



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE MEDICINA
DIVISION DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
SECRETARIA DE SALUD

HOSPITAL GENERAL DE MEXICO "DR. EDUARDO LICEAGA"

PREDICCIÓN DE DESENLACES PERINATALES ADVERSOS

EN PARTO PRETÉRMINO MEDIANTE INTELIGENCIA

ARTIFICIAL BASADA EN CARACTERÍSTICAS CLÍNICAS Y

PARAMETROS BIOQUÍMICOS DEL PRIMER TRIMESTRE.

TESIS

Que para obtener el título de Especialista en:

GINECOLOGÍA Y OBSTETRICIA

PRESENTA

Deyanira Baca

Asesores de Tesis:

Dr. Johnatan Torres Torres

Dr. José Alberto Carranco Martínez



DR. EDUARDO LICEAGA

Ciudad de México, Julio 2025



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

DEDICATORIA

A mis padres, Dinora y Jose Alfredo quienes, a pesar de la distancia física, han estado siempre cerca de mi corazón. Su amor, sus enseñanzas y su apoyo incondicional han sido la fuerza que me ha sostenido en los momentos más desafiantes de este camino. Aunque lejos, pero su presencia ha sido constante en cada logro, cada esfuerzo y cada paso hacia la meta.

A mi madre Dinora, por ser mi refugio. Porque incluso lejos, su voz siempre supo encontrarme en mis momentos más difíciles, escuchándome con amor, paciencia. Por darlo todo para que yo pudiera seguir adelante con mi carrera.

A mis hermanos, Yaritzell y Edwin por su compañía discreta pero firme, por compartir conmigo este trayecto con palabras de aliento y cariño.

A mi tía Maria de los Angeles, quien ha sido una segunda madre para mí. Por su amor incondicional, su compañía constante gracias por creer en mí incluso en los momentos en que yo dudaba, por celebrar cada uno de mis logros como si fueran tuyos, y por estar presente en cada paso.

A mi abuelita Rosa y a mi hermana Khloe, quien desde el cielo han sido mi luz en los días más oscuros. Su amor, estuvo presente en cada paso que doy y que apesar de su ausencia física se que nunca me dejaron, sola en mi sueño de ser profesionista.

Gracias a ustedes, este logro tiene sentido.

Tabla de Contenido

1.	RESUMEN	5
2.	ANTECEDENTES	6
3.	PLANTEAMIENTO DEL PROBLEMA.	9
4.	JUSTIFICACIÓN	10
5.	HIPOTESIS	11
6.	OBJETIVOS	12
	a. Objetivo general.....	12
	b. Objetivos específicos.....	12
7.	METODOLOGÍA	12
	a. Tipo y diseño de estudio.....	12
	b. Población.....	13
	c. Tamaño de la muestra.....	13
	d. Criterios de inclusión y exclusión.	14
	e. Definición de las variables.....	14
	f. Análisis estadístico	22
8.	RECURSOS NECESARIOS	24
9.	ASPECTOS ÉTICOS Y DE BIOSEGURIDAD	24
10.	RESULTADOS	25
	Características de la población incluida	25
	Desarrollo del modelo predictivo mediante inteligencia artificial.....	27
	Desempeño predictivo del modelo	28
	Evaluación del rendimiento a tasas específicas de falsos positivos	29
	Evaluación de la calibración del modelo.....	29
	Desempeño del modelo en desenlaces secundarios.....	30
11.	DISCUSIÓN	31
	Hallazgos principales	31
	Comparación con la literatura existente.....	31
	Implicaciones clínicas	34
	Implicaciones para la investigación.....	34
	Fortalezas y limitaciones	34
12.	CONCLUSIÓN	35
13.	BIBLIOGRAFIA	35

1. RESUMEN

Introducción: El parto pretérmino (<37 semanas) continúa representando una de las principales causas de morbilidad y mortalidad neonatal a nivel mundial. En México, su prevalencia sigue siendo alta, y la predicción oportuna de este desenlace obstétrico adverso representa un reto clínico importante. Los métodos actuales, basados en factores clínicos aislados, presentan limitaciones importantes en sensibilidad y especificidad. Este trabajo evaluó el uso de inteligencia artificial como herramienta para integrar múltiples variables clínicas y bioquímicas del primer trimestre, con el objetivo de generar un modelo predictivo más preciso para la identificación temprana de embarazos con riesgo de parto pretérmino.

Objetivo: Evaluar la utilidad de una herramienta de detección de riesgo, basada en características clínicas y parámetros bioquímicos del primer trimestre, para identificar a mujeres con mayor probabilidad de presentar parto pretérmino y desenlaces perinatales adversos, mediante el desarrollo y validación de un modelo predictivo con inteligencia artificial.

Metodología: Se realizó un estudio observacional, descriptivo, longitudinal y retrospectivo en el Hospital General de México, en el periodo comprendido de enero de 2020 a febrero de 2025. Se incluyeron 1014 expedientes clínicos, de los cuales 314 correspondieron a pacientes con parto pretérmino y 700 con parto a término. Se recopilaron variables clínicas y bioquímicas del primer trimestre. Se aplicaron pruebas estadísticas bivariadas y multivariadas, y se desarrollaron modelos predictivos utilizando algoritmos de machine learning (regresión LASSO y Random Forest). La capacidad discriminativa del modelo se evaluó mediante el cálculo del área bajo la curva ROC (AUC).

Resultados: El modelo predictivo basado en inteligencia artificial logró una mejora significativa en la capacidad de predicción del parto pretérmino, con un AUC superior al de los métodos clínicos convencionales. Los factores más relevantes identificados fueron la longitud cervical, índice de masa corporal, niveles de colesterol, presencia de infecciones del tracto urinario, hemoglobina y antecedentes obstétricos. La herramienta permitió identificar con mayor precisión a mujeres con riesgo elevado de desenlaces perinatales adversos como ingreso a UCIN, bajo peso al nacer y bajo puntaje Apgar a los 5 minutos.

Conclusiones: La integración de características clínicas y bioquímicas del primer trimestre en un modelo predictivo basado en inteligencia artificial demostró ser una herramienta efectiva para la identificación oportuna del riesgo de parto pretérmino. Su implementación en la práctica clínica podría mejorar significativamente los desenlaces perinatales y optimizar la toma de decisiones en el manejo prenatal de embarazos de alto riesgo. Estos hallazgos respaldan el uso de la inteligencia artificial como apoyo en la medicina perinatal moderna.

2. ANTECEDENTES

El parto pretérmino, es definido por la Organización Mundial de la Salud, como aquel que ocurre antes de completar las 37 semanas de gestación. Dentro del parto pretermino se divide basados en la edad gestacional en prematuros tardíos aquellos que nacen entre las (34-36 semanas), prematuros moderados (32-33 semanas) en donde se estima que el 85% de estos nacimientos corresponden categoría, el 10% son prematuros muy tempranos entre las (28-31 semanas) y el 5% son extremadamente prematuros (menos de 28 semanas). (1)

Es una de las principales complicaciones obstétricas a nivel mundial y constituye una causa significativa de morbilidad y mortalidad neonatal debido a complicaciones asociadas a la prematuridad ya que es el motivo más frecuente de fallecimiento en niños menores de cinco años. Según la Organización Mundial de la Salud (OMS), cada año nacen aproximadamente 15 millones de bebés prematuros, lo que representa más del 10% de los nacimientos globales (1). En México, la incidencia de partos pretérmino se ha mantenido en niveles preocupantes. Estudios recientes indican que la tasa de nacimientos prematuros en el país es de aproximadamente el 7.5% de todos los nacimientos (2). Esta alta incidencia se ha mantenido constante en la última década, sin cambios significativos en las tasas de nacimientos prematuros en ninguna región del mundo.

Existen dos tipos principales de parto prematuro: espontáneo e iatrogénico, siendo el primero responsable de aproximadamente el 70 % de los casos. Los mecanismos que provocan el parto prematuro siguen siendo difíciles de comprender, especialmente en más del 50 % de los casos en los que no se encuentra una causa evidente. (3) En el caso del iatrogénico, puede

ocurrir debido a factores como sufrimiento fetal, desprendimiento de placenta y embarazos múltiples.

