

# Determinantes de la pobreza en México: Un análisis con Inteligencia Artificial.

Oscar Jonathan Banderas-Orozco<sup>1</sup>, María del Rosario Escalante-Peinado<sup>1</sup>, Luis Espino-Gutiérrez, Emmanuel Soriano-Basilio<sup>1</sup>, Jonathan Betzain Trujillo-Magaña<sup>1</sup>.

<sup>1</sup> Universidad La Salle Morelia, Dirección de Posgrados, Investigación y Educación Continua. Morelia, México.

224009@ulsamorelia.edu.mx, 224012@ulsamorelia.edu.mx,  
248003@ulsamorelia.edu.mx, e\_soriano@ulsamorelia.edu.mx,  
jtrujillo@ulsamorelia.edu.mx

**Resumen.** El presente estudio tiene la finalidad de determinar cuáles son los factores que explican que un municipio se mantenga en pobreza extrema, de forma tal que los resultados vertidos de esta investigación sirvan de base para diseñar y establecer políticas públicas más eficientes y focalizadas en disminuir la pobreza en nuestro país, identificando con mayor precisión patrones de desigualdad que limitan el acceso a mejores oportunidades de vida y que impactan de manera negativa en el desarrollo de la población. Para realizar el análisis de los diversos factores que inciden primordialmente en la pobreza en México, se utilizaron modelos de regresión logística e inteligencia artificial como *Random Forest*. A partir de los resultados obtenidos se establece la probabilidad de que un municipio pueda encontrarse o no en pobreza extrema, teniendo como principales variables de influencia: el rezago educativo, la tasa de delitos (violencia), el acceso a la salud, la seguridad social y la falta de servicios básicos de vivienda y alimentación. Adicionalmente se identificó que los municipios con menor Índice de Desarrollo Humano (IDH) se encuentran en zonas rurales, se dedican a actividades agrícolas, con alto porcentaje de población indígena y bajo ingreso; lo cual contrasta con los municipios con mayor IDH que se encuentran en el norte y centro del país en condiciones totalmente diferentes, es decir, con actividades en el sector secundario y terciario de la economía, así como mejores niveles de educación y salud. Se espera que la presente investigación pueda ofrecer a los responsables de la elaboración de políticas públicas en los distintos niveles de gobierno, un panorama claro, preciso y actual de las principales causas que generan pobreza extrema en varios de los municipios del país, lo cual podría llevarnos a lograr el cumplimiento de los Objetivos de Desarrollo Sostenible (ODS) propuestos por la Organización de las Naciones Unidas, en específico a los ODS 1 Fin de la pobreza y ODS 10 Reducción de las desigualdades como país.

**Palabras Clave:** Inteligencia Artificial, Pobreza extrema, Políticas públicas.

## 1 Descripción de la problemática prioritaria abordada

El presente análisis se fundamenta en la necesidad de comprender la pobreza como un fenómeno complejo, estructural y territorialmente diferenciado, que no puede ser abordado desde una sola dimensión ni mediante métricas agregadas que invisibilizan las desigualdades locales. En este sentido, se reconoce que atacar la pobreza exige estrategias articuladas que incrementen los ingresos locales, reduzcan la vulnerabilidad social y garanticen el acceso efectivo a derechos fundamentales como salud, vivienda y seguridad social.

México fue el primer país del mundo en adoptar oficialmente una medición multidimensional de la pobreza, establecida por el CONEVAL en 2009 conforme a la Ley General de Desarrollo Social (LGDS) y estos son los datos con los que se cuentan al 2022.

Esta perspectiva se alinea con los enfoques más avanzados en la medición y análisis de la pobreza, entre los cuales destaca el método Alkire-Foster (AF), desarrollado por Sabina Alkire y James Foster, como una herramienta rigurosa y flexible para capturar la multidimensionalidad del fenómeno. Este enfoque va más allá de la insuficiencia de los recursos económicos e incluye dimensiones como el rezago educativo, el acceso a salud, alimentación, seguridad social, calidad y servicios en la vivienda, y la cohesión social, ofreciendo así una visión integral que combina bienestar económico y derechos sociales para focalizar políticas públicas y evaluar sus impactos.

