


# Comparativa de modelos de machine learning frente al GRACE score para la predicción de MACE a un año en pacientes con síndrome coronario agudo sin elevación del ST

Javier Vilasánchez Vilar(1), Gabriel González Barbeito(1), Antonio Fuentes Vivero(1), Rodrigo Ignacio Araníbar Martínez(1), Miguel González Montes(1), Carmen Vidau Getán(1), Diego Pérez Ortiz(1), Miguel Louro Freire(1), Lucas Calvo Dios(1), Vicente Piñero Maciá(1), Fausto de Andrés Cardelle(1) y Guillermo Aldama López(2) de (1)Servicio de Cardiología y (2)Servicio de Cardiología. Unidad de Hemodinámica. Complexo Hospitalario Universitario A Coruña, A Coruña - España

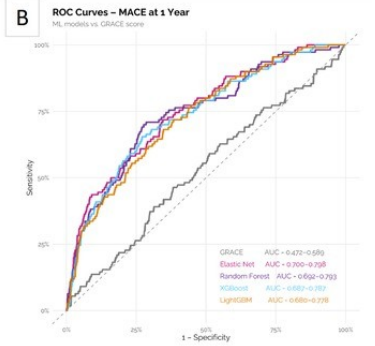
Introducción: La estratificación de pacientes con síndrome coronario agudo sin elevación del ST (SCASEST) constituye un reto por sus implicaciones en nuestra práctica clínica. Los modelos predictivos vigentes, como el GRACE score, se elaboraron en un periodo en el que no estaban tan extendidas la revascularización percutánea ni los tratamientos médicos de alta intensidad. El objetivo fue comparar el rendimiento de modelos de machine learning (ML) frente al GRACE score para predecir MACE al año en una cohorte contemporánea.

Métodos: Estudio observacional retrospectivo de 3380 pacientes ingresados por SCASEST (IAMSEST o angina inestable) registrados en una base de datos entre 2018 y 2022. El objetivo primario fue el combinado de MACE a los 12 meses: síndrome coronario agudo (SCA), hospitalización por insuficiencia cardíaca (IC) y mortalidad total. Se desarrollaron cuatro modelos de ML: Elastic Net, Random Forest (RF), XGBoost y LightGBM, comparándolos con el GRACE score. Se evaluó la discriminación mediante el área bajo la curva ROC (AUC), la calibración mediante el score de Brier y las curvas de calibración y la utilidad clínica neta mediante curvas de análisis de decisión (DCA).

Resultados: La tasa de MACE al año fue del 10.8% (n=365): SCA 4.85% (n=164), hospitalización por IC 3.13% (n=106) y mortalidad total 4.32% (n=146). El GRACE score mostró una baja discriminación (AUC 0.531), mala calibración (Brier 0.167) y ausencia de beneficio neto en las DCA. Los modelos de ML superaron significativamente al GRACE. El RF fue el test que obtuvo mejor rendimiento global (AUC 0.743; Brier 0.092) con una sensibilidad del 70.9%, especificidad del 71.4% y alto valor predictivo negativo (95.3%), siendo el único modelo con beneficio neto clínico para umbrales de probabilidad entre 0–20% en la DCA (gráfico D, figura 1). Las variables predictoras más relevantes fueron: enfermedad arterial coronaria previa, infarto de miocardio previo, tratamiento previo con IECA, diabetes mellitus, tratamiento previo con antagonistas del calcio y clase Killip al ingreso (gráfico E, figura 1), entre otras.

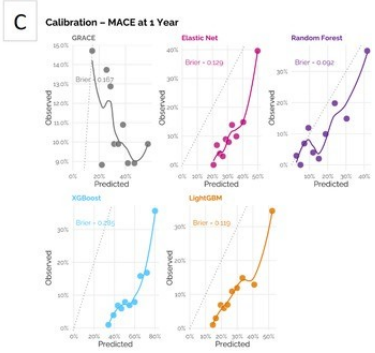
Conclusiones: Los modelos de ML, especialmente el Random Forest, superaron al GRACE score para la predicción de MACE al año en nuestra cohorte de SCASEST. Además constituyen una herramienta prometedora para la estratificación del riesgo y la optimización de las decisiones terapéuticas.


A
Model Comparison – Test Set
AUC
Sensitivity
Specificity
PPV
NPV
Brier
LightGBM
XGBoost
Random Forest
Elastic Net
GRACE


B
ROC Curves – MACE at 1 Year
ML models vs. GRACE score
Sensitivity
1 – Specificity
GRACE AUC = 0.472–0.589
Elastic Net AUC = 0.700–0.798
Random Forest AUC = 0.692–0.793
XGBoost AUC = 0.687–0.787
LightGBM AUC = 0.680–0.778


D
Decision Curve Analysis – MACE at 1 Year
Net benefit across clinical decision thresholds
Net benefit
Threshold probability
GRACE
Elastic Net
Random Forest
XGBoost
LightGBM
Treat all
Treat none


E
Variable Importance
Random Forest – Permutation Importance
eac_previa
im_previo_bin
ieca_previo
dm
calcioant_previo
killip
hta
aas_previo
arteriopatia_previa
erc_previa
estatina_previa
bb_previo
icp_previa
diureticos_previo
nitratos_previo
ipzyt2_previo_bin
cr_ingreso
tabaco
sexo
dislipemia
Relative importance (%)


C
Calibration – MACE at 1 Year
GRACE
Elastic Net
Random Forest
XGBoost
LightGBM
Observed
Predicted