Los mecanismos moleculares involucrados aún no se entienden completamente, aunque se cree que están relacionados con un desequilibrio entre las vías antiinflamatorias y proinflamatorias que provocan el inicio del parto. Los factores inflamatorios como las variantes genéticas desempeñan roles cruciales en la predisposición del parto prematuro aunado a sus factores de riesgo, por lo que la prevención del parto prematuro se considera actualmente una prioridad de salud pública. (4)

Por otro lado, se ha planteado que diversos factores de riesgo están vinculados a la ocurrencia de parto pretermino espontaneo. Los factores de riesgo asociados al parto prematuro se dividen principalmente en diversas categorías, que incluyen aspectos demográficos y socioeconómicos, hábitos y estilo de vida, condiciones de salud materna y enfermedades crónicas. Además, se consideran las características del embarazo y del feto, los antecedentes reproductivos y factores genéticos, así como ciertos aspectos biológicos y otros elementos que pueden influir en la gestación (5).

La categoría demográfica y socioeconómica incluye factores como la edad materna específicamente dentro de esta categoría se hace énfasis en menores de 20 años o mayor de 35 años, la raza o etnia, el nivel educativo, el estado civil y la condición socioeconómica desfavorable, un bajo nivel educativo materno. Así mismo las características conductuales incluyen estilo de vida como el consumo de alcohol, tabaco y drogas, así como el estrés psicológico y social. Diversos estudios demuestran que la categoría de salud materna es de los principales factores de riesgo determinantes en la aparición del parto prematuro englobando índice de masa corporal, diabetes, hipertensión, anemia, asma y enfermedades tiroideas. (5) Sin dejar a un lado la historia clínica obstétrica con antecedentes de parto pretermino, procedimientos cervicales, jugando parte fundamental en el desenlace de parto prematuro.

En el 2024 se realizó un estudio retrospectivo en donde se indica que la dislipidemia durante el primer trimestre del embarazo, caracterizada por concentraciones altas de apolipoproteínas

A y B, colesterol total y triglicéridos, está vinculada a un mayor riesgo de parto prematuro. En consecuencia, controlar y regular los niveles de lípidos en el primer trimestre podría ser una estrategia eficaz para disminuir la tasa de partos prematuros (6)

Por último, se consideran otros factores como el uso de ecografías en donde se enfoca en la evaluación de la longitud cervical. El aumento en la cantidad de nacimientos se debe a una compleja interacción de causas, factores de riesgo. Entre las razones más destacadas se encuentra el retraso en la edad materna para quedar embarazada, lo que conlleva un mayor riesgo de complicaciones en el mismo así como un aumento de embarazos múltiples debido al uso de tecnologías de reproducción asistida. Existen múltiples factores de riesgo y desencadenantes asociados al parto prematuro; sin embargo, en muchos casos, la causa sigue siendo desconocida. Por ejemplo, según la Encuesta de Trabajo de Parto y Alumbramiento en China, se encontró que en 187,035 nacimientos prematuros (34.2%), no se identificó ningún factor de riesgo evidente. Por lo que la variabilidad en las causas y la falta de claridad en muchos casos han dificultado los esfuerzos de prevención. (7)

El parto prematuro sigue siendo un problema en salud pública, por lo que el presente estudio busca utilizar tecnología similar al pensamiento lógico humano para crear una herramienta diagnóstica para la detección oportuna de riesgo del parto pretermino. En la actualidad, el uso de la inteligencia artificial en el campo de la medicina busca facilitar la interpretación de pruebas diagnósticas y actividades quitando así una gran carga de trabajo, para el personal de la salud mejorando así la relación médico paciente y agilizar los procesos.

El uso de la inteligencia artificial en medicina ha evolucionado rápidamente en los últimos años, ofreciendo herramientas innovadoras para el diagnóstico, pronóstico y tratamiento personalizado de múltiples condiciones clínicas, mostrando un gran potencial para mejorar los resultados materno-fetales, especialmente en áreas críticas como el parto pretérmino, la preeclampsia, la predicción de complicaciones perinatales y la salud reproductiva

Estudios recientes demostraron que el uso de la inteligencia artificial en la medicina ha sido aplicada en la detección temprana de preeclampsia, anomalías congénitas, restricción del crecimiento intrauterino y complicaciones relacionadas con la fertilidad. Wang lo utilizó en un

estudio para la selección de embriones viables con mayor precisión mediante análisis de imágenes de blastocistos y características morfológicas (8).

Otra área relevante es la predicción de complicaciones en cesáreas, hemorragia postparto y mortalidad materna, mediante el uso de registros clínicos electrónicos y algoritmos supervisados. Asimismo, los sistemas de inteligencia artificial están comenzando a integrarse en aplicaciones móviles y dispositivos de monitoreo fetal remoto, lo que puede ser particularmente útil en regiones con recursos limitados. El parto pretérmino continúa siendo un problema a nivel global por lo que su etiología multifactorial y la complejidad de los factores que lo desencadenan dificultan su predicción con los métodos tradicionales, buscando que la inteligencia artificial nos ayude a integrar diferentes variables clínicas y bioquímicas para así lograr modelos predictivos más precisos.

3. PLANTEAMIENTO DEL PROBLEMA.

Dado el impacto de la prematuridad en los recién nacidos, sus cuidadores y el entorno social, el parto pretermino constituye un desafío relevante para los sistemas de salud. Ya que acorde al Instituto Nacional de Estadística (2018) constituye a un 6.5 a 9% del número total de partos, siendo de 12.5% en centros de referencia. (9) .Siendo una de las principales causas de morbilidad perinatal y representa un reto en la práctica clínica debido a su impacto en la salud neonatal y materna por lo que la predicción de desenlaces perinatales adversos asociados al parto pretérmino sigue siendo un desafío clínico.

Actualmente, existen diversos factores clínicos y parámetros bioquímicos que pueden indicar un mayor riesgo de parto prematuro, pero su aplicación en la práctica diaria es variable y depende de la experiencia del clínico. La integración de estos factores en una herramienta sistematizada podría mejorar la identificación de pacientes en riesgo y permitir la implementación oportuna de intervenciones dirigidas, como el uso de progesterona, el cerclaje cervical o la administración de corticoides para la maduración pulmonar fetal.(10)

Las herramientas convencionales, basadas en factores de riesgo clínico, antecedentes obstétricos y hallazgos ecográficos, presentan limitaciones en sensibilidad y especificidad, lo

que disminuye su capacidad para prevenir de manera efectiva complicaciones neonatales severas. A pesar de los avances en la atención obstétrica, la identificación temprana de mujeres en riesgo de parto pretérmino sigue siendo un desafío. La IA ha emergido como una herramienta prometedora para abordar esta limitación. Su capacidad para integrar múltiples variables clínicas y bioquímicas de forma simultánea y su habilidad para identificar patrones ocultos en grandes volúmenes de datos podrían superar las barreras de los métodos tradicionales. Sin embargo, a pesar de la extensa investigación en este campo, la más reciente revisión Cochrane concluyó que no existen ensayos clínicos que evalúen de manera robusta el uso de sistemas de puntuación de riesgo basados en IA para la prevención del parto prematuro. Esto revela un vacío de conocimiento y una oportunidad para innovar en la predicción temprana del riesgo, optimizando así la implementación de estrategias preventivas (11).

Sin embargo, no está claro en qué medida el uso estructurado de una herramienta de detección de riesgos puede reducir la incidencia de parto prematuro y mejorar los desenlaces perinatales. Por ello, es necesario evaluar si la implementación de una herramienta predictiva, basada en criterios clínicos y de laboratorio del primer trimestre, junto con intervenciones específicas en las pacientes de alto riesgo, puede contribuir a una reducción significativa del parto pretérmino y sus complicaciones asociadas en un entorno clínico real.

4. JUSTIFICACIÓN

A pesar de los avances en medicina materno-fetal, los métodos actuales para identificar embarazos con riesgo de parto pretérmino son insuficientes. La predicción se basa principalmente en factores clínicos como antecedentes obstétricos, edad materna, infecciones o características socioeconómicas, además de herramientas ecográficas como la medición de la longitud cervical. Sin embargo, estos métodos por sí solos presentan baja sensibilidad y especificidad, lo que limita su capacidad para identificar de manera temprana a las pacientes en riesgo (12). Por ello, se requiere de nuevas estrategias que integren múltiples fuentes de información para mejorar la predicción y permitir intervenciones oportunas que reduzcan la incidencia de desenlaces perinatales adversos.

