En la segunda parte, se usó el oversampling (SMOTE) para balancear datos, observándose en la tabla 4 los resultados de las métricas obtenidas tanto para los datos de entrenamiento como de prueba, en donde los datos de entrenamiento presentaron al Random Forest como el modelo de mayor exactitud (0.95), mayor precisión (0.92), mayor F1-Score y el AUC= 0.99 frente a valores bajos de los demás modelos, pero con una sensibilidad menor (0.98) frente al mismo valor obtenido (1.00) por la Regresión logística, árbol de decisión, GNB, SVM y LDA. En cuanto a las métricas obtenidas con los datos de prueba, los que tuvieron similar exactitud (0.87) fueron el Árbol de decisión y el Random Forest, aunque este último también tuvo una mayor precisión (0.83) frente a los demás mas no así su sensibilidad (0.92) y F1-Score (0.87) que fueron superados por la mayoría de los modelos restantes.

Tabla 4. Métricas del rendimiento estadístico de cada modelo empleando datos balanceados.

Tipo de modelo	Entrenamiento					Prueba				
	Accuracy	Precision	Recall	F1-Score	AUC	Accuracy	Precision	Recall	F1-Score	AUC
Regresión Logística	0.86	0.78	1.00	0.88	0.90	0.86	0.78	1.00	0.88	0.90
Árbol de decisión	0.87	0.80	1.00	0.89	0.90	0.87	0.80	1.00	0.89	0.90
K-NN	0.88	0.83	0.95	0.89	0.95	0.82	0.78	0.90	0.84	0.88
GNB	0.86	0.78	1.00	0.88	0.90	0.86	0.78	1.00	0.88	0.90
SVM	0.86	0.79	1.00	0.88	0.90	0.86	0.79	1.00	0.88	0.90
Random Forest	0.95	0.92	0.98	0.95	0.99	0.87	0.83	0.92	0.87	0.92
LDA	0.86	0.78	1.00	0.88	0.90	0.86	0.78	1.00	0.88	0.90

Fuente:Elaboración propia.

En la figura 3 observamos las gráficas de curvas ROC de los modelos evaluados con los datos de prueba balanceados, donde se muestra que el Random Forest posee mayor área bajo la curva (AUC) frente al árbol de decisión y demás modelos.

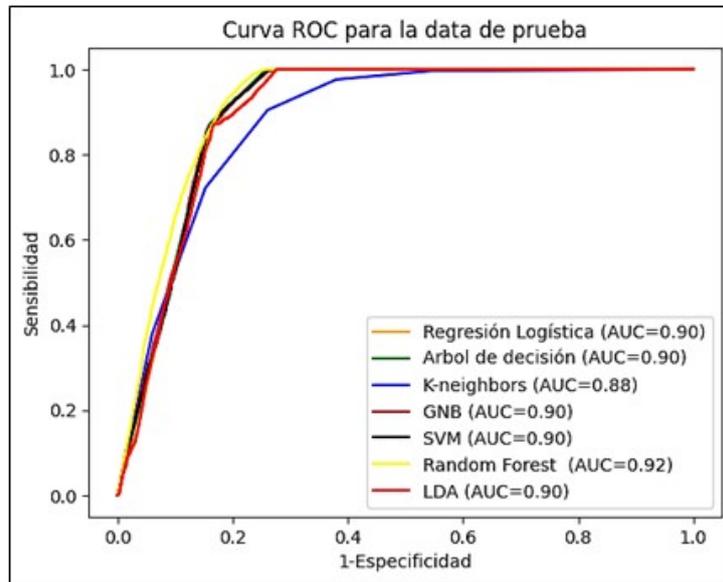


Figura 3: Curvas ROC de cada modelo predictivo empleando datos de prueba balanceados.

La figura 4, 5 y 6 resumen el rendimiento estadístico de cada modelo investigado comparando al emplear datos no balanceados y balanceados. Se observa que la exactitud y la sensibilidad poseen buen rendimiento en los modelos que usan datos no balanceados como es el caso del árbol de decisión. Solo en la figura 6, los valores bajo la curva (AUC) son mejores en todos los modelos que emplean datos balanceados, sobresaliendo el Random Forest.