La pobreza constituye un desafío estructural complejo que impacta significativamente a amplios sectores de la sociedad con diferentes problemas como el desarrollo humano, la violencia, delincuencia, entre otros. A pesar de las mejoras económicas registradas en las últimas décadas, los frutos de estos progresos no han alcanzado de manera equitativa a toda la población. Según datos del Consejo Nacional de Evaluación de la Política de Desarrollo Social, en 2022 el 36.3% de la población equivalente a 46.8 millones de personas a nivel nacional se encontraba en situación de pobreza con un promedio de 2.6 carencias por persona y el 7.1% en situación de pobreza extrema equivalente a 9.1 millones de personas con 3.8 carencias promedio por persona (CONEVAL, 2023).

Ante esta realidad, es indispensable contar con análisis estadísticos robustos que permitan determinar la relación entre la pobreza y los diferentes factores que inciden en la misma, de forma tal que los resultados que se obtienen en el presente estudio puedan servir como guía a los tomadores de decisiones de políticas públicas para generar aquellas que ayuden a disminuir el nivel de pobreza extrema en el país.

Para llevar a cabo un análisis robusto se emplearon tres técnicas: Regresión Logística, Machine Learning y Análisis de Clusters. Las dos primeras técnicas permitieron identificar diferentes patrones dentro de grandes volúmenes de datos que ayudan a predecir la probabilidad de mantenerse en pobreza extrema, y lo más importante, identificar las principales variables claves que la explican a un dado nivel de confianza (BBVA, 2024) y por otra parte, el análisis de cluster permitió generar grupos homogéneos al interior y heterogéneos al exterior para poder contrastar las características entre los municipios con menor Índice de Desarrollo Humano (IDH) respecto de los municipios que presentan mayor IDH.

Entender estas metodologías de composición social, económica, de servicios y política, entre otros inmersos en la pobreza, se vuelve tan importante como su combate mismo, provocando así claras oportunidades de desarrollo de acciones para acercar a México a los Objetivos de Desarrollo Sostenible (ODS) definidos por la ONU

Al hacer referencia a algún objeto dentro del documento debe escribirse la palabra Figura, Tabla o Sección. Las figuras incorporadas deben ser originales, de uso libre o, en su defecto, poder contar con la autorización pertinente para su reproducción.

## 2 Objetivo

Determinar, mediante técnicas de Regresión Logística, Machine Learning (*Random Forest*) y Análisis de Clusters los factores que inciden en la pobreza extrema a nivel municipal en México, de forma tal que sirvan los resultados encontrados en el presente estudio a los actores encargados de las políticas públicas pertinentes a desarrollar de forma más efectiva dichas políticas para alcanzar las metas que los Objetivo de Desarrollo Sostenible (ODS) número 1, referente a la base de estrategias de desarrollo en favor de los pobres, y número 10 de la ONU, enfocada a la reducción de las desigualdades entre los pobladores de las naciones (Naciones Unidas, 2015) para reducir la pobreza extrema en México.

## 3 Propuesta teórico-metodológica

En un entorno cada vez más orientado por los datos cuantitativos, la capacidad de extraer variables significativas a partir de grandes volúmenes de información se vuelve esencial para analizar fenómenos sociales complejos como la pobreza. Entre las técnicas estadísticas más empleadas, está la **regresión logística** que permite modelar una variable binaria —en el presente estudio la presencia o ausencia de pobreza extrema en un municipio— en función de variables predictoras

llamadas características (por ejemplo, la salud) en función de sus atributos (por ejemplo, acceso bajo, medio o alto a la salud). Estas variables suelen transformarse en **variables dicotómicas (dummies)** para indicar la presencia o ausencia del atributo y facilitar su interpretación, y el modelo se ajusta considerando  $n - 1$  atributos de cada variable con el fin de evitar problemas de multicolinealidad. Esta técnica es ampliamente utilizada en ciencias sociales por su capacidad para identificar relaciones no lineales y estimar probabilidades asociadas a fenómenos categóricos (Hosmer, Lemeshow & Sturdivant, 2013). La función logística se expresa como:

$$P(y) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}} \quad (1)$$

Las betas ( $\beta_i$ ) indican el valor explicativo del atributo  $i$  al fenómeno de estudio (pobreza extrema), manteniéndose en el modelo solo aquellas significativas a un  $\alpha\%$  de confianza (95%), las cuales se obtienen a través de un método conocido como stepwise.

