

Estado de la publicación: El preprint no ha sido enviado para publicación

Rendimiento de modelos de aprendizaje automático en la predicción de recurrencia de fibrilación auricular paroxística

Yoander Nápoles-Zaldivar, Ivonne María Nodarse Palacios, Edilio Silva Velasco, Juan Carlos Baster Moro, Luis Aníbal Alonso-Betancourt

<https://doi.org/10.1590/SciELOPreprints.16661>

Enviado en: 2026-06-23

Postado en: 2026-06-30 (versión 1)

(AAAA-MM-DD)

Rendimiento de modelos de aprendizaje automático en la predicción de recurrencia de fibrilación auricular paroxística

Machine learning models performance in prediction of paroxysmal atrial fibrillation recurrence

Yoander Nápoles-Zaldivar ^{1*} <https://orcid.org/0000-0002-9827-6747>

Ivonne María Nodarse-Palacios¹ <https://orcid.org/0000-0002-4436-2041>

Edilio Silva-Velasco² <https://orcid.org/0000-0003-1151-6769>

Juan Carlos Báster-Moro³ <https://orcid.org/0000-0002-5019-382X>

Luis Aníbal Alonso-Betancourt⁴ <https://orcid.org/0000-0003-0989-746X>

¹Universidad de Ciencias Médicas de Holguín. Hospital General Dr. "Gustavo Aldereguía Lima". Holguín, Cuba.

²Universidad de Ciencias Médicas de Holguín. Hospital General Universitario "Vladimir Ilich Lenin". Holguín, Cuba.

³Universidad de Ciencias Médicas de Holguín. Centro Provincial de Higiene, Epidemiología y Microbiología. Holguín, Cuba.

⁴Universidad de Holguín. Holguín, Cuba.

*Autor para la correspondencia. Correo electrónico: yoandernap@gmail.com

RESUMEN

Introducción: Los algoritmos de aprendizaje automático han impulsado el desarrollo de modelos capaces de predecir la recurrencia de la fibrilación auricular paroxística con rendimiento superior a las escalas convencionales.

Objetivo: Sintetizar el rendimiento discriminativo de los algoritmos de aprendizaje automático en la predicción de recurrencia de la fibrilación auricular paroxística.

Métodos: Se realizó una revisión sistemática de artículos publicados en LILACS, PUBMED, OpenAlex, Sciencedirect y Europe PMC. Se incluyeron ensayos clínicos, cohortes y estudios de desarrollo/validación de modelos predictivos que involucraran a

adultos diagnosticados con fibrilación auricular paroxística. El desenlace primario fue la recurrencia de la arritmia. Las métricas de rendimiento se sintetizaron mediante un modelo de efectos aleatorios. El riesgo de sesgo se evaluó con PROBAST.

Resultados: Se identificaron siete estudios en la fase cualitativa (N = 7 466 pacientes; recurrencia post-ablación: 13,47%-37,5%). Cinco modelos aportaron datos para la síntesis cuantitativa. Los algoritmos basados en inteligencia artificial mostraron un elevado rendimiento discriminativo global (AUC = 0,78; IC95%: 0,71-0,85; $p < 0,0001$), con alta heterogeneidad interestudio ($I^2 = 91,5\%$). El análisis por subgrupos reportó mayor estabilidad en la familia de arquitecturas alternativas frente a *Ensemble Trees*. Las investigaciones incluidas exhibieron alto riesgo de sesgo global en el dominio de análisis estadístico.

Conclusiones: Los modelos de aprendizaje automático muestran una alta capacidad discriminativa en la predicción de recurrencias. Sin embargo, el alto riesgo de sesgo metodológico de la literatura primaria obliga a interpretar el rendimiento global con cautela.

Palabras clave: aprendizaje automático; biología computacional; fibrilación auricular; metaanálisis; revisión sistemática

ABSTRACT

Introduction: Machine learning algorithms have driven the development of models capable of predicting paroxysmal atrial fibrillation recurrence, outperforming conventional risk scores.

Objective: To synthesize the discriminative performance of machine learning algorithms for predicting paroxysmal atrial fibrillation recurrence.

Methods: A systematic review of articles published in LILACS, PubMed, OpenAlex, ScienceDirect, and Europe PMC was conducted. Clinical trials, cohort studies, and predictive model development/validation studies involving adults diagnosed with paroxysmal atrial fibrillation were included. The primary outcome was arrhythmia

recurrence. Performance metrics were pooled using a random-effects meta-analysis, and the risk of bias was evaluated using the PROBAST tool.

Results: Seven studies were identified in the qualitative phase (N = 7,466 patients; post-ablation recurrence rate: 13.47%–37.5%), and five models provided data for the quantitative synthesis. Artificial intelligence-based algorithms demonstrated a high overall discriminative performance (AUC = 0.78; 95% CI: 0.71–0.85; $p < 0.0001$), along with high inter-study heterogeneity ($I^2 = 91.5\%$). Subgroup analysis reported higher stability in alternative architectures compared to Ensemble Trees. All included studies exhibited a high overall risk of bias, driven by deficiencies in the statistical analysis domain.

Conclusions: Machine learning models demonstrate high overall discriminative performance for predicting recurrence. Nonetheless, the high methodological risk of bias identified in primary literature requires a cautious interpretation of the overall performance.