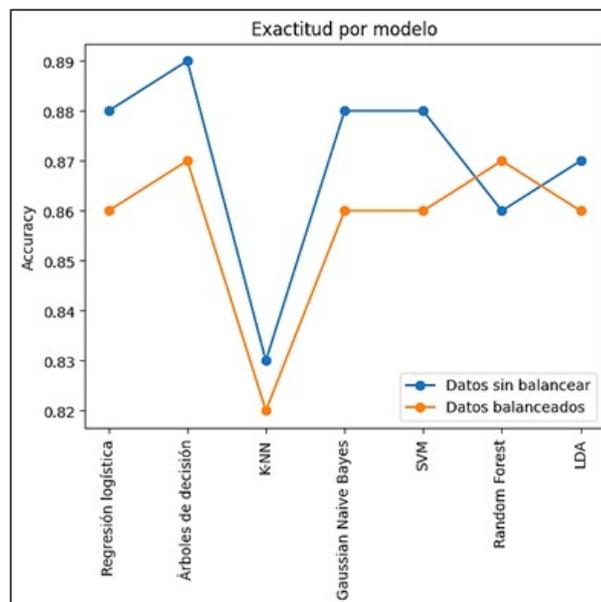


Figura 4: Comparación de la exactitud de los modelos usando datos de prueba no balanceados y balanceados

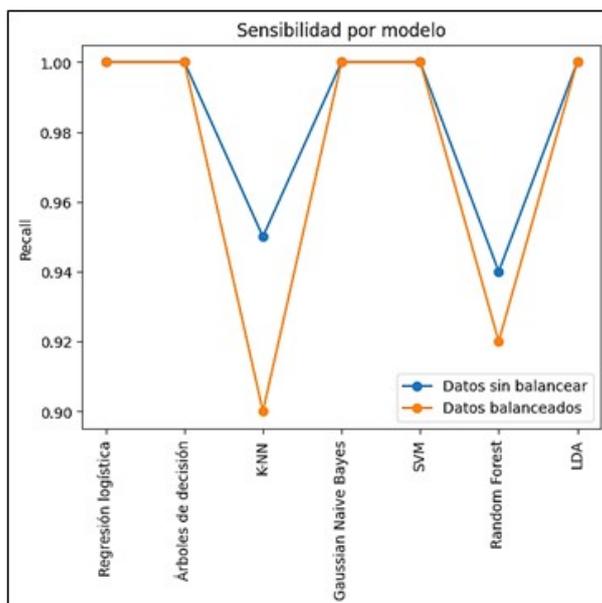


Figura 5: Comparación de la sensibilidad de los modelos usando datos de prueba no balanceados y balanceados

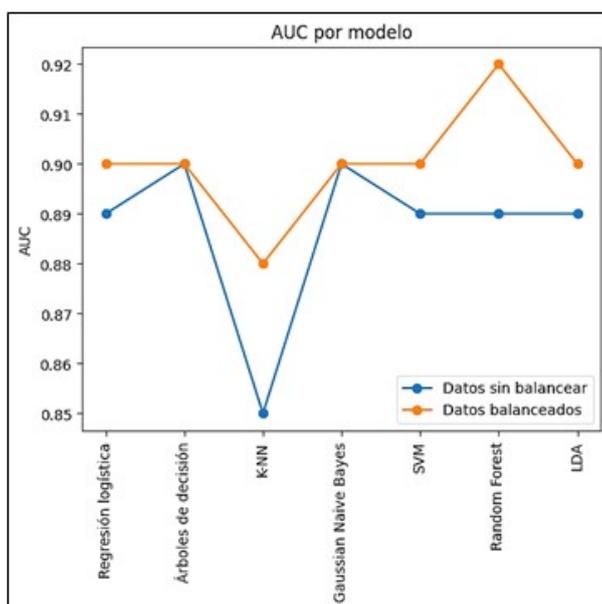


Figura 6: Comparación del AUC de los modelos usando datos de prueba no balanceados y balanceados

3.2. Discusiones

El objetivo de la presente investigación fue determinar el mejor modelo predictivo que permita clasificar donantes a plaquetoféresis sanguínea en el Hospital Nacional Edgardo Rebagliati Martins, en tal sentido, se encontró que el modelo que presenta mejor desempeño frente al resto en clasificar donantes a plaquetoféresis como APTO o NO APTO es el árbol de decisión, este resultado se basa principalmente en los valores de los indicadores de Exactitud y F1-Score, el cual es una métrica de la matriz de confusión que resume de mejor manera la Precisión y el Recall ó sensibilidad [31], [13]. Los resultados obtenidos mostraron diferencias con estudios como el de [7], [6] y [26] quienes encuentran que el ANN (Redes neuronales), el SVM y el K-NN,

