

Predictive Models of Neonatal and Postneonatal Mortality Based on Machine Learning in Honduras

Salvador Diaz¹; Gustavo Galo²; Waldina Urrutia³; Alicia Diaz⁴; Olman Gradis⁵
Flora Lopez⁶; Selvin Reyes⁷

^{1,2,3}Facultad de Ciencias Médicas, Universidad Nacional Autónoma de Honduras, Honduras, sedicacdo@hotmail.com,
gustavo.galo@unah.edu.hn, waldina.urrutia@unah.edu.hn

^{4,5}Facultad de Ciencias Médicas, Universidad Católica de Honduras Nuestra Señora Reina de la Paz, Honduras,
a.sofiadiatz2002@gmail.com, odgradis_soj@unicah.edu

⁶Secretaría de Salud, Honduras, krislop494@gmail.com

⁷Instituto de Investigación en Ciencias Médicas y Derecho a la Salud, Universidad Nacional Autónoma de Honduras, Honduras,
selvin.reyes@unah.edu.hn

Abstract– Child mortality remains a critical public health indicator in low- and middle-income countries, and risk stratification using machine learning represents a promising approach to target targeted interventions. This study aimed to develop and validate predictive models for neonatal (0–27 days) and postneonatal (28–364 days) mortality in Honduras, and to identify their main determinants using interpretability methods. A retrospective cohort study was conducted with data from ENDESA/MICS 2019, comparing three classification models (logistic regression, Random Forest and Gradient Boosting). Performance was assessed with AUC-ROC, AUC-PR, and Brier score, and interpretability was addressed using SHAP values. Among 9,579 live births, neonatal mortality was 14.2 per 1,000 and postneonatal mortality was 8.6 per 1,000. Gradient Boosting showed the best calibration (Brier=0.029 for neonatal; 0.019 for postneonatal). The most influential determinants of neonatal mortality were parity, wealth quintile and access to improved water; for post-neonatal mortality, the wealth quintile, parity and rural residence stood out. In conclusion, machine learning models interpretable using SHAP allow the identification of differential risk profiles for neonatal and postneonatal mortality, supporting the prioritization of maternal and child health interventions.

Keywords– Machine learning, MICS, neonatal mortality, postneonatal mortality, SHAP.

Modelos Predictivos de Mortalidad Neonatal y Posneonatal Basados en Aprendizaje Automático en Honduras

Salvador Diaz¹; Gustavo Galo²; Waldina Urrutia³; Alicia Diaz⁴; Olman Gradis⁵;
Flora Lopez⁶; Selvin Reyes⁷

^{1,2,3}Facultad de Ciencias Médicas, Universidad Nacional Autónoma de Honduras, Honduras, sedicacdo@hotmail.com,
gustavo.galo@unah.edu.hn, waldina.urrutia@unah.edu.hn

^{4,5}Facultad de Ciencias Médicas, Universidad Católica de Honduras Nuestra Señora Reina de la Paz, Honduras,
a.sofiadiatz2002@gmail.com, odgradis_scy@unicah.edu

⁶Secretaría de Salud, Honduras, krislop494@gmail.com

⁷Instituto de Investigación en Ciencias Médicas y Derecho a la Salud, Universidad Nacional Autónoma de Honduras, Honduras,
selvin.reyes@unah.edu.hn

Resumen— La mortalidad infantil continúa siendo un indicador crítico de salud pública en países de ingresos bajos y medios, y la estratificación del riesgo mediante aprendizaje automático representa un enfoque prometedor para orientar intervenciones focalizadas. Este estudio tuvo como objetivo desarrollar y validar modelos predictivos para mortalidad neonatal (0–27 días) y posneonatal (28–364 días) en Honduras, e identificar sus determinantes principales mediante métodos de interpretabilidad. Se realizó un estudio de cohorte retrospectivo con datos de ENDESA/MICS 2019, comparando tres modelos de clasificación (regresión logística, Random Forest y Gradient Boosting). El desempeño se evaluó con AUC-ROC, AUC-PR y la puntuación de Brier, y la interpretabilidad se abordó mediante valores SHAP. Entre 9,579 nacidos vivos, la mortalidad neonatal fue de 14.2 por 1,000 y la posneonatal de 8.6 por 1,000. Gradient Boosting mostró la mejor calibración (Brier=0.029 para neonatal; 0.019 para posneonatal). Los determinantes más influyentes para mortalidad neonatal fueron la paridad, el quintil de riqueza y el acceso a agua mejorada; para mortalidad posneonatal destacaron el quintil de riqueza, la paridad y la residencia rural. En conclusión, los modelos de aprendizaje automático interpretables mediante SHAP permiten identificar perfiles diferenciales de riesgo para mortalidad neonatal y posneonatal, respaldando la priorización de intervenciones en salud materno-infantil.