Keywords: atrial fibrillation; computational biology; machine learning; meta-analysis; systematic review

INTRODUCCIÓN

La fibrilación auricular (FA) es la arritmia cardiaca más frecuente en la práctica médica.⁽¹⁾ Entre sus formas clínicas, la fibrilación auricular paroxística (FAP) destaca por su perfil temporal, estrecha ventana diagnóstica y el consecuente subregistro de pacientes.^(2,3) A pesar de que el desarrollo de desfibriladores implantables, nuevos fármacos antiarrítmicos y ablación por catéter ha ampliado la posibilidad de modificar la carga de la arritmia, el acceso a estas tecnologías y la disponibilidad de personal entrenado, constituyen una asignatura pendiente en países de bajos ingresos, incluida Latinoamérica; donde la FA se erige como la arritmia más importante en el contexto clínico.⁽⁴⁾

Frente a este escenario, la aplicación de algoritmos de aprendizaje profundo ha impulsado una línea de trabajo que se enfoca en captar la naturaleza electrofisiológica y estructural no lineal de la FAP. De particular interés resulta la posibilidad de construir

modelos basados en variables de fácil acceso, lo que podría hacer viable el cribado de poblaciones vulnerables en entornos con recursos limitados.⁽⁵⁾ Su utilidad radica en la capacidad para predecir recurrencias a partir de fenómenos multidimensionales complejos; omitidos con frecuencia por los modelos convencionales o no captados con la misma precisión discriminativa.

Sin embargo, a la existencia de múltiples diseños, poblaciones y arquitecturas se suma la omisión en el reporte de la precisión estadística. En este contexto, el objetivo de la presente revisión sistemática y metaanálisis es sintetizar el rendimiento discriminativo de los algoritmos de aprendizaje automático en la predicción de recurrencia de la fibrilación auricular paroxística.

MÉTODOS

Protocolo

Las recomendaciones del *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA 2020) fueron seguidas. El protocolo se registró de forma prospectiva en el *International Prospective Register of Systematic Reviews* (PROSPERO) con código de identificación CRD420261398192.^(6,7) No se requirió aprobación por Comités de Ética Médica al sintetizarse datos de investigaciones publicadas.

Estrategia de búsqueda

Se accedió a LILACS, PUBMED, Open Alex, Scencedirect y Europe PMC el día 09/05/2026. Para optimizar la búsqueda se incluyeron términos del *Medical Subject Headings* (MeSH) y operadores booleanos. No se aplicaron restricciones de idioma, fecha de publicación ni tipo de documento en la fase inicial para capturar la totalidad de documentos disponibles y evitar sesgos de selección prematuros. La estrategia de búsqueda se recopila en el material suplementario (Tabla S1). Dos revisores independientes, J.C.B y L.A.A, examinaron los registros por título y resumen.

Selección de artículos

Estrategia PICOD:

- Población (P): adultos (>18 años) con diagnóstico documentado de fibrilación auricular paroxística. En caso de población mixta se incluyeron los estudios sólo si los datos del subgrupo FAP podían extrapolarse.
- Indicador / Algoritmo (I): modelos predictivos basados en algoritmos de inteligencia artificial.
Comparación (C): no aplica (evaluación del rendimiento discriminativo absoluto o comparación directa entre arquitecturas computacionales)
- Desenlace / *Outcome* (O): rendimiento discriminativo medido con área bajo la curva (AUC).
- Diseño (D): ensayos clínicos, cohortes, estudios de desarrollo/validación de modelos predictivos.

Se excluyeron *preprint* y artículos sin validación ni texto completo, editoriales, cartas, revisiones narrativas, conferencias; e investigaciones que no reporten métricas de rendimiento discriminativo.

Extracción de datos

I.M.N y E.S de forma independiente procedieron a la lectura completa de los artículos seleccionados. En las discrepancias intervino Y.N. Todo el proceso fue graficado en un diagrama PRISMA y se ejecutó en el software Zotero 9.0.2.

Se recopilaron los siguientes datos: autor, año, país, diseño del estudio, tamaño muestral (N), edad (media o mediana), recurrencias (%), distribución por sexo masculino (%), algoritmo evaluado, familia arquitectónica, métricas de rendimiento: AUC, intervalo de confianza al 95% (IC95%), error estándar (SE), sensibilidad, especificidad; tipo de validación, y tiempo de seguimiento. Se respetaron las definiciones de recurrencia de cada estudio.

Se excluyeron las investigaciones que no reportaron el IC95% ni SE durante la fase del metaanálisis cuantitativo; aunque se mantuvieron en la síntesis cualitativa. Los datos se procesaron en RStudio 2025.09.2+418 con el paquete “meta”.

Evaluación de sesgo

Y.N e I.M.N evaluaron de forma independiente el riesgo de sesgo con *Prediction model Risk Of Bias ASsessment Tool* (PROBAST+AI).^(8,9) Los 34 acápites de la herramienta se estructuran en cuatro dominios críticos: participantes, predictores, resultado y análisis. Las discrepancias se resolvieron mediante consenso. El riesgo de sesgo global se clasificó como “alto” si al menos un dominio se consideraba con alto riesgo. La evaluación global se expuso en un gráfico de barras apiladas. Los datos se procesaron en Robvis, programado en R.⁽¹⁰⁾

Análisis estadístico

El análisis estadístico se dividió en una fase cualitativa y una de síntesis cuantitativa. En esta última se incluyeron sólo los modelos que reportaron el AUC y el IC95% o SE. En los casos donde los estudios primarios omitieron el reporte del SE, este se estimó aplicando el método de Hanley y McNeil.⁽¹¹⁾ Para ello, se reconstruyó la varianza de la métrica de rendimiento al asumir una distribución asintótica normal. El cálculo se realizó a partir del valor de AUC reportado y el tamaño muestral específico de los subgrupos de pacientes con y sin recurrencia de FAP.