Con base en datos de CONEVAL (2020) y CONAPO (2020), para fines del presente estudio se clasifican como municipios en pobreza extrema aquéllos donde más del 40% de la población se encuentra en esta condición.

Como variables explicativas (predictoras) se obtuvieron diferentes variables a nivel municipio como salud, tasa de delitos, carencias sociales, ingreso, nivel educativo, nivel de vivienda. Con el objetivo de que no se presentaran sesgos en el modelo, para cada característica se obtuvieron sus atributos y se clasificaron en bajo, intermedio o alto a partir de los percentiles del 33%, 66% y mayor respectivamente. En la siguiente figura se muestra lo descrito para la variable de rezago educativo. Por ejemplo, si en el municipio menos del 10% de la población (percentil del 33%) tiene rezago educativo, se le clasifica como rezago educativo bajo y si es más del 39% (percentil del 66%) es un municipio con rezago educativo alto.

Por su parte, el **Machine Learning (ML)** ofrece técnicas que permiten detectar patrones y predecir comportamientos futuros sin necesidad de suposiciones estrictas sobre la forma funcional de los datos. Dentro del ML supervisado, destaca el algoritmo **Random Forest**, una técnica no paramétrica de clasificación y regresión que emplea múltiples árboles de decisión para mejorar la precisión y la robustez del modelo. Esta herramienta resulta especialmente útil en contextos complejos, ya que es **interpretativa, tolerante al ruido y adaptable a múltiples variables predictoras**. Gracias a estas propiedades, ha demostrado ser eficaz en el análisis de fenómenos sociales, como la pobreza y la exclusión, donde las relaciones entre variables suelen ser no lineales y multifactoriales (Lantz, 2019; Thoplan, 2014). Para fines del análisis con Random Forest se utilizó la misma base usada en el análisis de regresión lineal.

Otra herramienta clave en el análisis es el de conglomerados (*cluster analysis*), el cual permite identificar estructuras subyacentes en los datos sin requerir una variable dependiente. De acuerdo con Mohamed (2017), este enfoque es particularmente útil para estudios exploratorios. Se distingue entre métodos jerárquicos como el método de *Ward*, que minimiza la varianza *intra-cluster* y se visualiza mediante dendrogramas y métodos no jerárquicos como el *k-means*, que requiere definir previamente el número de grupos y asigna elementos al centroide más cercano. En este estudio, el método *k-means* se emplea para clasificar municipios según su IDH y sus componentes (ingreso, educación y salud). En la siguiente sección se muestran los resultados obtenidos.

En conjunto, estas metodologías permiten un análisis integral y, sobre todo, ofrecen estadísticas que nos permiten determinar comportamientos o patrones y relaciones no evidentes asociados a la pobreza extrema a nivel municipal generando grupos homogéneos al interior y heterogéneos al exterior, para poder observar de una manera más clara las diferencias entre grupos.

Cabe señalar que el uso de tecnologías de Machine Learning y Regresión logística son altamente utilizadas para determinar la predicción de la pobreza, como lo muestra en su estudio Usmanova et al (Usmanova, Aziz, Rakhmonov, & Osamy, 2022), quien señala que entre 2016 y 2022 el 55% de los estudios relacionados con la predicción de la pobreza fue con Random Forest, otro 35% con otras técnicas de machine learning y 10% con el método de regresión logística.

## 4 Discusión de resultados

Una vez analizada la información obtenida de diferentes fuentes, así como el tratamiento de las variables para la incorporación a los modelos, con el modelo de regresión logística se encontraron las siguientes variables significativas a un 95% de confianza (tabla 1). El modelo cuenta con una precisión para separar entre los municipios que se encuentran en pobreza extrema o no del 98.25% medido a través de lo que se conoce como prueba ROC (figura 5). Así mismo, el modelo presenta una eficacia del 96% en la clasificación de los municipios como se observa en la tabla 2.

El modelo de regresión logística indica que la probabilidad de que un municipio se mantenga en pobreza extrema es del 76%. En los modelos de regresión logística, una beta positiva incrementa la probabilidad de que se presente el evento (municipio en pobreza extrema) y si es negativa ayuda a disminuir la probabilidad. En la siguiente tabla se interpretan los resultados de las betas que encontró el modelo. Por ejemplo, la beta de alta carencia a los servicios básicos de vivienda es positiva, lo que significa que, a mayor carencia de dichos servicios, mayor es la probabilidad de permanecer en pobreza extrema.