Palabras clave—MICS, Mortalidad neonatal, mortalidad postneonatal, aprendizaje automático, SHAP.

I. INTRODUCCIÓN

La mortalidad infantil temprana constituye uno de los indicadores más sensibles del desarrollo socioeconómico y del funcionamiento de los sistemas de salud de un país [1]. A nivel mundial, aproximadamente 2.4 millones de niños mueren durante su primer mes de vida cada año, representando el 47% de todas las muertes en menores de cinco años [2]. Honduras, como país de ingresos medios-bajos en Centroamérica, ha logrado avances significativos en la reducción de la mortalidad infantil durante las últimas décadas; sin embargo, las tasas actuales aun superan los promedios regionales y los Objetivos de Desarrollo Sostenible propuestos para 2030 [3].

La distinción entre mortalidad neonatal (defunciones ocurridas entre el nacimiento y los 27 días de vida) y mortalidad posneonatal (defunciones entre los 28 y 364 días) resulta epidemiológica y programáticamente relevante, dado que responden a determinantes distintos. Mientras la mortalidad neonatal se asocia principalmente con factores perinatales como prematuridad, asfixia al nacer, infecciones y anomalías congénitas, la mortalidad posneonatal está más vinculada a factores ambientales, nutricionales e infecciosos como neumonías, diarreas y desnutrición [4]. Esta diferenciación etiológica implica que las estrategias de intervención deben ser específicas para cada periodo.

Los enfoques tradicionales para el análisis de determinantes de mortalidad infantil han empleado predominantemente modelos de regresión logística o modelos de supervivencia, los cuales, aunque informativos para inferencia causal, presentan limitaciones para la predicción del riesgo individual y la identificación de interacciones complejas entre variables [5]. En este contexto, las técnicas de aprendizaje automático (machine learning) ofrecen ventajas potenciales al capturar relaciones no lineales y efectos de interacción sin especificación previa, lo cual puede mejorar la capacidad predictiva y revelar patrones de riesgo no detectados por métodos convencionales [6].

No obstante, una crítica frecuente a los modelos de aprendizaje automático es su naturaleza de caja negra, que dificulta la interpretación de los mecanismos subyacentes a las predicciones [7]. Los métodos de interpretabilidad como SHAP (SHapley Additive exPlanations), basados en teoría de juegos cooperativos, permiten cuantificar la contribución de cada variable a las predicciones individuales, proporcionando explicaciones consistentes y localmente fieles [8]. Esta combinación de capacidad predictiva e interpretabilidad resulta particularmente valiosa para informar políticas de salud pública, donde es necesario no solo identificar poblaciones en riesgo sino también comprender los factores modificables que impulsan dicho riesgo.

El presente estudio tiene como objetivos: (i) desarrollar y validar modelos predictivos de aprendizaje automático para mortalidad neonatal y posneonatal utilizando datos representativos a nivel nacional de Honduras; (ii) comparar el desempeño de diferentes algoritmos en términos de discriminación y calibración; (iii) identificar y contrastar los determinantes principales de cada tipo de mortalidad mediante análisis SHAP; y (iv) generar perfiles de riesgo interpretables que puedan orientar intervenciones focalizadas en salud materno-infantil.

II. MATERIALES Y MÉTODOS

A. Fuente de Datos, Diseño y Población de Estudio

Se recurrió a datos provenientes de la Encuesta Nacional de Demografía y Salud con Indicadores Múltiples (ENDESA/MICS) Honduras 2019, llevada a cabo por el Instituto Nacional de Estadística (INE) con asistencia técnica de UNICEF [8], [9]. La encuesta utiliza un diseño muestral estratificado a través de conglomerados en dos fases, representativo a escala nacional, urbano/rural y departamental, con un total de 24,643 hogares y una tasa de respuesta del 98,2%. Se diseñó una cohorte retrospectiva que abarca todos los nacimientos reportados por mujeres de 15 a 49 años. Con el objetivo de mitigar el sesgo de recuerdo y garantizar relevancia temporal, el análisis se limitó a los nacimientos acontecidos en los cinco años previos a la encuesta (2014-2019), constituyendo una cohorte de 9,579 nacidos vivos.