Si se reportaban valores de IC95%: $SE = \frac{AUC_{superior} - AUC_{inferior}}{2 \times 1,96}$

Sin valores del IC95%: Método de Hanley y McNeil:

1. Determinar probabilidades Q_1 y Q_2 : $Q_1 = \frac{\theta}{2 - \theta}$ y $Q_2 = \frac{2\theta^2}{1 + \theta}$; $\theta = AUC$

2. Sustituir en $SE(\theta) = \sqrt{\frac{\theta(1-\theta) + (n_A-1)(Q_1\theta^2) + (n_N-1)(Q_2-\theta^2)}{n_A \times n_N}}$; $N_A =$ enfermos y $N_N =$ sanos

RESULTADOS

La búsqueda inicial identificó 198 registros. Al final del proceso de revisión, se incluyeron siete estudios publicados entre 2020 y 2026. El diagrama de flujo PRISMA se presenta en la Figura 1.

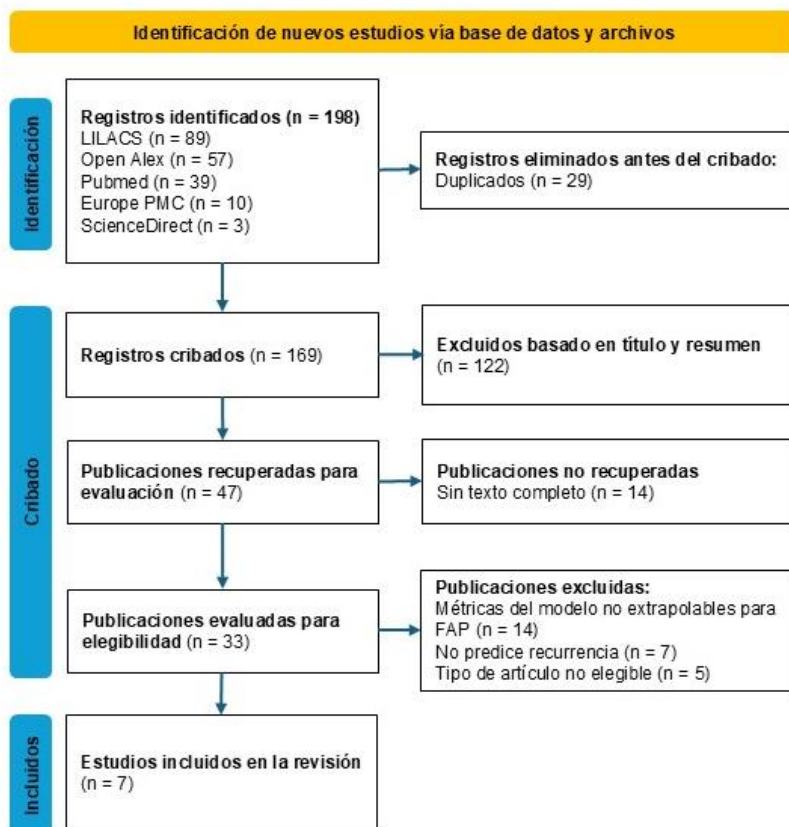


Fig. 1 - Diagrama de flujo PRISMA 2020.

La Tabla 1 resume las características de los estudios incluidos en el análisis cualitativo. Se analizaron 7 466 pacientes con FAP sometidos a ablación por catéter. Los estudios procedieron mayoritariamente de China (n=4). La recurrencia de FAP post-ablación varió del 13,47% al 37,5%. La edad media se situó entre 59 y 63 años. El sexo masculino representó del 55 al 74% de los participantes en los estudios. La mediana de seguimientos fue 15,6 meses. Las estrategias de validación incluyeron *Hold out* (n=4), *bootstrap* (n=1), *nested cross* (n=1) y *pooled cohort* (n=1).

Tabla 1 - Características de los estudios incluidos

| Autor | Año | País | Diseño | Muestra | Recurrencia | Edad | Masculino | Seguimiento | Validación |
|--|------------|----------------|-----------------------|----------------|--------------------|-------------|------------------|--------------------|-------------------|
| <i>Shade JK et al.</i> ⁽¹²⁾ | 2020 | Estados Unidos | Estudio retrospectivo | 32 | 37,5% | 63 ± 8,5 | 65% | 12,2 | Nested cross |
| <i>Jiang J et al.</i> ⁽¹³⁾ | 2023 | China | Cohorte retrospectiva | 1618 | 13,47% | 59,05 | 71% | 15,6 | Hold out |
| <i>Ma Y et al.</i> ⁽¹⁴⁾ | 2023 | China | Cohorte retrospectiva | 471 | 28,66% | 60,2 ± 10,6 | 55% | 25 | Hold out |
| <i>Liu CM et al.</i> ⁽¹⁵⁾ | 2024 | Taiwán | Retrospectivo | 638 | 23,04% | 56,3 ± 11,2 | 58% | 12 | Hold out |
| <i>Park H et al.</i> ⁽¹⁶⁾ | 2025 | Corea del Sur | Cohorte retrospectiva | 4385 | 24,95% | 60 | 61% | 24 | Pooled cohort |
| <i>Han X et al.</i> ⁽¹⁷⁾ | 2026 | China | Cohorte retrospectiva | 230 | 23,04% | 61,9 | 59% | 12 | Hold out |
| <i>Ren H et al.</i> ⁽¹⁸⁾ | 2026 | China | Cohorte retrospectiva | 92 | 14,13% | 60,1 ± 10,9 | 74% | 28 | Bootstrap |

La evaluación del riesgo de sesgo con PROBAST-AI se muestra en la Figura 2. Se identificó un alto riesgo de sesgo global los siete estudios. Esta calificación estuvo determinada principalmente por deficiencias críticas en el dominio de "análisis", relacionadas con tamaños muestrales insuficientes, falta de reporte de IC95% y omisión de calibración. A la vez, en dos estudios (28,6%) se identificaron preocupaciones en el dominio de "predictores", relacionadas con preprocesamiento complejo de imágenes sin validación externa de reproducibilidad. Por el contrario, el dominio de "participantes" y la aplicabilidad de los modelos presentó un riesgo de sesgo bajo en la totalidad de los estudios, al coincidir población, predictores y desenlace.