Mediante la implementación del modelo Clasificador de árboles aleatorios (*Random Forest Classifier*) se jerarquizaron las variables con mayor poder predictivo (importancia del modelo), siendo el ingreso per cápita la de mayor importancia (29%), seguida por la vulnerabilidad por carencias sociales (22%) y la carencia por acceso a la seguridad social (16%). Las variables con mayor importancia del modelo se determinaron mediante la reducción de impureza, con Mean Decrease Gini (MDG). Por otro lado, el modelo se entrenó con la técnica muestreo con reemplazo (bootstrap samples), y con múltiples corridas para determinar el número óptimo de árboles con el mayor poder predictivo dando como resultado 100 árboles (reducción de sobre ajuste), las variables y nodos de cada árbol fueron contruidos con el método Gini Score que busca la reducción de impureza de las clases (Toplan, 2020). En contraste, variables tradicionalmente consideradas claves, como el rezago educativo y la violencia (tasa de delitos) tuvieron un peso explicativo relativamente bajo y otras variables como las remesas fueron descartadas por el modelo al no aportar capacidad predictiva significativa. El modelo de Random Forest también presenta una alta eficiencia en la clasificación de los municipios, con una precisión del 96% (tabla 5). Las variables más importantes que coincidieron entre el modelo de regresión logística y el modelo de Random Forest son: ingreso *per cápita*, carencias sociales y rezago educativo. Finalmente, se realizó un Análisis de Clústeres del IDH municipal que se compone a través de tres índices: ingreso, salud y educación. La técnica de clústeres a través del uso de software especializado, como lo es Python y Google Collab, generó 18 grupos los cuales contienen municipios homogéneos al interior y heterogéneos al exterior. Los 18 grupos fueron el resultado de la técnica codo de Jambu (elbow method), para la cual se ejecutaron múltiples corridas generando centroides aleatorios y buscando la reducción de suma de los cuadrados dentro de los clústeres (Within-Cluster Sum of Squares, WCSS) (Cui, 2020), dicha reducción se graficó mostrando como resultado el punto de inflexión donde se alcanzó el valor mínimo de WCSS y a su vez el número óptimo de clústeres(grupos). En particular, en el siguiente Mapa de la República se muestran dos grupos: los municipios de menor IDH (puntos rojos) y mayor IDH (puntos verdes).

En el mapa (figura 6 ) se puede observar que los municipios con bajo IDH se encuentran principalmente en el sur – sureste del país (Chiapas, Oaxaca, Guerrero y Veracruz), en municipios que se dedican principalmente a la actividad agrícola, con alta población indígena y baja infraestructura, mientras que los de alto IDH se encuentran en grandes ciudades con baja o nula actividad primaria, más bien focalizada a actividad industrial o de servicios, sin población indígena y que cuentan con alta infraestructura.

Así mismo, se observaron fuertes desigualdades entre grupos, con brechas en ingreso, educación y salud. El ingreso mensual en municipios con alto IDH es más de seis veces superior al de los municipios con bajo IDH.

Estos hallazgos ponen en evidencia que algunos factores estructurales tradicionalmente asociados a la pobreza pueden no ser tan determinantes como se pensaba. Por ejemplo, si bien el rezago educativo está presente en contextos de pobreza, no parece ser la variable que más explica, por sí misma, la situación de pobreza extrema en los municipios, al menos en el corto plazo. Del mismo modo, el hecho de que la violencia alta no esté correlacionada con la pobreza extrema