B. Desenlaces y Covariables

Se establecieron dos desenlaces binarios: mortalidad neonatal, definida como la defunción entre el nacimiento y los 27 días completos, y mortalidad posneonatal, que se refiere a la defunción entre 28 y 364 días. La edad al deceso fue documentada en días para las defunciones del primer mes, en meses para el resto del primer año y en años para las edades posteriores, lo que facilitó una clasificación precisa.

Las covariables fueron seleccionadas basándose en el marco de Mosley y Chen [10] e incorporaron atributos maternos (edad, paridad), del niño (género, gemelaridad), factores socioeconómicos (quintil de riqueza, área de residencia), acceso a servicios (control prenatal, parto institucional) y condiciones domésticas (agua mejorada, saneamiento mejorado). El índice de riqueza fue elaborado a través del análisis de elementos fundamentales de activos domésticos (como electricidad, televisión, refrigerador, vehículo, computadora, teléfono móvil, internet y cuenta bancaria) y se categorizó en quintiles.

C. Modelado Predictivo, Validación, Interpretabilidad y Ética

Se realizaron comparaciones entre tres modelos de clasificación: la regresión logística con regularización L2, el Foresta Aleatoria (100 árboles; profundidad máxima=5) y el Boosting Gradient (100 estimadores; profundidad máxima=2).

Para tratar la problemática del desequilibrio de clases, se utilizaron pesos de clase equilibrados y se implementó la técnica SMOTE durante el proceso de entrenamiento [11]. Los datos fueron segmentados en entrenamiento (75%) y prueba (25%) con estratificación por desenlace; el rendimiento discriminante se evaluó mediante AUC-ROC y AUC-PR, y la calibración se realizó mediante la puntuación de Brier (valores cercanos a cero señalan una calibración superior) [12], documentando las métricas en el conjunto de pruebas realizadas.

La interpretación se determinó a través de valores SHAP utilizando Tree-Explainer [8], cuantificando la contribución marginal de cada variable a nivel global y local. Posteriormente, se elaboraron gráficos de resumen SHAP para ilustrar la magnitud y la dirección de los efectos. En última instancia, se emplearon datos secundarios de acceso público anonimizados; el protocolo ENDESA/MICS 2019 fue aprobado por el correspondiente comité de ética y contó con consentimiento informado, por lo que este análisis secundario no requirió aprobación adicional conforme a la normativa vigente.

D. Análisis Estadístico y Software

La manipulación y procesamiento de datos se llevaron a cabo en Python versión 3.11, empleando las bibliotecas pandas (v2.0) y NumPy (v1.24) para la manipulación de los datos. El índice de riqueza residencial fue elaborado a través del Análisis de Componentes Principales (PCA) a partir de ocho activos domésticos, extrayendo el primer componente que representó el 49% de la varianza total, y posteriormente categorizado en quintiles. El software Scikit-Learn (v1.3) fue utilizado para el modelado predictivo, implementando tres algoritmos de aprendizaje automático: Logística de regresión con regularización L2, Foresta aleatoria con 100 árboles y profundidad máxima de 5, y Optimización Gradient con 100 estimadores y profundidad máxima de 3. Como consecuencia del desequilibrio de clases intrínseco a la baja prevalencia de los desenlaces, se implementó la técnica de sobre muestreo sintético SMOTE (Synthetic Minority Over-sampling Technique) exclusivamente en el conjunto de entrenamiento [13]-[19].

La segmentación de los datos se realizó siguiendo un esquema que asignaba un 75% al entrenamiento y un 25% a la prueba con estratificación para el desenlace. La evaluación del rendimiento discriminante se realizó a través de las curvas ROC (Receiver Operating Characteristic) y el área bajo la curva (AUC-ROC), mientras que la calibración fue evaluada mediante la puntuación de Brier. Se alcanzó la interpretación de los modelos a través de los valores SHAP (SHapley Additive exPlanations), que cuantifican la contribución marginal de cada variable a las predicciones individuales. Las representaciones visuales fueron producidas utilizando matplotlib (v3.7) y la biblioteca SHAP (v0.42). El valor de significancia estadística para las comparaciones descriptivas fue de $p < 0.05$ [8], [20].

III. RESULTADOS

A. Descripción de la muestra

La cohorte analizada comprendió 9,579 nacidos vivos durante el periodo comprendido entre 2014 y 2019. Se documentaron 136 fallecimientos neonatales, con una tasa de mortalidad neonatal de 14.2 por cada 1,000 nacidos vivos, y 82 fallecimientos posneonatales, con una tasa de mortalidad posneonatal de 8.6 por cada 1,000 nacidos vivos. La tasa combinada de mortalidad infantil (primer año de vida) fue de 22.8 por cada 1,000 nacidos vivos.