Fig. 2 – Evaluación del riesgo de sesgo. Herramienta PROBAST-AI.

Tabla 2 – Rendimiento discriminativo de los modelos de aprendizaje automático

| Estudio | Nombre | Familia | AUC (IC95%) | SE | Sensibilidad | Especificidad |
|--|------------------|---------|--------------------|--------------------|--------------|---------------|
| <i>Shade JK et al.</i> ⁽¹²⁾ | QDA | OTR | 0,82 (NR) | 0,083 ^a | 82% | 89% |
| <i>Jiang J et al.</i> ⁽¹³⁾ | CNN | NN | 0,84 (0,78 - 0,89) | 0,028 | 72,3% | 95% |
| <i>Ma Y et al.</i> ⁽¹⁴⁾ | Random Forest | ET | 0,67 (NR) | 0,029 ^a | 32,5% | NR |
| <i>Liu CM et al.</i> ⁽¹⁵⁾ | Ensemble (DL+ML) | OTR | 0,76 (NR) | 0,025 ^a | 86,7% | 51% |
| <i>Han X et al.</i> ⁽¹⁷⁾ | XGBoost | ET | 0,83 (NR) | 0,036 ^a | 69% | NR |

Legenda: ^a Error estándar estimado con Método de Hanley y McNeil; ^b El SE es reflejo del reducido tamaño muestral. CNN: redes neuronales convolucionales; DL: deep learning; ML: machine learning; NR: no referido; OTR: otras familias; QDA: análisis discriminante cuadrático

Se identificaron en total 17 algoritmos. Sin embargo, se excluyeron los modelos sin reporte de AUC, IC 95% extremadamente amplio o redundantes dentro de la misma familia. En la Tabla 2 se sintetizan las métricas de rendimiento de los cinco modelos elegidos para incluirse en el análisis cuantitativo. La familia de algoritmos, más frecuente fue *Ensemble Trees* (ET) con su variante *Random Forest* (RF). El AUC mostró alta variabilidad, con oscilaciones entre 0,67 y 0,84.

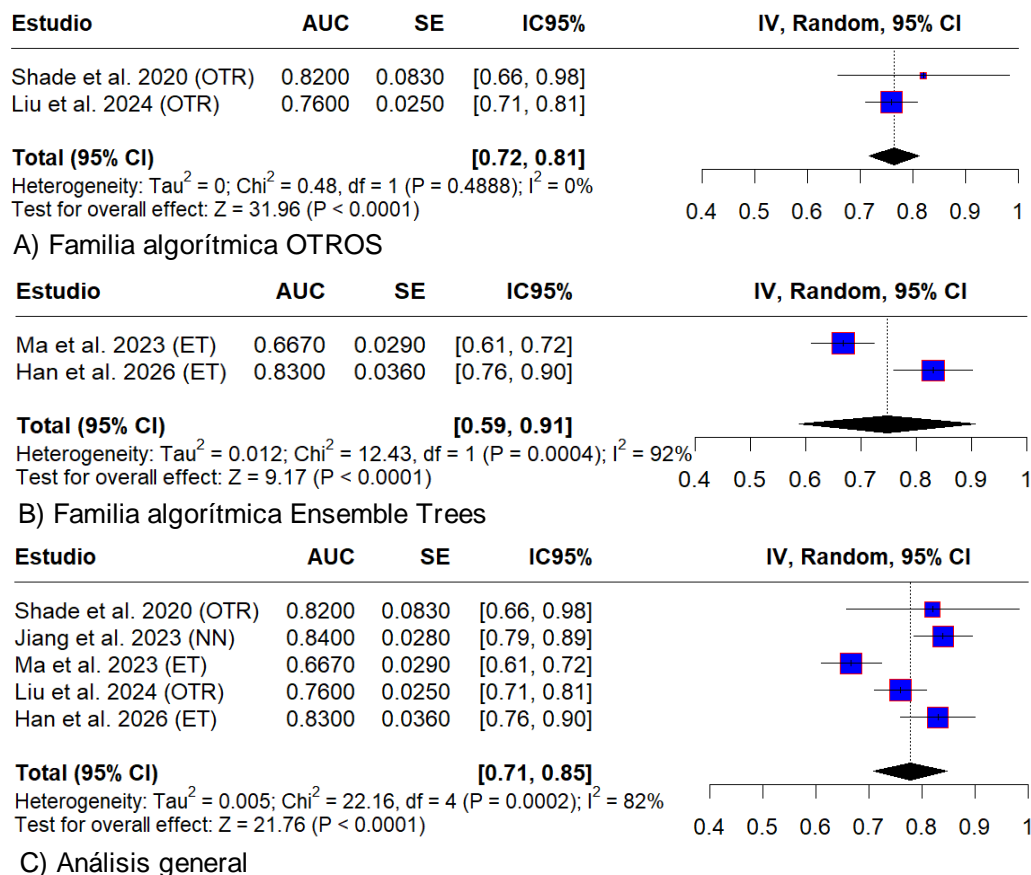


Fig. 3 – Metaanálisis de familias algorítmicas y general

Al estratificar el análisis por familia algorítmica (Figura 3), se observó que la familia de ET mostró un AUC de 0,75 (IC95%: 0,59-0,91), con una heterogeneidad extremadamente alta (I² = 92%; p < 0,0001). Por otro lado, la familia OTR obtuvo un AUC de 0,76 (IC95%: 0,72-0,81), con heterogeneidad no significativa (I² = 0%; p = 0,49). En el análisis general, se constató un AUC de 0,78 (IC95%: 0,71-0,85), con heterogeneidad alta (I² = 82%).

