



5007-7. INTELIGENCIA ARTIFICIAL FRENTE A ESTADÍSTICA CLÁSICA EN LA PREDICCIÓN DE CARDIOVERSIÓN ESPONTÁNEA, FARMACOLÓGICA, ELÉCTRICA Y RECURRENCIA DE FIBRILACIÓN AURICULAR


Jean Carlos Núñez García¹, Antonio Sánchez-Puente², Jesús Sampedro Gómez³, Víctor Vicente Palacios¹, Pedro Ignacio Dorado Díaz³, Juan Carlos Castro Garay⁴, David González Calle¹, Marta Alonso Fernández de Gatta¹, Javier Jiménez Candil¹, Jendri Manuel Pérez Perozo¹, Fabián Blanco Fernández⁴, Milena Antúnez Ballesteros⁴, Mónica García Monsalvo⁴ y Pedro Luis Sánchez Fernández¹, del ¹Complejo Asistencial Universitario de Salamanca, Salamanca, ²Instituto de Investigación Biomédica de Salamanca IBSAL, Salamanca y ³Centros de Investigación Biomédica en Red CIBER, Salamanca.

Resumen

Introducción y objetivos: Con el fin de evitar procedimientos y fármacos inútiles o innecesarios, se han identificado mediante métodos estadísticos clásicos (MEC), múltiples factores clave para el desarrollo de modelos predictivos del éxito de la cardioversión eléctrica (CVE), espontánea (CVE), farmacológica (CVF) y recurrencia de fibrilación auricular (RFA). El *machine learning* (ML) provee herramientas que mejoran la estratificación de pacientes que ofrecen los MEC, sin embargo, no se han publicado resultados positivos de ML en este contexto. El objetivo de este estudio es comparar la predicción de CVE, CVF, CVE y RFA a 6 meses mediante ML frente a modelos predictivos establecidos creados con MEC.

Métodos: Se han ajustado modelos de ML independientes para cada evento (CVE, CVF, CVE y RFA), escogiendo las variables más discriminantes de los distintos eventos mediante minería de datos. Para validar los ajustes se empleó una validación cruzada de 10 subconjuntos repetida 10 veces. Finalmente, se compararon los resultados con 2 escalas publicadas y creadas con MEC (escalas HATCH y CHA₂DS₂-VASc) frente a ML.

Resultados: A partir de una base con 320 CVEs, se identificaron múltiples variables discriminantes para cada modelo de ML (tabla). La predicción de los eventos mediante las escalas HATCH y CHA₂DS₂-VASc fue insuficiente salvo en la predicción de CVE (AUC CVE 0,68 y 0,66; AUC CVF 0,55 y 0,53; AUC CVE o CVF 0,55 y 0,53; AUC CVE 0,53 y 0,48; y AUC RFA 0,56 y 0,54). El algoritmo de clasificación mediante ML de mayor rendimiento variaba en función del evento a predecir: Random Forest para CVE, CVE o CVF y RFA (AUC 0,82, 0,78 y 0,71); regresión logística mediante ML para CVF (AUC 0,77); y XGBoost para CVE (AUC 0,62). Las diferencias encontradas entre los modelos de ML y los MEC fueron estadísticamente significativas. En la figura se muestra la comparación de las curvas ROC para cada evento.



Curvas ROC Machine Learning, HATCH y CHA₂DSVAsc.

Conclusiones: Describimos el primer modelo predictivo mediante técnicas de ML con resultados positivos en este contexto. En nuestro medio, el ML supera el rendimiento de escalas creadas con estadística clásica publicados en revistas de impacto.