La Tabla I expone las características de la muestra. El promedio de edad materna fue de 28.4 años (DE: 7.3) y la paridad media fue de 2.8 hijos. La mayoría de los nacimientos tuvieron lugar en zonas rurales. El 94.8% y el 89.4% de los partos fueron institucionalizados. La disponibilidad de agua mejorada alcanzó el 55.5% y la disponibilidad de saneamiento mejorado alcanzó el 84.1%.

TABLA I
CARACTERÍSTICAS DE LA MUESTRA DE NACIDOS VIVOS, HONDURAS
2014-2019

Característica	n / Media	% / DE
Total de nacidos vivos	9,579	100.0
Muertes neonatales	136	14.2 por mil
Muertes posneonatales	82	8.6 por mil
Edad materna (años)	28.4	7.3
Paridad	2.8	1.9
Sexo masculino	4,878	50.9
Gemelaridad	147	1.5
Area rural	6,222	65.0
Control prenatal	4,391	94.8
Parto institucional	4,140	89.4
Agua mejorada	5,312	55.5
Saneamiento mejorado	8,054	84.1

Nota: DE: Desviación estándar

B. Mortalidad por Subgrupos

Se encontraron diferencias importantes en las tasas de mortalidad según el área de residencia y el nivel socioeconómico. La tasa de mortalidad neonatal fue mayor en áreas rurales (15.3 por 1,000) que en áreas urbanas (12.2 por 1,000). Según el quintil de riqueza, la tasa de mortalidad neonatal varía desde 8.8 por 1,000 en el quintil más rico hasta 18.2 por 1,000 en el segundo quintil más pobre. La mortalidad posneonatal siguió un patrón similar, con las tasas más altas en los hogares del tercer quintil (13.5 por 1,000) y las más bajas en el segundo (5.2 por 1,000).

C. Desempeño de los Modelos Predictivos

La Tabla II expone la comparativa del rendimiento de los tres modelos para ambos desenlaces. Para la mortalidad neonatal, la Regresión Logística registró la AUC-ROC más alta (0.537), mientras que Gradient Boosting logró la calibración más alta (Brier: 0.029). En el caso de la mortalidad posneonatal, el modelo Gradient Boosting sobrepasó a los

otros modelos tanto en términos de discriminación (AUC-ROC: 0.730) como en calibración (Brier: 0.019).

TABLA II
DESEMPEÑO DE LOS MODELOS PREDICTIVOS EN EL CONJUNTO DE PRUEBA

Desenlace	Modelo	AUC-ROC	AUC-PR	Brier
Neonatal	Regresión Logística	0.537	0.019	0.220
	Random Forest	0.415	0.010	0.127
	Gradient Boosting	0.466	0.011	0.029
Posneonatal	Regresión Logística	0.601	0.009	0.224
	Random Forest	0.690	0.019	0.123
	Gradient Boosting	0.730	0.016	0.019

Nota: AUC-ROC: Area bajo la curva ROC; AUC-PR: Area bajo la curva Precisión-Recall; Brier: Puntuación de Brier (menor es mejor)

La Fig. 1 ilustra las curvas ROC correspondientes a los dos desenlaces. Se constata que los modelos consiguieron una discriminación más eficaz para la mortalidad posneonatal en comparación con la neonatal, lo que sugiere que las variables disponibles capturan de manera más eficaz los determinantes de la mortalidad tardía del primer año.




Fig. 1 Curvas ROC de mortalidad prenatal y postnatal.

D. Determinantes Identificados Mediante SHAP

El análisis SHAP del modelo Gradient Boosting identificó patrones diferenciales de determinantes entre la mortalidad neonatal y posneonatal, tal como se ilustra en la Fig. 2. Las variables más determinantes en la mortalidad neonatal fueron la paridad (con una importancia SHAP de 0.951), seguida del quintil de riqueza (0.793) y el acceso a agua mejorada (0.301). En el estudio de la mortalidad posneonatal, el quintil de riqueza se destacó como el factor determinante preponderante (importancia SHAP: 1.069), seguido de la paridad (0.822) y la zona rural (0.355).




Fig. 2 Variables consideradas junto a sus valores de importancia SHAP.

Un descubrimiento significativo es la distinción relativa entre la relevancia del control prenatal y el parto institucional entre ambos desenlaces. Aunque estas variables de atención sanitaria exhibieron una relevancia moderada para la mortalidad neonatal (0.028 y 0.126 respectivamente), su aportación fue menor para la mortalidad posneonatal (0.025 y 0.066), en la que predominan los factores socioeconómicos y ambientales.