DISCUSIÓN

El rendimiento discriminativo obtenido en el metaanálisis sugiere una superioridad marcada de la IA frente a modelos convencionales como APPLE (AUC 0,63) y CAAP-AF (AUC 0,65).^(19,20) De igual forma, los modelos evaluados superan el rendimiento de escalas predictivas extrapoladas para recurrencia de la FAP como CHARGE-AF, FHS-AF, HATCH y CHA₂DS₂-VASc (AUC promedio de 0,67-0,69).⁽²¹⁾ Esto podría estar relacionado con la limitada capacidad de los anteriores modelos para capturar la complejidad biológica del sustrato proarrítmico de la FAP y las interacciones no lineales.

En contraste, las redes neuronales convolucionales (CNN) y arquitecturas basadas en *Transformer*, logran un rendimiento superior al procesar datos de alta dimensionalidad. Por ejemplo, *Jiang J et al.*⁽¹³⁾ obtuvo un modelo basado en redes neuronales (AUC = 0,84) superando puntajes de modelos convencionales, lo cual sostiene una estratificación de riesgo más precisa. No obstante, el análisis por subgrupos permitió identificar que la familia de *Ensemble Trees* (árboles de decisión integrados) presenta mayor inestabilidad, mientras que otras arquitecturas computacionales muestran una consistencia diagnóstica superior en la predicción de recurrencia de la FAP.

A pesar del rendimiento prometedor, la evaluación mediante PROBAST reveló un alto riesgo de sesgo global en la totalidad de los estudios, consistente con la literatura, donde se reportan fallos en los criterios de rigor estadístico de esta herramienta en el 87-88% de los modelos predictivos basados en IA.⁽²²⁾ El sesgo identificado se localiza predominantemente en el dominio de "análisis", lo que obliga a interpretar el AUC de 0,78 obtenido con cautela ante una probable sobreestimación del rendimiento real derivado de las deficiencias de los estudios primarios.

Con respecto al tamaño muestral, PROBAST exige al menos 100 eventos para una validación externa considerada robusta⁽⁸⁾; estándar que sólo el estudio de *Park H et al.*⁽¹⁶⁾ cumplió al emplear bases de datos multinacionales masivas. Modelos como el de *Shade JK et al.*⁽¹²⁾ y *Ren H et al.*⁽¹⁸⁾ fueron desarrollados en cohortes limitadas, lo que incrementa el riesgo de sobreajuste.

Para mitigar el sesgo de reporte en investigaciones que no informaron SE, se aplicó el método de Hanley y McNeil.⁽¹¹⁾ Esta aproximación estadística permitió una síntesis cuantitativa más inclusiva, al estimar el SE en base al tamaño de la muestra (total de pacientes con recurrencia y sin recurrencia de FAP), aspecto indispensable para la ejecución del modelo de efectos aleatorios empleado en el metaanálisis.

Un hallazgo fundamental lo constituye la baja preocupación en la aplicabilidad para la totalidad de la muestra. Lo cual confirma que los modelos analizados abordan a la población correcta (adultos con FAP) en base a predictores de alta relevancia clínica para la toma de decisiones. La coherencia entre los objetivos de estudios primarios y la estrategia PICO asegura que la IA evalúa el escenario clínico de interés.

Otro elemento sustancial del estudio de *Han X et al.*⁽¹⁷⁾ es la identificación por el algoritmo de parámetros estructurales de aurícula derecha como predictores clave. Bajo esta óptica, se podría estar en los inicios de un cambio de paradigma; de un enfoque centrado en aurícula izquierda a una visión holística biauricular, que motivaría una línea de investigación atractiva en el futuro.

La innovación en el uso de la IA también se refleja en dos aspectos capitales. Primero la predicción del riesgo de recurrencia según el sexo biológico, a través del análisis automático del trazado electrocardiográfico, identificado por el estudio de *Park H et al.*⁽¹⁶⁾. En segundo lugar, *Han X et al.*⁽¹⁷⁾ al emplear varias familias algorítmicas expone la necesidad de refinar la selección del algoritmo más apropiado en dependencia del objetivo explícito del modelo.

Se recomienda para futuras investigaciones en el campo de la predicción de recurrencia de FAP el reporte de los IC95% del AUC y la ejecución de validación externa en cohortes independientes. De forma particular en Latinoamérica, la implementación de estos modelos debería priorizar los basados en variables clínicas de fácil adquisición, garantía de viabilidad en entornos con recursos limitados.

Para finalizar, como limitaciones se declara la alta heterogeneidad detectada, lo que obliga a interpretar los resultados globales con moderación. Esta variabilidad, en opinión de los autores; puede atribuirse a diferencias en los protocolos de ablación, tiempos de seguimiento y las diversas arquitecturas algorítmicas empleadas.

CONCLUSIONES

Los modelos de aprendizaje automático exhiben un rendimiento discriminativo superior a las escalas de puntuación clínicas convencionales en la predicción de la recurrencia de la fibrilación auricular paroxística. A pesar de lo cual, la alta heterogeneidad entre diferentes familias algorítmicas exige una selección rigurosa y personalizada del modelo en función del contexto clínico. Por otra parte, el alto riesgo de sesgo identificado obliga a interpretar estas métricas de rendimiento con cautela, con necesidad imperativa de que futuras investigaciones estandaricen el reporte de la precisión y prioricen la validación externa en cohortes independientes antes de su aplicación a la práctica médica.