En este contexto, el uso de parámetros bioquímicos del primer trimestre ha cobrado relevancia. Biomarcadores como la proteína A plasmática asociada al embarazo (PAPP-A), la fracción libre de β -hCG, el PIGF y los niveles altos de colesterol han sido estudiados por su asociación con complicaciones obstétricas como preeclampsia, restricción del crecimiento intrauterino y parto prematuro. Aunque estos marcadores han mostrado cierto valor predictivo individual, su utilidad clínica sigue siendo limitada cuando se utilizan de forma aislada (13).

Diversos estudios han evaluado biomarcadores del primer trimestre como predictores de complicaciones obstétricas; sin embargo, su uso clínico sigue siendo limitado debido a la variabilidad de resultados y a la falta de modelos robustos de integración de datos por lo que la inteligencia artificial ha emergido como una solución innovadora para procesar grandes volúmenes de información médica, permitiendo generar modelos predictivos más precisos y personalizados. Especialmente los algoritmos de aprendizaje automático, ofrece una herramienta potente para integrar múltiples variables y reconocer patrones complejos que escapan a los métodos estadísticos convencionales. Esta tecnología, además, permite reducir el sesgo clínico y estandarizar el análisis de variables múltiples en tiempo real. Por lo que el implementar este tipo de modelos predictivos en sistemas de salud con limitaciones estructurales podría representar un cambio significativo en la atención prenatal, al facilitar un abordaje anticipado, equitativo y basado en evidencia.

Por lo tanto, el desarrollo de un modelo predictivo basado en inteligencia artificial, que integre parámetros clínicos y bioquímicos del primer trimestre, podría representar un avance significativo en la identificación temprana de mujeres con riesgo de parto pretérmino. Esta herramienta permitiría una intervención oportuna, mejorando los desenlaces perinatales y disminuyendo la carga en los sistemas de salud. Por ello, este estudio se justifica por su potencial impacto clínico y social, al proponer un modelo predictivo basado en la IA que integra variables clínicas y bioquímicas del primer trimestre, con el fin de prevenir desenlaces adversos en embarazos de alto riesgo por parto pretérmino.

5. HIPOTESIS

El uso de una herramienta de detección de riesgo basada en características clínicas y parámetros bioquímicos del primer trimestre permitirá identificar con mayor precisión a las

mujeres con riesgo de parto prematuro, logrando al menos un 20% de mejora en la capacidad predictiva en comparación con los métodos clínicos convencionales. Esto facilitará la implementación de intervenciones oportunas que contribuyan a reducir su incidencia y a mejorar los desenlaces perinatales.

6. OBJETIVOS

a. Objetivo general.

Evaluar la utilidad de una herramienta de detección de riesgo basada en características clínicas y parámetros bioquímicos del primer trimestre para identificar a mujeres con mayor probabilidad de parto prematuro.

b. Objetivos específicos.

- i. Determinar la asociación entre características clínicas y parámetros bioquímicos del primer trimestre con la ocurrencia de parto prematuro.
- ii. Identificar los factores clínicos y bioquímicos más relevantes para la predicción del parto prematuro en la población estudiada.
- iii. Comparar la capacidad predictiva de la herramienta con los métodos clínicos convencionales, con un aumento del 20% en precisión.
- iv. Comparar los desenlaces perinatales entre las pacientes identificadas con alto riesgo y aquellas sin factores de riesgo mediante la herramienta de detección.

7. METODOLOGÍA

a. Tipo y diseño de estudio

Según la finalidad: descriptivo.

Según la interferencia del investigador: observacional

Según la secuencia temporal: longitudinal

Según el momento de incurrencia de información en relación con el inicio del estudio: retrospectivo

b. Población

Expedientes de pacientes con diagnóstico confirmado de parto pretermino en el Servicio de Ginecología y Obstetricia, Unidad 112, del Hospital General de México “Dr. Eduardo Liceaga” en el periodo comprendido del 2020 al 2025.

c. Tamaño de la muestra

Dado que se trata de un estudio observacional, longitudinal y retrospectivo, se utilizó un enfoque de muestreo dirigido con el propósito de garantizar una proporción equilibrada de casos con y sin parto pretérmino, lo cual permitió un análisis robusto mediante técnicas de machine learning, específicamente redes elásticas. La incidencia de parto pretérmino en la población del Hospital General de México se estima entre el 8 % y el 12 %. En un muestreo completamente aleatorio de 1000 expedientes, se espera identificar aproximadamente entre 100 y 120 casos de parto pretérmino, lo cual podría resultar insuficiente para entrenar un modelo predictivo con alta capacidad de discriminación.

Para optimizar la potencia estadística del modelo y reducir el riesgo de sesgos, se seleccionaron un mínimo de 300 expedientes correspondientes a pacientes con parto pretérmino, complementados con 700 expedientes de pacientes con parto a término. Esta estrategia busca garantizar una adecuada distribución de los eventos, lo cual es fundamental para entrenar y validar el modelo predictivo de forma efectiva. Además, permite evitar el problema de desbalanceo en los datos, una condición que podría comprometer la precisión del algoritmo de machine learning.

El cálculo del tamaño muestral se fundamentó en la necesidad de alcanzar un poder estadístico ($1-\beta$) de al menos 80 % y un nivel de confianza del 95 %. Para ello, se emplearon pruebas de hipótesis bilaterales para identificar diferencias en las variables clínicas y bioquímicas entre los grupos. La selección final de expedientes se realizará asegurando que los registros contengan información completa y de calidad sobre las características clínicas y los parámetros bioquímicos del primer trimestre. En caso de detectar expedientes incompletos o con datos faltantes en variables clave, se procederá a ajustar la muestra para preservar su validez y representatividad en el análisis estadístico.

Finalmente, se emplearán técnicas de imputación para manejar valores faltantes, siempre que el porcentaje de datos ausentes no supere el 5 %. Esto permitirá fortalecer la calidad

del conjunto de datos y evitar pérdidas significativas de información durante el proceso analítico.

d. Criterios de inclusión y exclusión.

Criterios de Inclusión

1. Mujeres con parto prematuro (<37 semanas) o parto a término (≥37 semanas) atendidas en el Servicio de Ginecología y Obstetricia, Unidad 112, del Hospital General de México "Dr. Eduardo Liceaga", entre Enero 2020 y Febrero 2025.
2. Expedientes con datos completos sobre características clínicas y parámetros bioquímicos del primer trimestre.
3. Gestación única, confirmada por ultrasonido en el primer trimestrem realizado dentro de la unidad.
4. Atención prenatal documentada en el hospital desde el primer trimestre.

Criterios de Exclusión

1. Embarazo múltiple (gemelar o mayor).
2. Anomalías congénitas fetales mayores.
3. Patologías maternas graves preexistentes que puedan influir en el desenlace (e.g., enfermedades autoinmunes, insuficiencia renal crónica, cardiopatías descompensadas).
4. Expedientes con datos incompletos sobre las variables estudiadas.
5. Parto prematuro iatrogénico, definido como interrupción médica del embarazo por indicaciones como preeclampsia severa, desprendimiento prematuro de placenta normoinserta (DPPNI) o restricción del crecimiento intrauterino severa.
6. Uso de tratamientos previos para prevención de parto prematuro (cerclaje, progesterona vaginal/intramuscular, pesario cervical) si la indicación no está claramente documentada.

e. Definición de las variables

A continuación, se hace la descripción de las variables con las que se realizó el estudio:

- Variables Independientes: Gestas, antecedente de parto pretermino, raza, peso, indice de masa corporal, nivel socioeconomico, edad gestacional, longitud cervical, leucositos,

hemoglobina, plaquetas, glucosa, urea, creatinina, acido urico, perfil tiroideo, exudado cervicovaginal, urocultivo, hiperlipidemia, hipotiroidismo, hipertension, diabetes gestacional.

- **Variables Dependientes:** resultados perinatales adversos.

