

Modelo de aprendizaje automático para la predicción del implante de marcapasos tras TAVI en práctica clínica real

Antonio Fuentes Vivero(1), Guillermo Aldama López(2), Domingo José López Vázquez(2), Miguel Louro Freire(2), Miguel González Montes(1), Gabriel González Barbeito(1), Carmen Vidau Getán(1), Fausto de Andrés Cardelle(1), Vicente Piñero Maciá(1), Diego Pérez Ortiz(1), Rodrigo Ignacio Aranibar Martínez(1), Raquel Vázquez García(3), Pablo Fernández de Aspe(3), Ramón Calviño Santos(2) y José Manuel Vázquez Rodríguez(2) de (1)Servicio de Cardiología, (2)Unidad de Hemodinámica, Servicio de Cardiología y (3)Unidad de Electrofisiología y Arritmias, Servicio de Cardiología. Complexo Hospitalario Universitario A Coruña, A Coruña - España

Introducción: El implante de marcapasos (MP) tras el implante percutáneo de válvula aórtica (TAVI) sigue siendo una complicación frecuente con importantes implicaciones clínicas. La evidencia reciente es contradictoria respecto a la superioridad de los modelos de aprendizaje automático frente a la regresión logística, y persisten limitaciones para identificar predictores robustos, especialmente en el implante tardío. El objetivo de este estudio fue desarrollar y validar un modelo de aprendizaje automático para predecir el implante de MP a 30 días tras TAVI en una cohorte de práctica clínica real.

Métodos: Se analizaron los datos de 1.047 pacientes sometidos a TAVI en un centro terciario entre 2008 y 2024. Se desarrollaron distintos modelos de aprendizaje automático, seleccionándose el algoritmo Random Forest en función de su rendimiento global. La cohorte se dividió en un conjunto de derivación (n=732) para el entrenamiento del modelo y un conjunto independiente de validación (n=315) para evaluar su rendimiento.
Se incluyeron variables clínicas, electrocardiográficas y procedimentales, tales como comorbilidades, parámetros de conducción (intervalos PR y QRS, así como trastornos de conducción basales), función ventricular izquierda y características protésicas valvulares (incluyendo tipo y tamaño protésico). La incidencia de implante de MP fue del 20,6% en la cohorte de derivación y del 21% en la cohorte de validación, sin diferencias estadísticamente significativas.

Resultados: El modelo Random Forest mostró adecuada discriminación (AUC 0,74), alto valor predictivo negativo (0,91) y buena calibración (Brier 0,148). Los predictores más relevantes fueron las alteraciones basales de conducción —especialmente el bloqueo de rama derecha—, el mayor tamaño protésico y la duración del QRS a las 24 horas. Se observó una relación no lineal entre tamaño valvular y riesgo, con menor riesgo en prótesis de 23 mm.

Conclusiones: Un modelo de aprendizaje automático basado en Random Forest permite predecir el implante de MP tras TAVI con adecuada capacidad discriminativa, buen valor predictivo negativo y correcta calibración. Su implementación podría mejorar la estratificación del riesgo y optimizar la toma de decisiones clínicas,

particularmente en la identificación de pacientes con mayor probabilidad de desarrollar trastornos de conducción que requieran estimulación cardíaca permanente.