respectivamente, son los que mejor desempeño presentaron en una población de donantes de sangre. Por su parte, nuestros hallazgos fueron también contrarios a lo mencionado por [29] quien encontró que el árbol de decisión fue el de menor exactitud (0.89) frente a otros modelos. Las diferencias posiblemente se dieron por las variables predictoras incluidas para seleccionar donantes a plaquetas, entre las cuales incluyen el previo tamizaje serológico, el adecuado acceso venoso y la reacción vasovagal, criterios no considerados al seleccionar donantes para sangre total, pero que son importantes para una adecuada optimización y rendimiento de los productos plaquetarios así como el de cumplir con sus estándares de calidad [33], [3]. No obstante, los resultados mostrados no fueron ajenos a aquellos estudios relacionados con el comportamiento del donante en donar sangre de manera frecuente o no, donde el árbol de decisión es considerado como un modelo adecuado con muy buena exactitud [?], [32].

En cuanto al empleo del balanceo de datos, no mejoró el desempeño del árbol de decisión, esto se observó en los resultados de las métricas usadas como la exactitud, precisión y F1-Score los cuales tuvieron mínima variación tanto al emplear modelos con datos no balanceados como datos balanceados. Si bien es cierto que las técnicas de remuestro son empleadas cuando los datos no presentan una distribución adecuada de cada clase [?], [25]; la presencia de datos con clases cercanas a la distribución del 50 % pudo haber influido en el desempeño de los modelos.

Por otro lado, el modelo del árbol de decisión se ajustó bien tanto a sus datos de entrenamiento como de prueba ó validación, sea en datos no balanceados y balanceados, frente a los modelos como la Regresión logística, K-NN, GNB, SVM y LDA que tuvieron valores menores a los hallados en cuanto a exactitud, Precisión, F1-Score y AUC; mas no así en la sensibilidad, donde la mayoría obtuvo un valor de 1.00 a excepción del K-NN y Random Forest evidenciando además este último modelo la presencia de sobreajuste debido a que su exactitud en los datos de entrenamiento (0.95) superó a la exactitud de los datos de prueba (0.84). La presencia del sobreajuste se debe cuando el modelo se ajusta bien a los datos de entrenamiento mas no a los datos de prueba ó validación, por lo cual no se pueden generalizar ni hacer predicciones precisas para nuevos datos; solo las métricas obtenidas con los datos de validación permitirán una medida de la calidad del modelo [37], [13].

En cuanto al AUC obtenido para los diferentes modelos, el árbol de decisión junto a otros modelos tuvo un óptimo valor (0.90) al emplear datos no balanceados, pero al emplear datos balanceados, el Random Forest obtuvo el mejor rendimiento (0.92) junto a modelos con AUC=0.90 donde también se encuentra incluido el árbol de decisión. Estos valores deben manejarse con cuidado, pues por sí solo el AUC no puede determinar si un modelo tiene buen rendimiento o no, debido a que el AUC está en función de los verdaderos positivos (Sensibilidad) y falsos positivos (1-Especificidad), de este modo debe evaluarse junto a las demás métricas, como la exactitud, para establecer el desempeño de un modelo [25], [?].

4. Conclusión

El árbol de decisión fue el modelo predictivo que tuvo mejor desempeño, por ende, una mejor capacidad predictiva en clasificar donantes a plaquetoféresis sanguínea, además de ajustarse bien tanto a los datos de entrenamiento y datos de prueba ó validación. Asimismo, podemos concluir que el balanceo de datos no mejoró de manera notable el desempeño del árbol de decisión.