Tabla de operacionalización de las variables

Variable	Definición operacional	Tipo de variable	Nivel de Medición
Parto prematuro	Definido como el nacimiento ocurrido antes de las 37 semanas completas de gestación.	Nominal dicotómica	0 = Parto a término (≥ 37 semanas) 1 = Parto prematuro (<37 semanas)
Desenlace perinatal adverso	Se considera positivo cuando el recién nacido presenta al menos uno de los siguientes eventos: ingreso del RN a la UCIN, Neonato grande para la edad gestacional, Neonato pequeño para la edad gestacional, bajo puntaje Apgar (<7 a los 5 minutos)	Nominal dicotómica	0 = Ausente 1 = Presente
Ingreso del RN a la UCIN	Necesidad de hospitalización del recién nacido en una unidad especializada	Cualitativa Nominal	1= Si 2= No

	de cuidados intensivos neonatales inmediatamente después del nacimiento, por cualquier motivo médico		
Neonatos pequeños para la edad gestacional	Neonato con un peso al nacer por debajo del percentil 10 para el sexo y edad gestacional.	Nominal dicotómica	0 = Ausente 1 = Presente
Puntaje Apgar al minuto 1	Valor numérico de 0 a 10 que evalúa la adaptación inmediata del recién nacido, considerando 5 criterios (frecuencia cardíaca, esfuerzo respiratorio, tono muscular, irritabilidad refleja y coloración).	Cuantitativa discreta	Escala ordinal o numérica
Puntaje Apgar al minuto 5	Valor numérico de 0 a 10 que indica la respuesta del	Cuantitativa discreta	Escala ordinal o numérica

	neonato tras intervención o adaptación espontánea durante los primeros 5 minutos de vida.		
Obito	Muerte fetal intrauterina después de las 20 semanas de gestación.	Nominal dicotómica	0 = ausente 1 = presente
Vía de resolución del parto	Se refiere al método mediante el cual finaliza el embarazo. Se clasifica en: parto vaginal espontáneo, parto vaginal instrumentado (fórceps o ventosa) o cesárea.	Cualitativa nominal	1 = parto 2 = cesárea.
Edad materna	Tiempo que ha vivido una persona u otro ser vivo contando desde su nacimiento.	Numérica continua	Años
Índice de Masa Corporal (IMC) al inicio del embarazo	El Índice de Masa Corporal es una medida que calcula la relación entre el peso	Numérica categorizada según los criterios de la OMS.	Bajo peso: IMC menor de 18.5 Peso normal: IMC entre 18.5 y 24.9

	y la altura de una persona, para clasificar el estado nutricional.		Sobrepeso: IMC entre 25 y 29.9 Obesidad Grado I: IMC entre 30 y 34.9 Obesidad Grado II: IMC entre 35 y 39.9 Obesidad Grado III: IMC de 40 o más
Antecedente de parto prematuro	Haber tenido un hijo previo que nació, antes de las 37 semanas completas de gestación.	Nominal dicotómica	0 = Ausente 1 = Presente
Tabaquismo	Es la adicción o dependencia al tabaco, principalmente a la nicotina, durante el embarazo.	Nominal dicotómica	0 = Ausente 1 = Presente
Consumo de alcohol o drogas	Todas las sustancias que, al introducirse al organismo, pueden modificar una o más de sus funciones y generar dependencia	Nominal dicotómica	0 = Ausente 1 = Presente
Historia de enfermedades maternas crónicas	Hipertensión, diabetes, enfermedades autoinmunes,	Nominal dicotómica	0 = Ausente 1 = Presente

	enfermedad renal, cardiopatías		
Historia de infecciones del tracto urinario o vaginal en el embarazo	Grupo heterogéneo de condiciones con etiologías diferentes, que tienen por denominador común la presencia de gérmenes en el tracto urinario, cuando este es habitualmente estéril, asociada a sintomatología clínica variable.	Nominal dicotómica	0 = Ausente 1 = Presente
Número de gestaciones previas.	Número de veces que la paciente se ha embarazado	Numérica categórica.	Unidades
Longitud cervical	Medida del cuello uterino, desde el orificio cervical interno hasta el externo, por ultrasonido en el primer trimestre	Variable numérica	Milímetros (mm)
Presión arterial media	El valor promedio de la presión arterial a lo largo de un ciclo cardíaco completo, incluyendo la sístole	Variable numérica	Milímetros de mercurio (mmHg).

	y la diástole en el primer trimestre		
Leucocitos	Conteo total de glóbulos blancos en sangre periférica, expresado en células por microlitro	Cuantitativa discreta	Conteo total en cél/ μ L
Hemoglobina	Concentración de hemoglobina en sangre, expresada en g/dL. Evalúa la capacidad de transporte de oxígeno.	Cuantitativa continua	g/dL
Plaquetas	Conteo total de plaquetas en sangre, en miles por microlitro	Cuantitativa discreta	mil/ μ L
Colesterol	Concentración total de colesterol en sangre, expresada en mg/dL	Cuantitativa discreta	mg/dL
Triglicéridos	Concentración de triglicéridos en sangre, expresada en mg/dL	Cuantitativa discreta	mg/dL
Glucosa	Nivel de glucosa en sangre en ayuno, expresado en mg/dL.	Cuantitativa discreta	mg/dL

	Refleja el metabolismo de carbohidratos.		
Urea	Concentración de urea en sangre, en mg/dL. Producto de desecho del metabolismo proteico	Cuantitativa continua	mg/dL
Creatinina	Nivel de creatinina en sangre, en mg/dL. Indicador de función renal y filtración glomerular.	Cuantitativa continua	mg/dL
Acido Urico	Concentración sérica de ácido úrico, en mg/dL	Cuantitativa continua	mg/dL
Bilirrubina total	Suma de bilirrubina directa e indirecta, expresada en mg/dL. Evalúa función hepática y hemólisis.	Cuantitativa continua	mg/dL
ALT (Alanina aminotransferasa)	Enzima hepática expresada en U/L	Cuantitativa discreta	U/L
AST (Aspartato aminotransferasa)	Enzima hepática y muscular. Elevada en daño tisular.	Cuantitativa discreta	U/L

Fosfatasa alcalina (FA)			
Gammaglutamil transferasa (GGT)	Enzima asociada a hueso, hígado y placenta.	Cuantitativa discreta	U/L
Deshidrogenasa láctica (LDH)	Enzima presente en diversos tejidos. Elevada en daño celular general. Expresada en U/L.	Cuantitativa discreta	U/L
TSH	Hormona hipofisaria que regula la función tiroidea. Expresada en $\mu\text{UI/mL}$.	Cuantitativa continua	$\mu\text{UI/mL}$
T4 libre	Fracción libre no unida de T4, forma activa disponible. Expresada en ng/dL .	Cuantitativa continua	ng/dL

f. Análisis estadístico

El análisis estadístico fue realizado mediante el software Stata® versión 18.0 (StataCorp, College Station, TX, EE. UU.). Las variables continuas se describieron utilizando la mediana y el intervalo intercuartílico (IQR), dado que no se asumió distribución normal. Para la comparación de estas variables entre los grupos con y sin parto pretérmino se empleó la prueba no paramétrica de Kruskal–Wallis. Las variables categóricas se expresaron como frecuencias absolutas y proporciones, y su asociación con el desenlace se evaluó mediante la

prueba de chi cuadrada de Pearson. Se estableció un valor de $p < 0.05$ como umbral de significancia estadística.

Para la construcción del modelo predictivo de parto pretérmino se utilizó inteligencia artificial a través de una regresión logística penalizada mediante redes elásticas (elastic net), técnica de aprendizaje automático que combina las penalizaciones LASSO (Least Absolute Shrinkage and Selection Operator) y Ridge, lo que permite la selección automática de variables relevantes y reduce el riesgo de sobreajuste. La base de datos fue dividida aleatoriamente en dos subconjuntos de igual tamaño: uno para el entrenamiento ($n = 505$) y otro para la validación interna ($n = 507$), utilizando una semilla aleatoria fija para garantizar la reproducibilidad de los resultados. El modelo fue ajustado mediante validación cruzada de 10 pliegues, evaluando tres valores de penalización ($\alpha = 1.0, 0.75$ y 0.5). Se seleccionó el modelo final con base en el menor error de validación cruzada promedio, el cual correspondió a $\alpha = 1.0$ (modelo tipo LASSO) y un valor óptimo de lambda de 0.01093. A partir de este modelo se generó una probabilidad individual de parto pretérmino para cada paciente.