sugiere que su dinámica responde a factores distintos, como urbanización, desigualdad o criminalidad organizada, y no necesariamente a la falta de recursos o servicios básicos, aunque disminuir la violencia si puede ayudar a mejorar (en el modelo de regresión logística la violencia baja presenta una beta negativa). El análisis de la matriz de correlación entre variables permitió profundizar en estas observaciones. Por un lado, se confirmaron relaciones esperadas, como las fuertes correlaciones negativas entre el ingreso *per cápita* y diversas carencias sociales: con carencia en servicios básicos de vivienda, con carencia de seguridad social, y con población con tres o más carencias. Estas correlaciones refuerzan la conclusión de que mejorar el ingreso per cápita tiene un efecto multiplicador para superar la pobreza multidimensional, reduciendo múltiples privaciones de manera simultánea. También se observaron altas correlaciones positivas entre dimensiones de pobreza estructural, por ejemplo, entre la carencia en servicios básicos y la población con tres o más carencias (0.91), o entre la carencia por calidad de la vivienda y la carencia por servicios básicos (0.78). Estos resultados muestran que la pobreza extrema tiende a ser acumulativa, es decir, cuando existe una carencia, es altamente probable que existan otras, lo cual limita severamente las oportunidades de desarrollo. En cuanto a los hallazgos más inesperados, destaca la correlación negativa entre el rezago educativo y la tasa de delitos (-0.52), lo que sugiere que los municipios con mayor rezago educativo suelen tener menores niveles de criminalidad reportada. Una posible explicación es que estas regiones tienden a ser rurales, con población indígena dispersa, en las que la cohesión comunitaria, la geografía aislada o incluso la subreportación pueden explicar esta tendencia. Por el contrario, se observó una correlación positiva entre ingreso y tasa de delitos (0.55), lo cual puede relacionarse con una mayor presencia del crimen en zonas urbanas y con desarrollo económico, donde los delitos patrimoniales y la desigualdad pueden ser más prevalentes. En conjunto, estos resultados evidencian que la pobreza extrema en México es un fenómeno multidimensional, pero también jerarquizable, donde ciertas variables tienen un mayor poder explicativo. El ingreso per cápita emerge como el factor transversal más influyente, lo cual tiene profundas implicaciones para el diseño de políticas públicas. No basta con atacar la pobreza desde una sola dimensión, es necesario articular estrategias que incrementen los ingresos locales, reduzcan la vulnerabilidad social, y promuevan el acceso efectivo a derechos básicos como salud, vivienda y seguridad social, tal como lo propone Filgueira (2001).

## 5 Conclusiones y perspectivas futuras

Una de las lecciones más valiosas de este estudio es que, en los municipios más rezagados, las personas están tan enfocadas en sobrevivir, que no tienen condiciones para desarrollar sus capacidades plenas, como estudiar, innovar o integrarse a sectores económicos más productivos. Esta situación fue teorizada por Amartya Sen (1999), quien planteó que el verdadero desarrollo no consiste sólo en aumentar el ingreso, sino en ampliar las libertades reales de las personas. En su enfoque de las capacidades, Sen señala que cuando los individuos viven en condiciones de carencia extrema, no pueden elegir cómo vivir: están atrapados en una lucha constante por satisfacer necesidades mínimas como alimentarse, tener un techo o cuidar su salud, lo que impide que accedan a logros de más alto nivel como educación, participación política o crecimiento económico sostenido.

Si se toma como referencia los resultados obtenidos y los hallazgos encontrados en el presente estudio y que se presentan en las tablas 1, 4 y figura 5, tomando como base que una mayor beta aumenta en mayor medida la probabilidad de estar en pobreza extrema, así como la importancia en las variables y la ubicación de los municipios con bajo IDH, se recomiendan los siguientes pasos de política pública para tratar de disminuir la pobreza extrema y alcanzar los ODS1 y 10 de la ONU: Basándonos en los hallazgos de este estudio (ver tablas 1 y 4, y figura 6), los cuales muestran que un mayor valor de beta se asocia con una probabilidad significativamente más alta de sufrir pobreza extrema, junto con la importancia de ciertas variables y la localización de municipios con bajo IDH, se proponen las siguientes políticas públicas con el objetivo de disminuir la pobreza extrema y alcanzar los ODS1 y 10 de la ONU. Dar acceso a servicios básicos de Vivienda, Aumentar la calidad de la vivienda, Programas de alimentación, Mejorar el acceso a los servicios de salud, Dar acceso a la educación, Aumentar el ingreso, Disminuir las carencias de seguridad social.

Así mismo, generar infraestructura carretera para comunicar a las poblaciones rurales a la economía y que dichas poblaciones no solo se dediquen a actividades económicas relacionadas con