Referencias bibliográficas

- [1] Aira, F., Casas, L. y Romero, P. (2021). Aplicación y casos de uso de técnicas de inteligencia artificial contra el COVID-19. *Revista de investigación de sistemas e informática*, 14 (1), 53-62. DOI:<https://doi.org/10.15381/risi.v14i1.21862>
- [2] Álvarez, M., Quirós, L. y Cortés, M. (2020). Inteligencia artificial y aprendizaje automático en medicina. *Revista Médica Sinergia*, 5(8). DOI:<https://doi.org/10.31434/rms.v5i8.557>
- [3] American Association of Blood Banks. (2020). *Manual técnico de la aabb (20th ed.)*. USA: AABB org.
- [4] Ávila, J.F., Mayer, M.A. y Quesada, V.J. (2021). La inteligencia artificial y sus aplicaciones en medicina II: importancia actual y aplicaciones prácticas. *Aten Primaria*, 53(1), 81-8. DOI: 10.1016/j.aprim.2020.04.014
- [5] Bagnato, J.(Diciembre del 2017). 7 pasos para crear ML. *Aprende Machine Learning*.<https://www.aprendemachinelearning.com/7-pasos-machine-learning-construir-maquina/>
- [6] Bahel, D., Ghosh, P., Sarkar, A. & Lanham, M.(2018). Predicting Blood Donations Using Machine Learning Techniques. Purdue University, Department of Management, 1-19. chrome-extension://efaidnbmninnibpcjpcglclefindmkaj/http://matthewalanham.com/Students/2017_MWDSI_Final_Bahel.pdf
- [7] Boonyanusith, W. & Jittamai, P. (2012). Blood Donor Classification Using Neural Network and Decision Tree Techniques. *Proceedings of the World Congress on Engineering and Computer Science*, 1, 24-26. http://www.iaeng.org/publication/WCECS2012/WCECS2012_pp499-503.pdf
- [8] Cabitza, F. & Banfi, G. (2018). Machine learning in laboratory medicine: waiting for the flood? *Clin Chem Lab Med*, 56(4), 516-524. <https://doi.org/10.1515/cclm-2017-0287>
- [9] Carrión, F.P., Lliguizaca, J.R. y Perero, D.L. (27-31 de julio del 2020). *Selección de métodos de recuperación mejorada de petróleo utilizando el algoritmo de machine-learning de los K vecinos más cercanos (KNN)*. [Resumen de presentación en conferencia]. 18 th LACCEI International Multi-Conference for Engineering, Education, and Technology (Virtual Edition). <http://dx.doi.org/10.18687/LACCEI2020.1.1.564>
- [10] Curioso, W.H. & Brunette, M.J. (2020). Inteligencia artificial e innovación para optimizar el proceso de diagnóstico de la tuberculosis. *Rev Peru Med Exp Salud Pública*, 37(3), 554-558. DOI:<https://doi.org/10.17843/rpmesp.2020.373.5585>
- [11] Del Río, M.L., López, J.M. y Vaquero, C. (2018). La inteligencia artificial en el ámbito médico. *Revista española de investigaciones quirúrgicas*, 21(3), 113-116. <http://www.reiq.es/ING/pdf/REIQ21.3.2018.pdf>
- [12] Dulhare, U. N., Ahmad, K. & Bin Ahmad, K.M. (2020). *Machine Learning and Big data: Concepts, Algorithms, Tools and Applications*. USA: Wiley-Scrivener.
- [13] Geetha, T.V. & Sendhilkumar, S. (2023). *Machine Learning. Concepts, Techniques and Applications (1rst ed.)*. New York: CRC Press. DOI:10.1201/9781003290100
- [14] Gilchrist, P.T., Masser, B.M., Horsley, K. & Ditto, B. (2019). Predicting blood donation intention: the importance of fear. *Transfusion*, 59, 3666-3673 DOI:10.1111/trf.15554
- [15] Gollapudi, S. (2016). *Practical Machine Learning (1rst ed.)*. United Kingdom: Packt Publishing.