El desempeño discriminativo del modelo fue evaluado mediante curvas ROC (Receiver Operating Characteristic) y cálculo del área bajo la curva (AUC), tanto en el conjunto de entrenamiento como en el de validación. Se aplicó la prueba de DeLong para comparar la capacidad discriminativa entre ambos conjuntos. Adicionalmente, se calcularon AUC específicas a tasas fijas de falsos positivos (false positive rate, FPR) del 10% y 15%, aplicando métodos no paramétricos con remuestreo bootstrap (1,000 iteraciones). Asimismo, se estimaron métricas de rendimiento, como sensibilidad, especificidad, valor predictivo positivo (VPP), valor predictivo negativo (VPN) y proporción de clasificación correcta, utilizando un punto de corte de probabilidad predicha ≥ 0.5 .

La calibración del modelo se evaluó mediante una curva de calibración con suavizado tipo lowess en la cohorte de validación, que permite visualizar la concordancia entre las probabilidades estimadas y las frecuencias observadas de parto pretérmino. Adicionalmente, se calcularon métricas complementarias: la razón entre eventos observados y esperados (E:O), la calibración in-the-large (CITL) y la pendiente de calibración. Esta estrategia permite

valorar si el modelo tiende a sobrestimar o subestimar el riesgo real, garantizando no solo una adecuada discriminación, sino también una estimación confiable del riesgo individual.

Por último, se exploró la capacidad del modelo predictivo de parto pretérmino para anticipar desenlaces neonatales adversos en la cohorte de validación. Se analizaron los siguientes eventos secundarios: puntaje de Apgar < 7 al minuto 5, Apgar persistentemente bajo (menor de 7 tanto al minuto 1 como al minuto 5), ingreso a unidad de cuidados intensivos neonatales (UCIN) y óbito neonatal. Para cada desenlace se calculó el AUC del modelo a tasas fijas de falsos positivos del 10% y 15%, con el objetivo de valorar su utilidad clínica en la predicción de resultados neonatales graves.

8. RECURSOS NECESARIOS

- Investigador principal: Médico residente a graduarse, análisis de la información y resultados.
- Investigador asociado: Tutor del alumno a graduarse el cual coordina la realización del protocolo de investigación, búsqueda y recopilación de datos, análisis de la información.
- Computadora del autor principal para el vaciamiento de datos con hoja de cálculo de Microsoft Excel® y Software de análisis estadístico SPSS® versión 22.0, con los cuales ya cuenta el investigador.
- Materiales: Material de papelería.
- Financieros: Sin recursos financieros.

9. ASPECTOS ÉTICOS Y DE BIOSEGURIDAD

Para la realización del estudio se utilizó datos reportados en el expediente clínico de las pacientes, por lo que no implica una intervención directa sobre la misma. Dentro de los datos se asignó un número de secuencia (código) a cada expediente con la finalidad de garantizar la protección de datos personales como lo estipula la Ley General de Protección de Datos Personales. La información se utilizó exclusivamente para fines académicos y de investigación. Los registros físicos o informáticos serán custodiados en el archivo de investigación de la Unidad 112 del Hospital General de México "Dr. Eduardo Liceaga". El estudio se realizó dentro de los principios éticos para las investigaciones médicas en seres humanos según la Declaración de Helsinki - Asamblea General, Fortaleza, Brasil 2013, así como al artículo 17 del Reglamento de la Ley General de Salud en Materia de Investigación para la Salud, clasificándolo en la categoría I. Investigación sin riesgo: Son estudios que emplean técnicas y

métodos de investigación documental retrospectivos y aquéllos en los que no se realiza ninguna intervención o modificación intencionada en las variables fisiológicas, psicológicas y sociales de los individuos que participan en el estudio, entre los que se consideran: cuestionarios, entrevistas, revisión de expedientes clínicos y otros, en los que no se le identifique ni se traten aspectos sensitivos de su conducta.

10. RESULTADOS

Características de la población incluida

El estudio incluyó a 1014 embarazadas, de las cuales 314 (30.9%) presentaron parto pretérmino **Tabla 1**. Al comparar las características basales entre las pacientes que cursaron con parto pretérmino y aquellas con parto a término, no se observaron diferencias significativas en la edad materna ni en el número de gestaciones. La mediana de edad fue de 28 años en ambos grupos (IQR: 24–31 años, $p=0.862$), mientras que la mediana del número de gestaciones fue de dos, con un IQR entre una y cuatro gestas, $p=0.908$.

En cuanto a los parámetros hematológicos y bioquímicos, los niveles medianos de leucocitos, hemoglobina, plaquetas, colesterol, triglicéridos, glucosa, urea, creatinina, ácido úrico, bilirrubina total, ALT y AST, GGT, DHL, TSH y T4 libre fueron similares entre ambos grupos, sin alcanzar significancia estadística. Sin embargo, dos variables clínicas destacaron por mostrar diferencias importantes. En primer lugar, la PAM fue significativamente más alta en las mujeres que tuvieron parto pretérmino (84 mmHg, IQR: 78–92) en comparación con las que tuvieron parto a término (80 mmHg, IQR: 73–87), con una $p<0.001$. En segundo lugar, la longitud cervical medida por ultrasonido transvaginal fue notablemente más corta en las pacientes con parto pretérmino, con una mediana de 24.6 mm (IQR: 21.6–28.7), frente a 34.8 mm (IQR: 31.6–38.4) en el grupo a término, diferencia altamente significativa ($p<0.001$).

Se observó un incremento en la frecuencia de parto pretérmino conforme aumentaba el grado de obesidad. Por ejemplo, el 15.6% de las mujeres con obesidad grado III (IMC ≥ 40) presentaron parto pretérmino, mientras que la proporción fue solo del 4.6% en mujeres con IMC bajo (<18.5), esta diferencia fue estadísticamente significativa ($p<0.001$).

De las mujeres con historia previa de parto pretérmino, el 77.8% repitieron el desenlace, frente al 23.2% en aquellas sin dicho antecedente ($p < 0.001$). El tabaquismo durante el embarazo también se relacionó con una mayor frecuencia de parto pretérmino (17.2% vs. 9.3%, $p < 0.001$), al igual que el consumo de alcohol (7.6% vs. 4.1%, $p = 0.021$) y la presencia de infección urinaria durante el embarazo, observada en el 29.6% de los casos con parto pretérmino en comparación con el 17.0% de los partos a término ($p < 0.001$).

Tabla 1. Características de la población incluida

Variable	Término (N=700)	Pretérmino (N=314)	Valor p
Edad	28.0 [24.0-31.0]	28.0 [24.0-31.0]	0.862
Gestas	2.0 [1.0-4.0]	2.0 [1.0-4.0]	0.905
Leucocitos	8.0 [6.6-9.2]	8.2 [6.7-9.4]	0.204
Hemoglobina	12.6 [11.9-13.3]	12.7 [11.9-13.3]	0.752
Plaquetas	277.0 [218.5-336.0]	278.5 [211.0-338.0]	0.849
Colesterol	199.0 [173.0-222.0]	203.0 [175.0-227.0]	0.158
Triglicéridos	195.5 [145.0-248.0]	202.0 [154.0-247.0]	0.515
Glucosa	94.0 [82.0-106.0]	91.5 [80.0-104.0]	0.168
Urea	25.1 [21.6-28.3]	24.9 [21.4-28.3]	0.537
Creatinina	0.8 [0.7-0.9]	0.8 [0.6-0.9]	0.454
Ácido úrico	4.0 [3.4-4.7]	3.9 [3.3-4.7]	0.458
Bilirrubina total	0.8 [0.6-1.0]	0.8 [0.6-1.0]	0.455
ALT	34.0 [20.0-46.0]	32.0 [21.0-46.0]	0.541
AST	34.0 [21.0-47.0]	35.0 [21.0-48.0]	0.418
GGT	29.0 [17.0-40.0]	25.0 [15.0-39.0]	0.155
DHL	184.0 [150.0-219.5]	183.0 [148.0-220.0]	0.861
TSH	1.5 [1.1-1.8]	1.5 [1.2-1.9]	0.671
T4 libre	1.1 [0.9-1.3]	1.1 [0.9-1.3]	0.637
PAM	80.0 [73.0-87.0]	84.0 [78.0-92.0]	0.0001
Longitud cervical	34.8 [31.6-38.4]	24.6 [21.6-28.7]	0.0001
Bajo peso	32 (4.6%)	27 (8.6%)	0.0001
Normopeso	245 (35.0%)	66 (21.0%)	
Sobrepeso	215 (30.7%)	79 (25.2%)	
Obesidad I	104 (14.9%)	58 (18.5%)	
Obesidad II	58 (8.3%)	49 (15.6%)	
Obesidad III	46 (6.6%)	34 (10.8%)	