La Fig. 3 ilustra el diagrama beeswarm de SHAP correspondiente al modelo de mortalidad neonatal, en el que

los valores SHAP positivos señalan una contribución más significativa al riesgo preestablecido, mientras que los valores negativos representan un efecto protector. La paridad se reconoce como el determinante más determinante, exhibiendo un gradiente coherente: los valores elevados (puntos en tonalidades rojas) se desplazan hacia SHAP positivos, mientras que las paridades bajas (puntos en tonalidades azules) se concentran en valores negativos. El quintil de riqueza emerge como el segundo predictor de relevancia, exhibiendo una correlación inversa con un gradiente socioeconómico: los niveles más elevados se correlacionan con contribuciones SHAP negativas, mientras que los niveles más bajos con contribuciones SHAP menos favorables. En una escala más reducida, variables relacionadas con el entorno residencial (agua y saneamiento mejorados) y el contexto (área rural) proporcionan datos complementarios, con una tendencia a incrementar el riesgo en situaciones de vulnerabilidad. La gemelaridad exhibe un impacto menos común pero significativo, evidenciado por un subconjunto con valores SHAP claramente positivos, lo que sugiere un incremento significativo del riesgo neonatal en nacimientos múltiples.




Fig. 3 Resumen SHAP del modelo predictivo de mortalidad neonatal (0–27 días).

El resumen SHAP correspondiente al modelo de mortalidad posneonatal se presenta en la Fig. 4. Durante este intervalo temporal, el quintil de riqueza emerge como el predictor preponderante y manifiesta la mayor diversidad de valores SHAP, lo que indica que el gradiente socioeconómico explica una proporción significativa de la variación del riesgo. Los niveles más elevados se agrupan en valores SHAP negativos, mientras que los niveles inferiores se vinculan con contribuciones menos protectoras. La paridad se sitúa en la segunda posición, manteniendo un patrón de aumento del riesgo con valores elevados. La residencia rural se manifiesta como el tercer factor determinante esencial, evidenciando un desplazamiento neto hacia valores SHAP positivos, lo que indica un efecto territorial autónomo durante el periodo posnatal. Las variables asociadas con las condiciones

domésticas y el acceso a servicios (agua y saneamiento mejorados, parto institucional y control prenatal) aportan, aunque de manera menor, pero de manera consistente, lo que sugiere que las discrepancias estructurales y de acceso persisten en la modulación del riesgo más allá del periodo neonatal.




Fig. 4 Resumen SHAP del modelo predictivo de mortalidad posneonatal (28–364 días).

IV. DISCUSIÓN

La presente investigación elaboró y contrastó modelos de aprendizaje automático para la predicción de la mortalidad neonatal y posneonatal en Honduras, empleando datos representativos a nivel nacional de ENDESA/MICS 2019. Los hallazgos evidencian que las técnicas de aprendizaje automático, en particular el Gradient Boosting, tienen la capacidad de alcanzar una calibración apropiada incluso en eventos excepcionales, y que el análisis SHAP facilita la identificación de determinantes diferenciales entre ambos tipos de mortalidad.

Las tasas observadas de mortalidad (neonatal: 14.2 por 1,000; posneonatal: 8.6 por 1,000) se alinean con estimaciones anteriores para Honduras y evidencian la persistencia de las disparidades en la salud materno-infantil [21]. La mayor proporción de decesos en el periodo neonatal en comparación con el posneonatal (62% contra 38% de la mortalidad infantil) se alinea con tendencias epidemiológicas globales que evidencian un incremento en la concentración de la mortalidad infantil durante las primeras semanas de vida conforme se controlan las causas posneonatales a través de la inmunización, la rehidratación oral y las mejoras en el saneamiento [22].

El rendimiento discriminatorio moderado de los modelos, particularmente en relación con la mortalidad neonatal (AUC-ROC < 0.60), requiere consideración. Este resultado puede ser atribuido a múltiples factores. Inicialmente, la reducida prevalencia del desenlace (1.3% en neonatal y 0.75% en posneonatal) obstaculiza intrínsecamente la discriminación en la clasificación binaria. En segundo lugar, las variables

presentes en las encuestas poblacionales no incorporan factores clínicos proximales tales como el peso al nacer exacto, la edad gestacional o las complicaciones del parto, que representan predictores robustos de la mortalidad neonatal. En tercer lugar, la mortalidad neonatal posee un componente estocástico significativo vinculado a eventos perinatales agudos que resultan desafiantes de prever con datos recolectados retrospectivamente [23].