REFERENCIAS BIBLIOGRÁFICAS

1. Van Gelder IC, Rienstra M, Bunting KV, Casado-Arroyo R, Caso V, Crijns HJGM, et al. 2024 ESC Guidelines for the management of atrial fibrillation developed in collaboration with the European Association for Cardio-Thoracic Surgery (EACTS) [Internet]. Eur Heart J. 2024;45(36):3314–414. DOI: 10.1093/eurheartj/ehae176
2. Nápoles-Zaldivar Y, Nodarse-Palacios IM, Silva-Velasco E. Factores predictivos de recurrencia de fibrilación auricular paroxística tras ablación por catéter [Internet]. Rev Cuba Med Mil. 2026 [acceso: 17/05/2026];55(2):e026076659. Disponible en: <https://revmedmilitar.sld.cu/index.php/mil/article/view/76659>
3. Dilaveris PE, Kennedy HL. Silent atrial fibrillation: epidemiology, diagnosis, and clinical impact [Internet]. Clin Cardiol. 2017;40(6):413. DOI: 10.1002/clc.22667

4. Rojel U, Diaz JC, Oliveira Figueiredo MJ de, Di Biase L, Saad E, Aguinaga-Arrascue L, et al. Current state of arrhythmia care in Latin America: A statement from the Latin American Heart Rhythm Society [Internet]. *Heart Rhythm O2*. 2024;6(1):112–26. DOI: 10.1016/j.hroo.2024.11.010
5. Rawshani A, Rawshani A, Smith G, Boren J, Bhatt DL, Börjesson M, et al. Integrating deep learning with ECG, heart rate variability and demographic data for improved detection of atrial fibrillation [Internet]. *Open Heart*. 2025;12(1):e003185. DOI: 10.1136/openhrt-2025-003185
6. Page M, McKenzie J, Bossuyt P, Boutron I, Hoffmann T, Mulrow C, et al. Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas [Internet]. *Rev Esp Cardiol*. 2021;74(9):790–9. DOI: [10.1016/j.recesp.2021.06.016](https://doi.org/10.1016/j.recesp.2021.06.016)
7. Nápoles-Zaldivar Y, Nodarse-Palacios IM. Machine learning models performance in prediction of paroxysmal atrial fibrillation recurrence [Internet]. PROSPERO. 2026 [acceso:17/05/2026]. Disponible en: <https://www.crd.york.ac.uk/PROSPERO/view/CRD420261398192>
8. Moons KGM, Damen JAA, Kaul T, Hooft L, Andaur Navarro C, Dhiman P, et al. PROBAST+AI: an updated quality, risk of bias, and applicability assessment tool for prediction models using regression or artificial intelligence methods [Internet]. *BMJ*. 2025;388:e082505. DOI: 10.1136/bmj-2024-082505Wolff RF
9. Wolff RF, Moons KGM, Riley RD, Whiting PF, Westwood M, Collins GS, et al. PROBAST: A Tool to Assess the Risk of Bias and Applicability of Prediction Model Studies [Internet]. *Ann Intern Med*. 2019;170(1):51–8. DOI: 10.7326/M18-1376
10. McGuinness LA, Higgins JPT. Risk-of-bias Visualization (robvis): An R package and Shiny web app for visualizing risk-of-bias assessments [Internet]. *Res Synth Methods*. 2021;12(1):55–61. DOI: 10.1002/jrsm.1411

11. Hanley JA, McNeil BJ. The meaning and use of the area under a receiver operating characteristic (ROC) curve [Internet]. *Radiology*. 1982;143(1):29–36. DOI: 10.1148/radiology.143.1.7063747
12. Shade JK, Ali RL, Basile D, Popescu D, Akhtar T, Marine JE, et al. Preprocedure Application of Machine Learning and Mechanistic Simulations Predicts Likelihood of Paroxysmal Atrial Fibrillation Recurrence Following Pulmonary Vein Isolation [Internet]. *Circ Arrhythm Electrophysiol*. United States; 2020;13(7):e008213. DOI: 10.1161/CIRCEP.119.008213
13. Jiang J, Deng H, Liao H, Fang X, Zhan X, Wei W, et al. An Artificial Intelligence-Enabled ECG Algorithm for Predicting the Risk of Recurrence in Patients with Paroxysmal Atrial Fibrillation after Catheter Ablation [Internet]. *J Clin Med*. Switzerland; 2023;12(5). DOI: 10.3390/jcm12051933
14. Ma Y, Zhang D, Xu J, Pang H, Hu M, Li J, et al. Explainable machine learning model reveals its decision-making process in identifying patients with paroxysmal atrial fibrillation at high risk for recurrence after catheter ablation [Internet]. *BMC Cardiovasc Disord*. England; 2023;23(1):91. DOI: 10.1186/s12872-023-03087-0
15. Liu C-M, Chen W-S, Chang S-L, Hsieh Y-C, Hsu Y-H, Chang H-X, et al. Use of artificial intelligence and I-Score for prediction of recurrence before catheter ablation of atrial fibrillation [Internet]. *Int J Cardiol*. 2024;402:131851. DOI: 10.1016/j.ijcard.2024.131851
16. Park H, Kwon O, Shim J, Kim D, Park J, Kim Y-G, et al. Artificial intelligence-estimated electrocardiographic sex as a recurrence predictor after atrial fibrillation catheter ablation [Internet]. *Eur Heart J - Digit Health*. Oxford University Press; 2025;6(4):624–34. DOI: 10.1093/ehjdh/ztaf054