Antecedente de parto pretérmino	32 (4.6%)	112 (35.7%)	0.0001
Tabaquismo	65 (9.3%)	54 (17.2%)	0.0001
Consumo de alcohol	29 (4.1%)	24 (7.6%)	0.0210
ITU	119 (17.0%)	93 (29.6%)	0.0001
ALT: Alanina aminotransferasa AST: Aspartato Aminotransferasa GGT: Gamma-glutamil transferasa DHL: Deshidrogenasa láctica ITU: Infecciones del tracto urinario			

Desarrollo del modelo predictivo mediante inteligencia artificial

Para la construcción del modelo predictivo de parto pretérmino, se utilizó inteligencia artificial con el enfoque de regresión logística penalizada a través de redes elásticas (elastic net). En el conjunto de entrenamiento (n=505), el modelo final incluyó 11 variables seleccionadas automáticamente, que mostraron peso predictivo significativo. La variable más influyente fue la longitud cervical, cuyo coeficiente estandarizado fue de -2.34 , lo que indica que a menor longitud cervical, mayor es el riesgo de parto pretérmino. Otras variables relevantes incluyeron el antecedente de parto pretérmino (0.55), la presión arterial media (0.48), el conteo de leucocitos (0.24), la presencia de infección urinaria (0.21), el IMC (0.20), y la edad materna, que mostró una relación inversa con el desenlace (-0.15). Adicionalmente, el modelo seleccionó con menor peso al ácido úrico, tabaquismo, colesterol y la enzima AST (**Tabla 2**).

Tabla 2. Variables seleccionadas por el modelo predictivo de parto pretérmino mediante inteligencia artificial en el conjunto de entrenamiento		
Variable seleccionada	Coefficiente estandarizado	Interpretación clínica
Longitud cervical	-2.34	Asociación inversa fuerte: menor longitud cervical aumenta el riesgo
Antecedente de parto pretérmino	0.55	Riesgo aumentado en mujeres con antecedente de parto pretérmino
Presión arterial media	0.48	Mayor presión arterial media se asocia con mayor riesgo
Leucocitos	0.24	Mayor recuento leucocitario predice mayor probabilidad de parto pretérmino
ITU	0.21	ITU durante el embarazo incrementa el riesgo
IMC	0.2	A mayor IMC, mayor probabilidad de parto pretérmino
Edad materna	-0.15	Edad materna ligeramente protectora (relación inversa)
Ácido úrico	0.12	Niveles más altos de ácido úrico se asocian con riesgo aumentado
Tabaquismo	0.06	Tabaquismo durante el embarazo incrementa el riesgo
Colesterol	0.04	Asociación leve entre colesterol total y parto pretérmino
AST	0.03	AST elevada podría estar relacionada con inflamación
ITU: Infecciones del tracto urinario, IMC: Índice de Masa Corporal AST: Aspartato Aminotransferasa		

Desempeño predictivo del modelo

El modelo construido fue evaluado en el conjunto de entrenamiento y posteriormente validado en la mitad restante de la muestra. En el conjunto de entrenamiento, el AUC fue de 0.968 (IC 95%: 0.941–0.978), reflejando una excelente capacidad discriminativa. En el conjunto de validación, la AUC fue igualmente alta, con un valor de 0.937 (IC 95%: 0.928–0.966) (**Figura 1**).

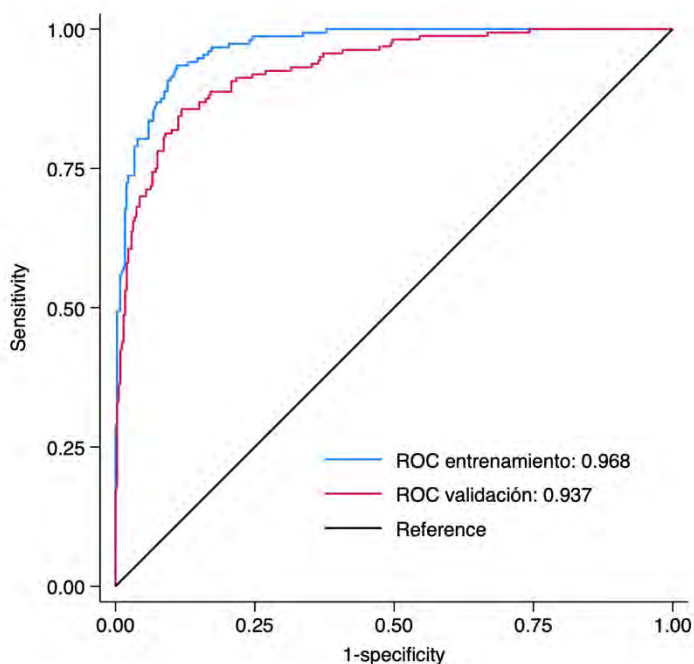


Figura 1. Curvas ROC del modelo predictivo de parto pretérmino. Conjunto de entrenamiento (AUC = 0.968) y conjunto de validación (AUC = 0.937), comparadas con la línea de referencia (diagonal).

En términos de métricas operativas, el modelo mostró una sensibilidad del 77.1% y una especificidad del 94.0% en el conjunto de entrenamiento. El VPP fue de 84.9%, mientras que el VPN alcanzó 90.4%. En el conjunto de validación, los resultados fueron comparables: sensibilidad del 78.0%, especificidad del 94.2%, VPP de 86.1% y VPN de 90.4% (**Tabla 3**).

Tabla 3. Desempeño diagnóstico del modelo predictivo en los conjuntos de entrenamiento y validación (IC95%)		
Métrica	Entrenamiento % (IC95%)	Validación % (IC95%)
Sensibilidad	77.12 (69.65 – 83.52)	77.99 (70.74 – 84.16)
Especificidad	94.03 (91.02 – 96.27)	94.25 (91.26 – 96.45)
Valor predictivo positivo	84.89 (77.84 – 90.40)	86.11 (79.37 – 91.31)
Valor predictivo negativo	90.44 (86.95 – 93.25)	90.36 (86.85 – 93.19)

Evaluación del rendimiento a tasas específicas de falsos positivos

Se realizó una evaluación adicional del modelo utilizando puntos fijos de la curva ROC correspondientes a tasas de falsos positivos del 10% y 15%, que son relevantes en un contexto clínico donde se privilegia minimizar el sobret ratamiento. A una tasa de falsos positivos del 10%, el área bajo la curva ROC fue de 0.869 en el conjunto de entrenamiento (IC 95%: 0.804–0.922) y de 0.868 en la validación (IC 95%: 0.792–0.918). A un umbral de FPR del 15%, el AUC aumentó a 0.902 y 0.899, respectivamente.

Tabla 4. Desempeño discriminativo del modelo predictivo		
Conjunto	Detección 10% FPR (IC95%)	Detección 15% FPR (IC95%)
Entrenamiento	0.869 (0.804 – 0.922)	0.902 (0.843 – 0.941)
Validación	0.868 (0.792 – 0.918)	0.899 (0.849 – 0.943)
FPR: tasa de falsos positivos, IC: intervalo de confianza		

Evaluación de la calibración del modelo

La calibración del modelo fue evaluada mediante una curva de calibración con ajuste suavizado tipo *lowess* en el conjunto de validación. La gráfica mostró una alineación adecuada entre los valores predichos y observados, con un ligero desplazamiento hacia la sobrestimación en probabilidades altas. El valor de la razón de E:O fue 0.953, lo cual indica una adecuada concordancia general. La pendiente de calibración fue de 0.880, lo que sugiere una ligera sobreajuste del modelo, mientras que el intercepto o CITL fue de 0.184. Estos hallazgos, junto con una AUC de 0.931, respaldan una buena capacidad discriminativa y una calibración razonable del modelo predictivo (**Figura 2**).