la agricultura, sino que a través de sus productos se introduzcan a los sectores secundarios y terciarios para aumentar el valor de su producción y, como consecuencia, su índice de Desarrollo humano y sus componentes (ingreso, salud y educación). De igual manera, resulta prioritario impulsar la infraestructura carretera que permita integrar a las poblaciones rurales a la dinámica económica nacional. Ello facilitaría que dichas comunidades no se limiten únicamente a actividades agrícolas, sino que, mediante la transformación y comercialización de sus productos, puedan incorporarse a los sectores secundario y terciario. Este proceso favorecería el incremento del valor agregado de su producción y, en consecuencia, el fortalecimiento de su Índice de Desarrollo Humano y de sus principales dimensiones: ingreso, salud y educación. En resumen, los resultados del estudio señalan que primero se debería atender lo urgente: alimentación, salud, vivienda, seguridad social, y simultáneamente construir las bases para lo estructural: educación, empleo formal, innovación, participación económica. Sólo así se podrá romper el círculo vicioso de la pobreza y avanzar hacia una sociedad verdaderamente inclusiva. Atacando los resultados obtenidos en la presente investigación, se podrá contribuir directamente al cumplimiento de los Objetivos de Desarrollo Sostenible (ODS) propuestos por la Organización de las Naciones Unidas: ODS 1: Fin de la pobreza, al identificar con evidencia científica cuáles son las variables clave que deben atenderse para reducir eficazmente la pobreza extrema desde una perspectiva multidimensional, no solo de ingreso, sino también de acceso a derechos fundamentales. ODS 10: Reducción de las desigualdades, al evidenciar que las condiciones estructurales que perpetúan la pobreza, como la precariedad habitacional, la falta de servicios básicos, la exclusión territorial y la desigualdad en el acceso a oportunidades, son obstáculos profundos que requieren intervenciones diferenciadas y focalizadas. Este trabajo permite enfocar políticas que promuevan mayor equidad y cohesión social, especialmente en los municipios históricamente marginados.

En síntesis, el presente análisis no se limita a generar conocimiento científico sobre la pobreza, que lo hace desde una perspectiva territorial y estructural que reconoce las configuraciones históricas, institucionales y socioespaciales que perpetúan la desigualdad, sino que también ofrece una hoja de ruta para la acción pública efectiva, ética y contextualizada. Este enfoque permite superar las limitaciones de las mediciones agregadas y descontextualizadas, al incorporar dinámicas locales, capacidades endógenas y vulnerabilidades diferenciadas entre regiones. Al articular evidencia empírica con marcos normativos, el estudio ofrece una hoja de ruta para la acción pública que no sólo es técnicamente viable, sino éticamente necesaria. Esta propuesta se alinea con los compromisos globales de sostenibilidad y justicia social —como los Objetivos de Desarrollo Sostenible (ODS) y el enfoque de capacidades de Sen—, al promover políticas que expandan las libertades reales de las personas y fortalezcan la resiliencia territorial frente a las múltiples dimensiones de la pobreza.

## 6 Agradecimientos


Agradecemos a la Universidad La Salle Morelia, Dirección de Posgrados, Investigación y Educación continua, así como a los asesores de este trabajo por su apoyo y servicios brindados para esta investigación.

## 7 Referencias

1. Alkire, S., & Foster, J. (2011). Counting and multidimensional poverty measurement. *Journal of Public Economics*, 95(7–8), 476–487.
2. BBVA Research. (2024). Machine learning para medición de pobreza en México. <https://www.bbva-research.com/publicaciones/machine-learning-para-medicion-de-pobreza-en-mexico/>
3. Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL). (2009). Metodología para la medición multidimensional de la pobreza en México. CONEVAL.
4. Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL). (2020). Índice de pobreza por municipio 2020. <https://www.coneval.org.mx/Medicion/Paginas/Medicion/Metodologia.aspx>
5. Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL). (2023). Medición de la pobreza en México 2022. [https://www.coneval.org.mx/Medicion/MP/Paginas/Pobreza\\_2022.aspx](https://www.coneval.org.mx/Medicion/MP/Paginas/Pobreza_2022.aspx)
6. Consejo Nacional de Población (CONAPO). (2020). Índice de marginación por municipio 2020. <https://www.gob.mx/conapo>