17. Han X, Liu T, Li M, Liu Y, Li F, Pan T, et al. Atrial fibrillation type-specific prediction of recurrence after catheter ablation: the pivotal role of right atrial remodeling revealed by explainable machine learning [Internet]. *Front Cardiovasc Med*. Frontiers Media; 2026;13. DOI: 10.3389/fcvm.2026.1805262
18. Ren H, Lai H. Integrating traditional statistics and explainable machine learning for risk stratification of atrial fibrillation recurrence after pulsed field ablation: a hypothesis-generating single-center study [Internet]. *BMC Cardiovasc Disord*. England; 2026;26(1). DOI: 10.1186/s12872-026-05666-3
19. Kornej J, Hindricks G, Shoemaker MB, Husser D, Arya A, Sommer P, et al. The APPLE score: a novel and simple score for the prediction of rhythm outcomes after catheter ablation of atrial fibrillation [Internet]. *Clin Res Cardiol*. 2015;104(10):871–6. DOI: 10.1007/s00392-015-0856-x
20. Winkle RA, Jarman JWE, Mead RH, Engel G, Kong MH, Fleming W, et al. Predicting atrial fibrillation ablation outcome: The CAAP-AF score [Internet]. *Heart Rhythm*. 2016;13(11):2119–25. DOI: 10.1016/j.hrthm.2016.07.018
21. Himmelreich JCL, Veelers L, Lucassen WAM, Schnabel RB, Rienstra M, van Weert HCPM, et al. Prediction models for atrial fibrillation applicable in the community: a systematic review and meta-analysis [Internet]. *Eur Eur Pacing Arrhythm Card Electrophysiol J Work Groups Card Pacing Arrhythm Card Cell Electrophysiol Eur Soc Cardiol*. 2020;22(5):684–94. DOI: 10.1093/europace/euaa005
22. Andaur Navarro CL, Damen JAA, Takada T, Nijman SWJ, Dhiman P, Ma J, et al. Risk of bias in studies on prediction models developed using supervised machine learning techniques: systematic review [Internet]. *BMJ*. 2021;n2281. DOI: 10.1136/bmj.n2281

Conflictos de interés

Los autores declaran que no existen conflictos de interés.

Información financiera

No se recibió financiamiento para realizar esta revisión.

Contribuciones de los autores

Conceptualización: Yoander Nápoles-Zaldivar, Ivonne María Nodarse-Palacios

Curación de datos: Yoander Nápoles-Zaldivar, Ivonne María Nodarse-Palacios, Edilio Silva-Velasco, Juan Carlos Báster-Moro, Luis Aníbal Alonso-Betancourt

Análisis Formal: Yoander Nápoles-Zaldivar, Ivonne María Nodarse-Palacios, Edilio Silva-Velasco

Investigación: Yoander Nápoles-Zaldivar, Ivonne María Nodarse-Palacios, Edilio Silva-Velasco, Juan Carlos Báster-Moro, Luis Aníbal Alonso-Betancourt

Metodología: Yoander Nápoles-Zaldivar, Ivonne María Nodarse-Palacios

Software: Yoander Nápoles-Zaldivar

Redacción - Elaboración del borrador original: Juan Carlos Báster-Moro, Luis Aníbal Alonso-Betancourt

Redacción - Revisión y edición: Yoander Nápoles-Zaldivar, Ivonne María Nodarse-Palacios, Edilio Silva-Velasco

Disponibilidad de datos

Material Suplementario. Estrategia de búsqueda, familias algorítmicas y código para RStudio. Microsoft Word 2024

MATERIAL SUPLEMENTARIO**Fecha:** 09/05/2026**Tabla S1** - Estrategia de búsqueda

| Base de datos | Ecuación de búsqueda | n |
|----------------------|---|----------|
| Pubmed | ((("Atrial Fibrillation"[MeSH Terms] OR "Atrial Fibrillation"[Title/Abstract]) AND ("paroxysmal"[Title/Abstract] OR "paroxysmal atrial fibrillation"[Title/Abstract])) AND ("Recurrence"[MeSH Terms] OR "Recurrence"[Title/Abstract]) AND ("Machine Learning"[MeSH Terms] OR "Artificial Intelligence"[MeSH Terms] OR "Deep Learning"[MeSH Terms] OR "machine learning"[Title/Abstract] OR "deep learning"[Title/Abstract] OR "neural network"[Title/Abstract]) | 39 |
| Open Alex | ("paroxysmal atrial fibrillation" OR "paroxysmal AF") AND ("recurrence" OR "relapse") AND ("machine learning" OR "artificial intelligence" OR "deep learning" OR "neural network") | 57 |
| Sciencedirect | "paroxysmal atrial fibrillation" AND ("recurrence" OR "relapse") AND ("machine learning" OR "artificial intelligence" OR "deep learning" OR "neural network") | 3 |
| Europe PMC | (MESH:"Atrial Fibrillation" OR TITLE_ABS:"Atrial Fibrillation") AND (TITLE_ABS:"paroxysmal") AND (MESH:"Recurrence" OR TITLE_ABS:"Recurrence") AND (TITLE_ABS:"machine learning" OR TITLE_ABS:"deep learning" OR TITLE_ABS:"neural network" OR TITLE_ABS:"artificial intelligence") | 10 |

| Base de datos | Ecuación de búsqueda | n |
|---------------|---|-----|
| LILACS | "paroxysmal atrial fibrillation" AND ("recurrence" OR "relapse") AND ("machine learning" OR "artificial intelligence" OR "deep learning" OR "neural network") | 89 |
| Total: | - | 198 |

Nota: Todas las búsquedas se ejecutaron el 09/05/2026. El total no descuenta posibles duplicados entre bases de datos, que fueron eliminados en la fase de cribado conforme al diagrama de flujo PRISMA.