Figura 2. Curva de calibración del modelo en la cohorte de validación. La figura muestra la relación entre el riesgo predicho y la proporción observada de partos pretérmino. La línea azul representa el ajuste por *lowess*, y la línea discontinua indica la referencia ideal (perfecta calibración). Los puntos verdes corresponden a grupos de riesgo con sus intervalos de confianza al 95%. El modelo mostró buena calibración, con razón esperados/observados (E:O) de 0.953, CITL de 0.184 y pendiente de 0.880.

Desempeño del modelo en desenlaces secundarios

En la cohorte de validación, se evaluó la capacidad del modelo predictivo de parto pretérmino para anticipar desenlaces neonatales secundarios de relevancia clínica. Para el puntaje de Apgar bajo al minuto 5, el modelo alcanzó un AUC de 0.118 con una FPR del 10%, y de 0.184 al aumentar el FPR al 15%. Al considerar un Apgar persistentemente bajo (es decir, menor de 7 tanto al minuto 1 como al minuto 5), el modelo mostró una capacidad de discriminación ligeramente superior, con una AUC de 0.124 a FPR 10% y de 0.182 a FPR 15%, lo que sugiere cierta utilidad para identificar recién nacidos con compromiso neonatal sostenido.

Respecto a la necesidad de ingreso a cuidados intensivos neonatales, el modelo presentó un desempeño más favorable, con un AUC de 0.309 a FPR 10% y de 0.471 al 15%, reflejando una capacidad moderada para anticipar este desenlace clínicamente significativo. En el caso del óbito, aunque se trata de un evento de baja frecuencia, el modelo alcanzó un AUC de 0.425 con FPR del 10% y de 0.500 con FPR del 15%, lo que indica una capacidad discriminativa aceptable para un evento tan crítico y difícil de predecir (**Tabla 5**).

Tabla 5. Desempeño del modelo predictivo para anticipar desenlaces neonatales adversos en la cohorte de validación		
Variable	Desempeño FPR 10%	Desempeño FPR 15%
Apgar bajo ¹	0.118	0.184
Apgar persistente bajo ²	0.124	0.182
Ingreso UCIN	0.309	0.504
Óbito	0.425	0.500
1. Apgar al minuto 5 <7, refleja compromiso neonatal inmediato. 2. Deterioro sostenido en el puntaje Apgar entre el 1° y 5° minuto. FPR: tasa de falsos positivos, UCIN: unidad de cuidados intensivos neonatales.		

11. DISCUSIÓN

Hallazgos principales

Este estudio desarrolló y validó internamente un modelo predictivo de parto pretérmino utilizando inteligencia artificial con regresión logística penalizada con elastic net, a partir de variables clínicas, bioquímicas y ecográficas obtenidas durante el primer trimestre de embarazo. El modelo mostró un desempeño discriminativo sobresaliente, con un AUC de 0.968 en la cohorte de entrenamiento y de 0.937 en la cohorte de validación. Además, presentó una calibración adecuada, con una razón esperados/observados de 0.953 y una pendiente de calibración de 0.880, lo que indica concordancia entre las probabilidades predichas y los eventos observados. Las variables con mayor peso predictivo fueron la longitud cervical, el antecedente de parto pretérmino, la presión arterial media y el recuento leucocitario.

Comparación con la literatura existente

El presente estudio tuvo como objetivo evaluar la capacidad predictiva de un modelo basado en inteligencia artificial, utilizando características clínicas y bioquímicas del primer trimestre del embarazo para la detección de parto pretérmino. La prevalencia de parto pretérmino en la cohorte analizada fue del 30.9%, valor superior al reportado por la Organización Mundial de la Salud (OMS), que estima una incidencia global cercana al 10%, y por estudios nacionales que reportan tasas entre el 8% y el 13% [14,15]. Esta diferencia podría explicarse por el perfil de la población atendida en una unidad de tercer nivel y la selección intencionada de casos para el presente estudio.

Con base en los resultados obtenidos encontramos que las mujeres con parto pretermino y parto a termino tuvieron una edad similar, sin encontrar una diferencia significativa. Lo que si fue evidente es que las mujeres con parto pretérmino presentaron un índice de masa corporal mayor en comparación con aquellas con parto a término lo que sugiere una asociación significativa entre valores elevados y la ocurrencia de parto pretérmino, lo cual coincide con estudios que plantean que el sobrepeso y la obesidad pregestacional incrementan el riesgo obstétrico, probablemente debido a un estado inflamatorio crónico, resistencia a la insulina y mayor incidencia de patologías como preeclampsia [16]

En las últimas décadas, los modelos clínicos tradicionales que emplean factores de riesgo como antecedente obstétrico, longitud cervical o infecciones urinarias han mostrado limitaciones en sensibilidad y especificidad para predecir parto pretérmino [17]. Es en este contexto donde la inteligencia artificial, y en particular las técnicas de aprendizaje automático, han cobrado relevancia como herramientas para mejorar la predicción temprana de partos pretérmino.

Un metaanálisis reciente de Kwon incluyó 14 estudios de predicción de parto pretérmino mediante IA, concluyó que los modelos de machine learning, especialmente aquellos que integran múltiples fuentes de datos clínicos y bioquímicos, superan significativamente a los modelos tradicionales, alcanzando valores de AUC entre 0.75 y 0.95 dependiendo del algoritmo y el tipo de variables utilizadas. [18].

Otros estudios similares, es el de Son et al. utilizando Random Forest con datos clínicos y ecográficos, en donde identificaron a la longitud cervical, el IMC y la presión arterial media como predictores claves de parto pretérmino. En dicho estudio, el AUC reportado para Random Forest fue de 0.87, comparable al desempeño del modelo de regresión penalizada por elastic net empleado en el presente trabajo[19].

Asimismo, el estudio multicéntrico de Zhang, que aplicó modelos basados en XGBoost y Random Forest en una cohorte de más de 8000 gestantes, encontró que variables como antecedentes obstétricos, edad materna, IMC, marcadores inflamatorios y factores

sociodemográficos, permitían construir modelos con AUC >0.90, especialmente cuando se combinaban con algoritmos de selección automática de variables, como LASSO o elastic net [20]. Respalda el enfoque estadístico utilizado en esta investigación.

Una revisión sistemática publicada en 2023 por Khan et al. identificó que los modelos más efectivos fueron aquellos entrenados con datos del primer y segundo trimestre, en lugar de limitarse a la evaluación tardía del embarazo, debido a que permiten intervenciones preventivas más tempranas. En este sentido, la inclusión en nuestro modelo de variables disponibles desde el primer trimestre representa una fortaleza clínica significativa[21]. Por otro lado, en un estudio innovador, Wang et al. emplearon inteligencia artificial para predecir parto pretérmino usando datos electrónicos de salud (EHR), demostrando que incluso sin parámetros bioquímicos, un modelo bien entrenado podía alcanzar AUC de 0.80, aunque con menor especificidad que modelos basados en biomarcadores como el nuestro[22]. También es importante destacar el trabajo de Abbar, quienes aplicaron redes neuronales profundas (DNN) y lograron una sensibilidad de hasta 85% para parto pretérmino utilizando variables bioquímicas e imagenológicas. No obstante, estos modelos suelen ser más difíciles de interpretar clínicamente, a diferencia del modelo LASSO desarrollado en el presente estudio, que permite una mejor comprensión de los predictores involucrados [23].

Estos hallazgos respaldan el potencial del uso de modelos de inteligencia artificial como herramienta de apoyo en la práctica clínica, particularmente en el primer trimestre del embarazo, donde la identificación temprana de mujeres en riesgo permitiría la implementación de estrategias de vigilancia intensificada y medidas preventivas. No obstante, se reconoce que la aplicabilidad clínica de estos modelos requiere validación externa y su integración en sistemas de salud con infraestructura tecnológica adecuada.