Esta restricción exige delimitar con precisión el nivel de aplicación apropiado de los modelos desarrollados. La ausencia de variables clínicas proximales peso al nacer, edad gestacional, complicaciones intrapartos o estado asfíctico impide su uso como herramientas de predicción individualizada en el entorno clínico y los excluye de la función de apoyo a la decisión en el punto de atención. Sin embargo, esto no reduce los modelos a un ejercicio puramente descriptivo de factores socioeconómicos. Los modelos de aprendizaje automático construidos sobre datos poblacionales de encuesta tienen una función diferenciada y complementaria: identifican qué características del hogar, del territorio y del perfil socioeconómico concentran el riesgo de mortalidad infantil, permitiendo priorizar intervenciones preventivas en las subpoblaciones y áreas geográficas de mayor vulnerabilidad [24], [25]. En este marco, la utilidad práctica de los modelos reside en orientar la planificación sanitaria focalización geográfica de programas materno-infantiles, despliegue de agentes comunitarios de salud y priorización de protección social, antes que en guiar decisiones clínicas individuales. Un sistema predictivo integral para la supervivencia neonatal requeriría integrar estos determinantes distales y modificables con datos clínicos perinatales disponibles al nacimiento; el presente trabajo aporta el componente poblacional y ascendente de ese sistema.

Sin embargo, la discriminación más favorable para la mortalidad posneonatal (AUC-ROC hasta 0.73) sugiere que los determinantes socioeconómicos y ambientales presentes en la encuesta poseen mayor relevancia para este hallazgo, lo cual es epidemiológicamente plausible, dado que la mortalidad posneonatal se encuentra más asociada a condiciones de vida modificables como la alimentación, el saneamiento y el acceso inmediato a servicios sanitarios [26].

El análisis SHAP identificó patrones que se alinean con la literatura existente. La relevancia de la paridad en la mortalidad neonatal se evidencia en el conocido efecto de J de la paridad sobre la mortalidad infantil, donde las primíparas y las grandes múltiparas presentan un mayor riesgo [27]. La relevancia del quintil de riqueza en ambos desenlaces, particularmente en relación con la mortalidad posneonatal, corrobora la persistencia de las inequidades socioeconómicas en la supervivencia infantil hondureña [28]. La incidencia más significativa del entorno rural en la mortalidad posneonatal puede estar vinculada con obstáculos en el acceso a servicios de salud para la atención de enfermedades predominantes durante la niñez.

Los hallazgos indican que las tácticas para disminuir la mortalidad neonatal deben orientarse hacia la mejora de la

calidad de la atención perinatal, especialmente en hogares de alta paridad y bajo nivel socioeconómico. En lo que respecta a la mortalidad posneonatal, las intervenciones deben otorgar prioridad a la reducción de las inequidades socioeconómicas, mejoras en los sistemas de agua y saneamiento, así como al fortalecimiento del acceso a servicios de salud en regiones rurales.

Este estudio posee diversas ventajas, entre las que se incluyen la utilización de datos representativos a escala nacional, la comparación sistemática de múltiples algoritmos y la implementación de métodos de interpretación de última generación. Entre sus limitaciones, el diseño retrospectivo basado en el reporte materno puede inducir sesgo de recuerdo, con mayor impacto en defunciones ocurridas en fechas próximas a la entrevista. La ausencia de indicadores clínicos detallados en particular el peso al nacer y la edad gestacional restringe la capacidad discriminativa individual, lo que es consistente con el alcance poblacional de este tipo de fuente de datos. El análisis no integró explícitamente el diseño muestral complejo en el entrenamiento de modelos, a pesar de que las tasas poblacionales se calcularon de manera precisa.

V. CONCLUSIÓN

Los modelos de aprendizaje automático con SHAP son útiles para caracterizar los factores que influyen en la mortalidad neonatal y posneonatal en Honduras. La capacidad discriminativa se vio limitada por la naturaleza de los datos de encuesta, pero los modelos encontraron patrones de riesgo consistentes con el conocimiento epidemiológico. En la comparación entre algoritmos, el Gradient Boosting mostró la mejor calibración para ambos desenlaces puntuación de Brier de 0.029 para mortalidad neonatal y de 0.019 para posneonatal así como la mayor capacidad discriminativa para la mortalidad posneonatal (AUC-ROC: 0.730), lo que respalda su selección preferente para la estratificación del riesgo en contextos con baja prevalencia del desenlace. La igualdad y el nivel socioeconómico fueron más importantes que los factores ambientales y de acceso a servicios para la mortalidad neonatal, pero no para la posneonatal. Estos resultados pueden orientar las intervenciones maternoinfantiles de acuerdo con el momento de riesgo y las características poblacionales. Estudios futuros deben incorporar variables clínicas perinatales y validar modelos en cohortes prospectivas para mejorar su capacidad predictiva.