Tabla S2 - Nodos de la red (familias algorítmicas)

| Nodo | Familia | Algoritmos incluidos |
|------------|------------------------|--|
| NN | <i>Neural Networks</i> | ANN, CNN, RNN, LSTM, <i>Deep Learning</i> (≥ 2 capas ocultas) |
| ET | <i>Ensemble trees</i> | Random Forest, XGBoost, LightGBM, CatBoost, Gradient Boosting Machines |
| SVM | <i>Kernel-based</i> | Support Vector Machine (lineal, RBF, polinomial), SVR |
| RLR | Regresión regularizada | LASSO, Ridge, <i>Elastic Net</i> |
| DT | Árboles simples | CART, C4.5, ID3, árbol de decisión único |
| KNN | Basados en vecinos | K-Nearest Neighbors, weighted KNN |
| NB | Probabilísticos | Naïve Bayes, redes bayesianas |
| OTR | Otros | Modelos no clasificables en categorías anteriores |

Código introducido en R para construir los Forest Plot en RStudio.

```
library(meta)
datos <- data.frame(
  estudio = c("Shade et al. 2020 (OTR)",
             "Jiang et al. 2023 (NN)",
             "Ma et al. 2023 (ET)",
             "Liu et al. 2024 (OTR)",
             "Han et al. 2026 (ET)"),
  familia = c("OTR", "NN", "ET", "OTR", "ET"),
  auc = c(0.82, 0.84, 0.667, 0.76, 0.83),
  se = c(0.083, 0.028, 0.029, 0.025, 0.036)
)
settings.meta("RevMan5")

# 1. FOREST PLOT FAMILIA ET
datos_ET <- datos[datos$familia == "ET", ]
meta_ET <- metagen(TE = auc, seTE = se,
                  data = datos_ET, studlab = estudio,
                  common = FALSE, random = TRUE, method.tau = "DL")
png("forest_ET.png", width = 1200, height = 300, res = 150)
forest(meta_ET,
       xlim = c(0.4, 1.0),
       xlab = "AUC",
       fontsize = 12,
       # Separación de texto y gráfico
       colgap = "0.5cm",
       colgap.forest.left = "2.2cm",
       # Columnas a la izquierda
       leftcols = c("studlab", "TE", "seTE", "ci"),
```

```
leftlabs = c("Estudio", "AUC", "SE", "IC95%"),
leftjust = c("left", "center", "center", "center"),
# Colores, etiquetas y posición
col.square = "blue",
col.diamond = "red",
overall = TRUE)
dev.off()

# 2. FOREST PLOT FAMILIA OTR
datos_OTR <- datos[datos$familia == "OTR", ]
meta_OTR <- metagen(TE = auc, seTE = se,
                    data = datos_OTR, studlab = estudio,
                    common = FALSE, random = TRUE, method.tau = "DL")

png("forest_OTR.png", width = 1200, height = 300, res = 150)
forest(meta_OTR,
       xlim = c(0.4, 1.0),
       xlab = "AUC",
       fontsize = 12,
       # Separación de texto y gráfico
       colgap = "0.5cm",
       colgap.forest.left = "2.2cm",
       # Columnas a la izquierda
       leftcols = c("studlab", "TE", "seTE", "ci"),
       leftlabs = c("Estudio", "AUC", "SE", "IC95%"),
       leftjust = c("left", "center", "center", "center"),
       # Colores, etiquetas y posición
       col.square = "blue",
       col.diamond = "red",
```

```
        overall = TRUE)
dev.off()

# 3. FOREST PLOT GENERAL
meta_general <- metagen(TE = auc, seTE = se,
                        data = datos, studlab = estudio,
                        common = FALSE, random = TRUE, method.tau = "DL")

png("forest_general.png", width = 1200, height = 400, res = 150)
forest(meta_general,
       xlim = c(0.4, 1.0),
       xlab = "AUC",
       fontsize = 12,
       # Separación de texto y gráfico
       colgap = "0.5cm",
       colgap.forest.left = "2.2cm",
       # Columnas a la izquierda
       leftcols = c("studlab", "TE", "seTE", "ci"),
       leftlabs = c("Estudio", "AUC", "SE", "IC95%"),
       leftjust = c("left", "center", "center", "center"),
       # Colores, etiquetas y posición
       col.square = "blue",
       col.diamond = "red",
       overall = TRUE)
dev.off()

# RESULTADOS
cat("\n=== FAMILIA ENSEMBLE TREES ===\n")
print(summary(meta_ET))
```

```
cat("\n=== FAMILIA OTROS ===\n")  
print(summary(meta_OTR))
```

```
cat("\n=== METAANÁLISIS GENERAL ===\n")  
print(summary(meta_general))
```

Este preprint fue presentado bajo las siguientes condiciones:

- Los autores declaran que se obtuvieron los términos necesarios del consentimiento libre e informado de los participantes o pacientes en la investigación y se describen en el manuscrito, cuando corresponde.
- Los autores declaran que la preparación del manuscrito siguió las normas éticas de comunicación científica.
- Los autores declaran que son conscientes de que son los únicos responsables del contenido del preprint y que el depósito en SciELO Preprints no significa ningún compromiso por parte de SciELO, excepto su preservación y difusión.
- Los autores declaran que los datos, las aplicaciones y otros contenidos subyacentes al manuscrito están referenciados.
- El manuscrito depositado está en formato PDF.
- Los autores declaran que la investigación que dio origen al manuscrito siguió buenas prácticas éticas y que las aprobaciones necesarias de los comités de ética de investigación, cuando corresponda, se describen en el manuscrito.
- Los autores declaran que una vez que un manuscrito es postado en el servidor SciELO Preprints, sólo puede ser retirado mediante solicitud a la Secretaría Editorial deSciELO Preprints, que publicará un aviso de retracción en su lugar.
- Los autores aceptan que el manuscrito aprobado esté disponible bajo licencia [Creative Commons CC-BY](#).
- El autor que presenta el manuscrito declara que las contribuciones de todos los autores y la declaración de conflicto de intereses se incluyen explícitamente y en secciones específicas del manuscrito.
- Los autores declaran que el manuscrito no fue depositado y/o previamente puesto a disposición en otro servidor de preprints o publicado en una revista.
- Si el manuscrito está siendo evaluado o siendo preparando para su publicación pero aún no ha sido publicado por una revista, los autores declaran que han recibido autorización de la revista para hacer este depósito.
- El autor que envía el manuscrito declara que todos los autores del mismo están de acuerdo con el envío a SciELO Preprints.