Este estudio favorece la utilidad de los marcadores clínicos y bioquímicos tempranos para la predicción del parto pretérmino, y demuestra que la inteligencia artificial puede aumentar la precisión predictiva respecto a los métodos convencionales, lo cual abre la posibilidad de mejorar los desenlaces perinatales mediante una detección oportuna y personalizada del riesgo.

Implicaciones clínicas

El modelo propuesto representa una herramienta factible y potencialmente útil para ser incorporada en la práctica clínica, particularmente en unidades de atención prenatal que cuentan con registros electrónicos básicos. Su alto valor predictivo negativo (90.4%) puede permitir una adecuada estratificación del riesgo y evitar intervenciones innecesarias en mujeres de bajo riesgo. A su vez, la buena capacidad de detección incluso con tasas de falsos positivos controladas lo posiciona como una estrategia costo-efectiva para optimizar el uso de recursos dirigidos a la prevención del parto pretérmino, como la progesterona vaginal, los cerclajes o el seguimiento especializado.

Implicaciones para la investigación

Este estudio evidencia el valor de la inteligencia artificial a través de aprendizaje automático en el desarrollo de modelos predictivos clínicamente relevantes en obstetricia. La metodología aplicada puede replicarse para otras condiciones obstétricas y perinatales, promoviendo la medicina personalizada y predictiva. Además, al evaluar desenlaces neonatales secundarios, se abre la posibilidad de extender el uso del modelo más allá de la predicción del parto pretérmino hacia una estimación integral del riesgo neonatal. Estudios futuros deben explorar la validación externa en poblaciones diversas y la implementación en plataformas digitales o aplicaciones móviles que faciliten su uso en tiempo real.

Fortalezas y limitaciones

Entre las principales fortalezas se encuentran el tamaño muestral adecuado, el diseño riguroso con validación interna, y el uso de variables accesibles y rutinarias, lo que favorece su aplicabilidad en contextos de salud pública. Además, el empleo de elastic net permite manejar la multicolinealidad y realizar una selección automatizada de predictores relevantes, evitando el sobreajuste. No obstante, se reconocen algunas limitaciones. El modelo fue desarrollado y validado en una única cohorte institucional, lo que restringe la generalización de los resultados. Asimismo, aunque se incluyeron desenlaces neonatales relevantes, su baja frecuencia, especialmente en el caso del óbito, limitó el poder discriminativo. Finalmente, el modelo no incorpora biomarcadores avanzados ni datos genéticos, lo cual podría mejorarse en futuras versiones híbridas.

12. CONCLUSIÓN

La implementación de modelos de predicción basados en inteligencia artificial, particularmente mediante el uso del algoritmo random forest, permite una identificación precisa y temprana de mujeres con riesgo de parto pretérmino utilizando variables clínicas y bioquímicas disponibles desde el primer trimestre. La elevada capacidad discriminativa del modelo desarrollado, superior a la de estudios previos, resalta la relevancia de incorporar herramientas tecnológicas en la atención prenatal como complemento a la evaluación convencional. En consecuencia, la integración de la IA en el entorno clínico podría favorecer intervenciones oportunas y dirigidas que mejoren los desenlaces perinatales, en particular en contextos de alto riesgo.

13. BIBLIOGRAFIA

1. Blencowe H, Cousens S, Oestergaard MZ, Chou D, Moller A-B, Narwal R, et al. National, regional, and worldwide estimates of preterm birth rates in the year 2010 with time trends since 1990 for selected countries: a systematic analysis and implications. *Lancet*. 2012;379(9832):2162–72.
2. Pérez Zamudio R, López Terrones CR, Rodríguez Barboza A. Morbilidad y mortalidad del recién nacido prematuro en el Hospital General de Irapuato. *Bol Med Hosp Infant Mex*. 2013;70(4):299–305.
3. Svenvik M, Raffetseder J, Brudin L, Berg G, Hellberg S, Blomberg M, et al. Early prediction of spontaneous preterm birth before 34 gestational weeks based on a combination of inflammation-associated plasma proteins. *Front Immunol*. 2024;15:1415016.
4. Couceiro J, Matos I, Mendes JJ, Baptista PV, Fernandes AR, Quintas A. Inflammatory factors, genetic variants, and predisposition for preterm birth. *Clin Genet*. 2021;100(4):357–67.
5. Wathan FM, Siregar KN. The risk factors and prediction models of preterm birth: An update systematic literature review. *Indian J Public Health Res Dev*. 2021;12(2):468–473.
6. Lv Y, Xu L, He Z, Liu X, Guo Y. The association between pregnancy levels of blood lipids and the risk of preterm birth. *Sci Rep*. 2024;14(1):1-8.

7. Zhang J, Sun K, Zhang Y. The rising preterm birth rate in China: a cause for concern. *Lancet Glob Health*. 2021;9(9):79–80.
8. Wang R, Pan W, Jin L, Li Y, Geng Y, Gao C, et al. Artificial intelligence in reproductive medicine. *J Reprod Fertil*. 2019;158(4):139–154.
9. World Health Organization. Mortalidad neonatal. 2024, 14 marzo. *Mortalidad neonatal*. <https://www.who.int/es/news-room/fact-sheets/detail/newborn-mortality>.
10. Ramachandran A, Clotney KD, Gordon A, Hyett JA. Prediction and prevention of preterm birth: Quality assessment and systematic review of clinical practice guidelines using the AGREE II framework. *Int J Gynaecol Obstet*. 2024;166(3):932–942.
11. Davey M-A, Watson L, Rayner JA, Rowlands S. Risk scoring systems for predicting preterm birth with the aim of reducing associated adverse outcomes. *Cochrane Database Syst Rev*. 2011;(11):CD004902.
12. Tang ID, Mallia D, Yan Q, Pe'er I, Raja A, Salieb-Aouissi A, et al. A scoping review of preterm birth risk factors. *Am J Perinatol*. 2024;41(S 01):e2804–17.
13. D'Silva AM, Hyett JA, Coorsen JR. First trimester protein biomarkers for risk of spontaneous preterm birth: Identifying a critical need for more rigorous approaches to biomarker identification and validation. *Fetal Diagn Ther*. 2020;47(6):497–506
14. World Health Organization. *Born Too Soon: The Global Action Report on Preterm Birth*. Geneva: WHO; 2018.
15. Centro Nacional de Equidad de Género y Salud Reproductiva. *Informe de Salud Materna y Perinatal*. México: CNEGSR; 2022.
16. Parker MG, Ouyang F, Pearson C, et al. Prepregnancy body mass index and risk of preterm birth: association heterogeneity by preterm subgroups. *BMC Pregnancy Childbirth*. 2014;14:153.
17. Iams JD, Romero R, Culhane JF, Goldenberg RL. Primary, secondary, and tertiary interventions to reduce the morbidity and mortality of preterm birth. *Lancet*. 2008;371(9607):164–75.
18. Kwon YS, Kim Y, Lee Y, et al. Application of artificial intelligence for prediction of preterm birth using electronic health records: A meta-analysis. *J Obstet Gynaecol Res*. 2022;48(6):1398–1407.

19. Son M, Miller ES, El-Sayed YY, et al. Predicting preterm birth with machine learning: a prospective cohort study. *Am J Obstet Gynecol*. 2022;226(1):93.e1–93.e14.
20. Zhang Y, Ma J, Song J, et al. Early prediction of spontaneous preterm birth using machine learning models: A population-based cohort study. *BMC Pregnancy Childbirth*. 2021;21(1):765.
21. Khan A, Farooq MU, Hussain S, et al. Machine learning in obstetrics: current trends and future directions. *Front Med (Lausanne)*. 2023;10:1123112.
22. Wang R, Kumar P, Tan W, et al. Predicting preterm birth using machine learning models with EHR data. *JAMA Netw Open*. 2021;4(10):e2134385.
23. Abbar H, Wang Y, Wang H, et al. Deep learning for prediction of preterm birth using biomarkers and ultrasound data. *PLoS One*. 2022;17(5):e0268657.