- [16] Ghojogh, B. & Crowley, M. (2019). Linear and Quadratic Discriminant Analysis: Tutorial. *Arxiv*. <https://doi.org/10.48550/arXiv.1906.02590>
- [17] Jiang, H., Liu, L., Wang, Y., Ji, H., Ma, X., Wu, J., Huang, Y., Wang, X., Gui, R., Zhao, Q. & Chen, B (2021). Machine Learning for the Prediction of Complications in Patients After Mitral Valve Surgery. *Front Cardiovasc Med*, 8, 1-11. Doi:10.3389/fcvm.2021.771246
- [18] Jung, A. (2022). *Machine Learning: Foundations, Methodologies and Applications*. Singapore: Springer. <https://doi.org/10.1007/978-981-16-8193-6>
- [19] Kassie, A., Azale, T. & Nigusie, A. (2020). Intention to donate blood and its predictors among adults of Gondar city: Using theory of planned behavior. *Plos One*, 15(3), 1-12. <https://doi.org/10.1371/journal.pone.0228929>
- [20] Lin, S. (2022). *Digital Health*. USA: Exon Publications. <https://exonpublications.com/index.php/exon/issue/view/digital-health>
- [21] Liu, Y. (2020). *Python Machine Learning by example (3rd ed.)*. United Kingdom: Packt Publishing.
- [22] Mahadevan, S., Poornima, S., Tripathi, K. & Pushpalatha, M. (2019). A survey on machine learning algorithms for the blood donation supply chain. *Journal of Physics: Conference Series* 1362 012124. DOI:10.1088/1742-6596/1362/1/012124
- [23] Mishra, A. (2019). *Machine Learning in the AWS Cloud*. Canadá: John Wiley & Sons. <https://www.jdnotes.net/pdf/aws/machinelearningintheawscloud.pdf>
- [24] Mujica, I.E., Toribio, L.M. y Córdor, D.F. (2020). Inteligencia artificial como apoyo a intervenciones no farmacológicas para combatir la COVID-19. *Rev Peru Med Exp Salud Pública*, 37(3), 582-584. <https://doi.org/10.17843/rpmesp.2020.373.5704>.
- [25] Müller, A.C. & Guido, S. (2017). *Introduction to Machine Learning with Python, a guide for data scientists (1rst ed.)*. USA: O'Reilly Media.
- [26] Pabreja, K. (2021). A Predictive Analytics Framework for Blood Donor Classification. *International Journal of Big Data and Analytics in Healthcare*, 6(2), 1-14. DOI:10.4018/IJBDAH.20210701.oa1
- [27] Park, D.J., Park, M.W., Lee, H., Kim, Y.L., Kim, Y. & Park, Y.H. (2021). Development of machine learning model for diagnostic disease prediction based on laboratory tests. *Scientific Reports*, 11, 1-11. <https://doi.org/10.1038/s41598-021-87171-5>
- [28] Rashidi, H., Tran, N., Vali, E., Howell, L. & Green, R. (2019). Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods. *Academic Pathology*, (6), 1-17. DOI:10.1177/2374289519873088
- [29] Rodríguez, L.M. (2019). *Modelo predictivo para la clasificación de donantes de sangre en el banco de sangre de la escuela de microbiología de la Universidad de Antioquia, Medellín, 2019* [Tesis de pregrado, Universidad de Antioquia]. <http://bibliotecadigital.udea.edu.co/handle/10495/18667>
- [30] Romeo, C. & Lazcoz, G. (2020). Inteligencia artificial aplicada a la salud: ¿Qué marco jurídico? *Rev Der Gen H Núm*, 52, 139-167. DOI:10.14679/1220
- [31] Russell, R. (2018). *Machine Learning. Step-by-step guide to implement Machine Learning algorithms with Python*. CreateSpace Independent Publishing Platform.

- [32] Santhanam, T. & Sundaram, S. (2010). Application of CART Algorithm in Blood Donors Classification. *Journal of Computer Science*, 6(5), 548-552. <https://thescipub.com/pdf/jcssp.2010.548.552.pdf>
- [33] Servicio de Medicina Transfusional-HNERM. (2015). *Manual de selección del donante de sangre, procedimiento operativo estándar*. Lima: sistema de gestión de la calidad de medicina transfusional.
- [34] Smit Sibinga CTh. (2020). Artificial intelligence in transfusion medicine and its impact on the quality concept. *Transfusion and Apheresis Science*, 59, 1-3. DOI:10.1016/j.transci.2020.103021
- [35] Shih, H. & Rajendran, S.(2019). Comparison of Time Series Methods and Machine Learning Algorithms for Forecasting Taiwan Blood Services Foundation's Blood Supply. *Journal of Healthcare Engineering*, 9, 1-6. <https://doi.org/10.1155/2019/6123745>
- [36] Subasi, A. (2020). *Practical Machine Learning for data analysis using python*. United Kingdom: ELSEVIER.
- [37] Tavarez, A. G. (2021). *Ciencia de Datos, una guía práctica (1rst ed.)*. República dominicana: Editora Santuario.
- [38] Van Der Post, H.(2023). *Machine Learning: A guide to Pytorch, tensor flow, and scikit-learn*. USA: Independently published.
- [39] Vasques, X. (2024). *Machine Learning theory and applications*. Canadá: John Wiley & Sons.
- [40] Wahono, H. & Riana, D. (2020). Prediksi Calon Pendonor Darah Potensial Dengan Algoritma Naïve Bayes, Knearest Neighbors dan Decision Tree C4.5. *Jurnal Riset Komputer*, 7(1), 7-14. DOI:10.30865/jurikom.v7i1.1953Ha17-14
- [41] Walczak, S. & Velanovich, V. (2020). Prediction of perioperative transfusions using an artificial neural network. *Plos One*, 15(2), 1-19. <https://doi.org/10.1371/journal.Pone.0229450>
- [42] Zela Moraya, W. (2021). *Estrategia nacional de inteligencia artificial. Presentado en Lima*. Secretaría de Gobierno y Transformación Digital. Presidencia del Consejo de Ministros.<https://www.gob.pe/14nstitucion/pcm>