



5009-3. MACHINE LEARNING EN LA PREDICCIÓN DE ÉXITO DE LA CARDIOVERSIÓN ELÉCTRICA PROGRAMADA EN LA FIBRILACIÓN AURICULAR

Jean Carlos Núñez García, Víctor Vicente Palacios, P. Ignacio Dorado Díaz y Pedro Luis Sánchez Fernández, del Servicio de Cardiología, Complejo Universitario de Salamanca, IBSAL, CIBER-CV, Salamanca.

Resumen

Introducción y objetivos: A pesar de no brindar ventajas pronósticas, el control de ritmo en fibrilación auricular (FA) presenta ventajas en casos seleccionados, siendo la cardioversión eléctrica (CVE) una de las técnicas utilizadas con este fin pero con tasas de fallo o recurrencia precoz que supera el 30%. Por este motivo identificar que pacientes podrían beneficiarse de la CVE es un reto clínico. El *Machine Learning* (ML), inteligencia artificial, es un método innovador que comienza a introducirse en medicina al crear sistemas que aprenden automáticamente, identificando patrones complejos en bases de datos y estableciendo algoritmos capaces de predecir comportamientos futuros. Con estos modelos podríamos crear aplicaciones capaces de predecir el riesgo individual del paciente y mejorar el modelo de forma automática.

Métodos: Hemos realizado 2 modelos de ML en la predicción de éxito de la CVE. Un primer modelo intentará predecir si la CVE será inicialmente efectiva durante la descarga eléctrica. Un segundo modelo predecirá la recaída a 6 meses en FA tras un CVE inicialmente exitosa. Mediante técnicas de minería de datos se escogieron las variables más discriminantes de las distintas categorías a predecir en ambos modelos. Posteriormente se realizaron los modelos ML con técnicas de Random Forest y máquinas de vector de soporte lineal. El resultado de estos modelos ML fue comparado con el obtenido de 2 modelos clásicos estadísticos (regresión logística y análisis discriminante lineal). Para validar los ajustes se empleó una validación cruzada de 3 subconjuntos repetida 35 veces.

Resultados: A partir de los datos estructurados obtenidos de 320 CVEs, se identificaron las variables discriminantes para los modelos ML. Las más significativas fueron: el volumen auricular, el tipo y tiempo de diagnóstico de la FA, FEVI, masa del VI, insuficiencia mitral, ICC, CF NYHA, neumopatías, función renal, cantidad de choques necesarios para la CVE, y CV espontánea. Los resultados (área bajo la curva) de los modelos ML fueron similares a los resultados obtenidos con estadística clásica (tabla).

Áreas bajo la curva de los distintos modelos

Modelo		CV efectiva	Recaída
Estadística clásica	Regresión logística	0,6655	0,6622

Análisis discriminante lineal	0,6637	0,6515	
	Random Forest	0,6207	0,672
Machine Learning	Máquinas de vector de soporte	0,6592	0,6497

Métrica: ROC AUC.

Conclusiones: Es necesario continuar explorando sistemas de ML en otros contextos clínicos de la cardiología, pero su aplicación no siempre mejorará los modelos predictivos habituales; especialmente cuando los tamaños muestrales no sean muy grandes.