



4013-2. APRENDIZAJE AUTOMÁTICO (MACHINE LEARNING) EN EL DIAGNÓSTICO DEL INFARTO DE MIOCARDIO CON ARTERIAS CORONARIAS SIN ESTENOSIS SIGNIFICATIVAS. (MINOCA)

María Jesús Espinosa Pascual¹, Pablo Vaquero Martínez¹, Víctor Vaquero Martínez², Javier López Pais³, Barbara Izquierdo Coronel¹, David Galán Gil¹, Renée Olsen Rodríguez¹, Rocío Abad Romero¹ y Joaquín Jesús Alonso Martín¹


¹Hospital Universitario de Getafe (Madrid). ²Universidad de Valladolid. ³Centro Hospitalario Universitario de Santiago de Compostela (A Coruña).

Resumen

Introducción y objetivos: El MINOCA representa en torno al 10-15% de todos los IAM. Los algoritmos de clasificación basados en aprendizaje profundo pudieran ser una alternativa a los algoritmos tradicionales. Se han publicado numerosos modelos de aprendizaje automático en diversas patologías, pero hasta la fecha ningún estudio ha propuesto un algoritmo para el diagnóstico del MINOCA. El objetivo de nuestro estudio es estimar la precisión diagnóstica de varios algoritmos de aprendizaje automatizado (Support-Vector Machine [SVM], Random Forest [RF] y Logistic Regression [LR]) para discriminar al ingreso y antes de realizar una coronariografía, las personas que sufren un MINOCA de aquellas con IAM con lesiones significativas (MICAD).

Métodos: Se realizó una evaluación de pruebas diagnósticas aplicando los algoritmos propuestos a una base de datos constituida por 553 pacientes (pts) consecutivos ingresados por IAM en nuestro hospital. Según las definiciones del documento de consenso sobre el MINOCA publicado por la ESC en 2016, los pts se clasificaron en dos grupos: MICAD y MINOCA. Del total de pts, 214 fueron descartados debido a la falta de un mínimo del 90% de los datos completos. El conjunto de algoritmos se entrenó en 244 pts y se probó en 80 pts. Un total de 64 variables (características demográficas, clínicas y de laboratorio) fueron analizadas para cada pt antes de la coronariografía. Finalmente se tomó la precisión diagnóstica de cada algoritmo de aprendizaje automatizado.

Resultados: El modelo de clasificación más preciso fue el Random Forest (E 0,88, S 0,57, VPN 0,93, AUC 0,85 [IC 0,83-0,88]) seguido de la LR estándar (E 0,76, S 0,57, VPN 0,92, AUC 0,74) y SVM (E 0,84, S 0,38, VPN 0,90, AUC 0,78). Las variables que más contribuyeron para discriminar MINOCA de MICAD fueron los FRCV, los biomarcadores de lesión miocárdica, los niveles de hemoglobina y el sexo. Los resultados fueron similares cuando se excluyeron del análisis a los 19 pacientes con síndrome de Takotsubo.



Curvas ROC de los diferentes algoritmos para el diagnóstico de MINOCA.

Conclusiones: Se desarrolló un modelo de predicción para el diagnóstico de MINOCA antes de realizar una coronariografía utilizando algoritmos de aprendizaje automático. Los resultados muestran una mayor precisión del algoritmo RF en el diagnóstico de MINOCA que los métodos estadísticos convencionales. Este estudio respalda la potencial aplicación de los algoritmos de aprendizaje automático en la cardiología clínica. Sin embargo, se requieren mayores estudios para validar estos resultados.