AGRADECIMIENTO

Los autores agradecen al Instituto Nacional de Estadística (INE) de Honduras por poner a disposición pública los datos de ENDESA/MICS 2019, y a UNICEF por el apoyo técnico en la recolección y documentación de la encuesta. De la misma forma, agradecemos el apoyo recibido del Instituto de Investigación en Ciencias Médicas y Derecho a la Salud (ICIMEDES) de la Facultad de Ciencias Médicas (FCM) y la

Dirección de Investigaciones Científicas, Humanísticas y Tecnológicas (DICIHT) todas ellas de la Universidad Nacional Autónoma de Honduras (UNAH). Los autores agradecen al Profesor Isaac Zablah y Profesor Marcio Madrid por su experta orientación metodológica y técnica, en múltiples aspectos de este trabajo.

REFERENCIAS

- [1] L. Liu, S. Oza, D. Hogan, J. Perin, I. Rudan, J. E. Lawn, S. Cousens, C. Mathers, y R. E. Black, "Global, regional, and national causes of child mortality in 2000-13, with projections to inform post-2015 priorities: An updated systematic analysis", *The Lancet*, vol. 385, no. 9966, pp. 430-440, 2015. doi: 10.1016/S0140-6736(14)61698-6
- [2] UNICEF, "Levels and Trends in Child Mortality: Report 2023", United Nations Inter-Agency Group for Child Mortality Estimation, New York, 2023. [Online]. Available: <https://data.unicef.org/resources/levels-and-trends-in-child-mortality-2023/>
- [3] United Nations, "Transforming our world: The 2030 Agenda for Sustainable Development," A/RES/70/1, 2015. [Online]. Available: https://unctad.org/system/files/official-document/ares70d1_es.pdf
- [4] J. E. Lawn, H. Blencowe, S. Oza, D. You, A. C. Lee, P. Waiswa, M. Lalli, Z. Bhutta, A. J. Barros, P. Christian, C. Mathers, y S. N. Cousens, "Every Newborn: Progress, priorities, and potential beyond survival", *The Lancet*, vol. 384, no. 9938, pp. 189-205, 2014. doi: 10.1016/S0140-6736(14)60496-7
- [5] T. Hastie, R. Tibshirani, y J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd ed. New York: Springer, 2009.
- [6] A. Rajkomar, J. Dean, y I. Kohane, "Machine learning in medicine", *N. Engl. J. Med.*, vol. 380, no. 14, pp. 1347-1358, 2019. doi: 10.1056/NEJMr1814259
- [7] C. Rudin, "Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead", *Nat. Mach. Intell.*, vol. 1, no. 5, pp. 206-215, 2019. doi: 10.1038/s42256-019-0048-x
- [8] S. M. Lundberg and S.-I. Lee, "A unified approach to interpreting model predictions," in *Adv. Neural Inf. Process. Syst.* (NeurIPS), vol. 30, 2017, pp. 4765-4774. [Online]. Available: <https://arxiv.org/abs/1705.07874> (doi: 10.48550/arXiv.1705.07874).
- [9] Instituto Nacional de Estadística (INE), "Encuesta Nacional de Demografía y Salud/Encuesta de Indicadores múltiples por Conglomerados (ENDESA/MICS 2019): Informe Final," INE, Tegucigalpa, Honduras, 2020. [Online]. Available: <https://ine.gob.hn/2020/06/17/informe-endesa-mics-2019/>
- [10] W. H. Mosley y L. C. Chen, "An analytical framework for the study of child survival in developing countries", *Popul. Dev. Rev.*, vol. 10, pp. 25-45, 1984. doi: 10.2307/2807954
- [11] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique", *J. Artif. Intell. Res.*, vol. 16, pp. 321-357, 2002, doi: 10.1613/jair.953.
- [12] G. W. Brier, "Verification of forecasts expressed in terms of probability," *Mon. Weather Rev.*, vol. 78, no. 1, pp. 1-3, 1950.
- [13] Python Software Foundation, "Python 3.11.0", 2022. [Online]. Available: <https://www.python.org/downloads/release/python-3110>
- [14] W. McKinney, "Data Structures for Statistical Computing in Python", in *Proc. 9th Python Sci. Conf. (SciPy)*, 2010, pp. 56-61, doi: 10.25080/Majora-92bf1922-00a.
- [15] C. R. Harris *et al.*, "Array programming with NumPy", *Nature*, vol. 585, no. 7825, pp. 357-362, 2020, doi: 10.1038/s41586-020-2649-2
- [16] F. Pedregosa *et al.*, "Scikit-learn: Machine Learning in Python", *J. Mach. Learn. Res.*, vol. 12, pp. 2825-2830, 2011
- [17] I. T. Jolliffe, *Principal Component Analysis*, 2nd ed. New York, NY, USA: Springer, 2002, doi: 10.1007/b98835.
- [18] L. Breiman, "Random Forests", *Mach. Learn.*, vol. 45, pp. 5-32, 2001, doi: 10.1023/A:1010933404324.

