

MODELO ANALÍTICO LONGITUDINAL
BASADO EN INTELIGENCIA ARTIFICIAL

para la identificación temprana de riesgo de abandono asistencial y deterioro clínico en programas de riesgo cardiovascular
Jair de Jesús Díaz Lora | Investigador independiente en analítica de datos aplicada en salud
Barranquilla, Colombia • NanoporeDay Colombia 2026 • Bogotá, 27 de agosto de 2026
PUBLICACIÓN CIENTÍFICA • Revista Hambatu Science 1(2), 66–80 • DOI 10.63862/rhs-v1n2-66-80-2026

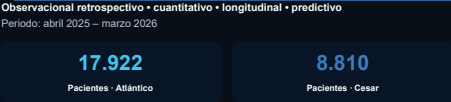


CONTEXTO Y OBJETIVO

Los programas de riesgo cardiovascular concentran información clínica, operativa y longitudinal. El reto es convertir esa información fragmentada en señales útiles para anticipar pérdida de continuidad, abandono asistencial y deterioro clínico.
OBJETIVO
Desarrollar y evaluar un modelo analítico longitudinal basado en Machine Learning para identificar patrones asociados con riesgo de abandono asistencial y deterioro clínico, integrando información clínica, operativa y longitudinal.

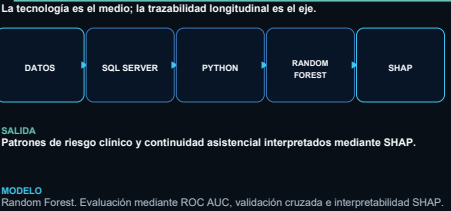
PREGUNTA DE INVESTIGACIÓN
¿Puede la integración longitudinal de datos clínicos y operativos aportar señales útiles para priorización del riesgo?

DISEÑO Y POBLACIÓN




VARIABLES CENTRALES
Clínicas: HTA, HbA1c, creatinina, TFG, ERC. Operativas/longitudinales: continuidad, días sin atención, frecuencia, adherencia, recencia y cohortes.


ARQUITECTURA ANALÍTICA



RESULTADOS: DOS REALIDADES REGIONALES



DESEMPEÑO PREDICTIVO



PRÓXIMO PASO
Validación externa • métricas complementarias • nuevas variables

INTERPRETABILIDAD SHAP




Figura original del artículo publicado. Elaboración propia mediante Random Forest y SHAP.
Lectura: la edad y el control de HTA concentran las interacciones mostradas.

HALLAZGO METODOLÓGICO CRÍTICO
TRAZABILIDAD ≠ CLASIFICACIÓN

Se identificaron pacientes clasificados como "incidentes" que previamente presentaban trazabilidad clínica y operativa dentro del sistema analizado.
IMPLICACIÓN
Antes de aumentar la complejidad del modelo, es necesario fortalecer integración, depuración y caracterización longitudinal de cohortes.

¿QUÉ APORTA EL MODELO?

- INTEGRA información clínica + operativa + longitudinal
IDENTIFICA patrones de continuidad y comportamiento poblacional
INTERPRET/aporte relativo de variables mediante SHAP
PRIORIZA seguimiento poblacional y gestión basada en riesgo
DATOS -> PATRONES -> RIESGO -> PRIORIZACIÓN

IMPACTO, LÍMITES Y ESCALABILIDAD

IMPACTO ACTUAL
Apoyo a la identificación de patrones y priorización del seguimiento poblacional.
NO DEMOSTRADO
No se ha demostrado reducción de hospitalizaciones, ahorro económico ni impacto clínico causal. Requieren estudios de implementación.
LIMITACIONES
Datos institucionales retrospectivos; inconsistencias poblacionales; subregistro; variabilidad regional; ausencia de validación externa multicéntrica.
ESCALABILIDAD
Potencial condicionada por calidad de datos, interoperabilidad, nuevas variables y validación externa.

CONCLUSIONES Y SIGUIENTE FRONTERA

- 1 La analítica longitudinal identificó patrones relevantes asociados con abandono, deterioro y progresión del riesgo.
2 La calidad, integración y trazabilidad condicionan la caracterización poblacional y la continuidad del seguimiento.
3 Continuidad asistencial y adherencia presentaron impacto relevante en la identificación del riesgo.
4 Machine Learning + interpretabilidad son herramientas complementarias para fortalecer la gestión del riesgo.
SIGUIENTE FRONTERA
• Progresión renal
• Deterioro metabólico
• Riesgo cardiovascular acumulado

REFERENCIAS ESENCIALES

Díaz Lora, J. de J. (2026). Modelo analítico longitudinal... Revista Hambatu Science, 1(2), 66–80. DOI 10.63862/rhs-v1n2-66-80-2026.
Breiman, L. (2001). Random Forests. Machine Learning.
Lundberg, S. M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions.
Collins, G. S., et al. (2015). TRIPOD: transparent reporting of a multivariable prediction model.