- [19]J. H. Friedman, "Greedy function approximation: A gradient boosting machine", *Ann. Stat.*, vol. 29, no. 5, pp. 1189–1232, 2001, doi: 10.1214/aos/1013203451.
- [20]E. W. Steyerberg, A. J. Vickers, N. R. Cook, T. Gerds, M. Gonen, N. Obuchowski, M. J. Pencina, and M. W. Kattan, "Assessing the performance of prediction models: A framework for traditional and novel measures," *Epidemiology*, vol. 21, no. 1, pp. 128–138, Jan. 2010, doi: 10.1097/EDE.0b013e3181c30fb2
- [21]GBD 2019 Under-5 Mortality Collaborators, "Global, regional, and national progress towards Sustainable Development Goal 3.2 for neonatal and child health: All-cause and cause-specific mortality findings from the Global Burden of Disease Study 2019", *The Lancet*, vol. 398, no. 10303, pp. 870–905, 2021. doi: 10.1016/S0140-6736(21)01207-1
- [22]L. Hug, M. Alexander, D. You, y L. Alkema, "National, regional, and global levels and trends in neonatal mortality between 1990 and 2017, with scenario-based projections to 2030: A systematic analysis", *Lancet Glob. Health*, vol. 7, no. 6, pp. e710–e720, 2019. doi: 10.1016/S2214-109X(19)30163-9
- [23]Y. A. Aynalem, W. S. Shiferaw, T. Y. Akalu, A. Dargie, H. K. Assefa, and T. D. Habtewold, "The magnitude of neonatal mortality and its predictors in Ethiopia: A systematic review and meta-analysis", *Int. J. Pediatr.*, vol. 2021, Art. no. 7478108, 2021, doi: 10.1155/2021/7478108
- [24]C. Hazlett, A. P. Ramos, and S. Smith, "Better individual-level risk models can improve the targeting and life-saving potential of early-mortality interventions," *Scientific Reports*, vol. 13, art. no. 21706, Dec. 2023, doi: 10.1038/s41598-023-48888-7
- [25]M. Polavarapu, T. N. Barasa, S. Singh, M. M. Orbain, and S. Ibrahim, "An Application of Social Vulnerability Index to Infant Mortality Rates in Ohio Using Geospatial Analysis: A Cross-Sectional Study," *Maternal and Child Health Journal*, vol. 28, pp. 999–1009, 2024, doi: 10.1007/s10995-024-03925-3
- [26]R. E. Black, C. G. Victora, S. P. Walker, Z. A. Bhutta, P. Christian, M. de Onis, M. Ezzati, S. Grantham-McGregor, J. Katz, R. Martorell, y R. Uauy, "Maternal and child undernutrition and overweight in low-income and middle-income countries", *The Lancet*, vol. 382, no. 9890, pp. 427–451, 2013. doi: 10.1016/S0140-6736(13)60937-X
- [27]K. Kozuki, A. C. Lee, M. F. Silveira, C. G. Victora, L. Adair, J. Humphrey, R. Ntozini, R. E. Black, y J. Katz, "The associations of parity and maternal age with small-for-gestational-age, preterm, and neonatal and infant mortality: A meta-analysis", *BMC Public Health*, vol. 13, Suppl 3, art. S2, 2013. doi: 10.1186/1471-2458-13-S3-S2
- [28]A. J. Barros, C. Ronsmans, H. Axelson, E. Loaiza, A. D. Bertoldi, G. V. Franca, J. Bryce, J. T. Boerma, y C. G. Victora, "Equity in maternal, newborn, and child health interventions in Countdown to 2015: A retrospective review of survey data from 54 countries", *The Lancet*, vol. 379, no. 9822, pp. 1225–1233, 2012. doi: 10.1016/S0140-6736(12)60113-5