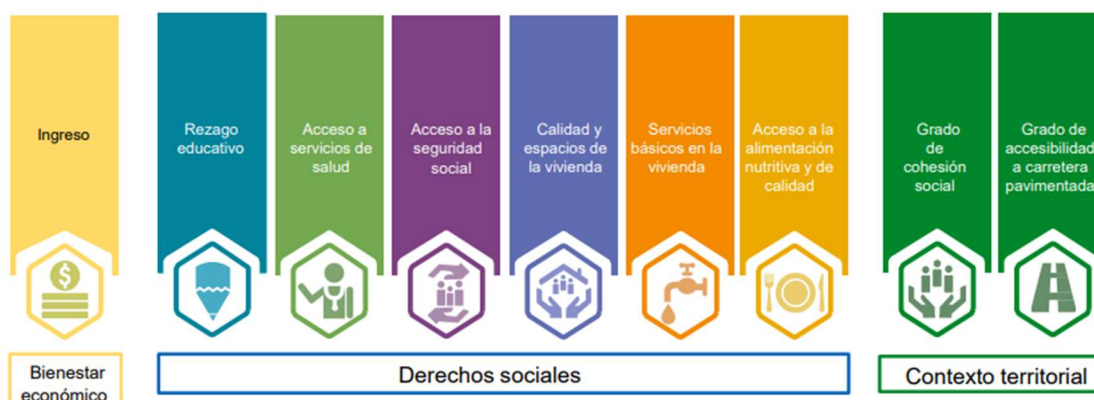
7. Cui, M. (2020). *Introduction to the K-Means Clustering Algorithm Based on the Elbow Method*. *Accounting, Auditing and Finance*, 1, 5-8. <https://doi.org/10.23977/accaf.2020.010102>
8. Filgueira, C. (2001). Estructura de oportunidades y vulnerabilidad social: Aproximaciones conceptuales para América Latina. Universidad de la República, Uruguay.
9. Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression* (3rd ed.). Wiley.
10. Lantz, B. (2019). *Machine learning with R: Expert techniques for predictive modeling* (3rd ed.). Packt Publishing.
11. Mohamed, A. E. (2017). Comparative study of four supervised machine learning techniques for classification. *International Journal of Applied Science and Technology*.
12. Naciones Unidas. (2015). Objetivos de Desarrollo Sostenible: ODS 1 – Fin de la pobreza y ODS 10 – Reducción de las desigualdades. <https://www.un.org/sustainabledevelopment/es/poverty/>
13. Usmanova, A., Aziz, A., Rakhmonov, D., & Osamy, W. (2022). Utilities of Artificial Intelligence in Poverty Prediction: A review. *Sustainability*, 14.
14. Sen, A. (2000). *Desarrollo y libertad* (1.ª ed.). Editorial Planeta.
15. Thoplan, R. (2014). *Random forests for poverty classification* [PDF]. Recuperado de [https://www.researchgate.net/profile/Ruben-Thoplan/publication/264785074\\_Random\\_Forests\\_for\\_Poverty\\_Classification/links/53ef8d0a0cf2711e0c42f4b4/Random-Forests-for-Poverty-Classification.pdf](https://www.researchgate.net/profile/Ruben-Thoplan/publication/264785074_Random_Forests_for_Poverty_Classification/links/53ef8d0a0cf2711e0c42f4b4/Random-Forests-for-Poverty-Classification.pdf)

**Figura 1.** Porcentaje y número de personas en situación de pobreza Estados Unidos Mexicanos 2016-2020




Fuente: Medición de Pobreza 2022 CONEVAL.

**Figura 2.** Pobreza multidimensional en México Dimensiones de la pobreza




Fuente: Medición de Pobreza 2022 CONEVAL.

Figura 3. Histograma de la distribución del porcentaje de la población en pobreza extrema.



Fuente: Elaboración propia con base en los resultados obtenidos de la investigación

Figura 4. Histograma de la distribución del porcentaje de la población con rezago educativo y su estratificación de nivel con base en sus deciles.




Fuente: Elaboración propia con base en los resultados obtenidos de la investigación

Tabla 1. Variables significativas al 95% de confianza para explicar la probabilidad de que un municipio se encuentre en pobreza extrema (Modelo de regresión logística)

Característica	Beta	P>  z
BAJA CARENCIA EN SERVICIO DE SALUD	-0.975	2.40%
TASA DE DELITOS BAJA	-0.749	5.00%
CARENCIAS SOCIALES PROMEDIO ALTO	0.774	2.00%
ALTA CARENCIA DE ACCESO A LA SEGURIDAD SOCIAL	1.177	0.00%
INGRESO PER CAPITA BAJO	1.340	0.00%
ALTO REZAGO EDUCATIVO	1.519	0.00%
ALTA CARENCIA EN SERVICIO DE SALUD	1.683	0.00%
ALTA CARENCIA DE ACCESO A LA ALIMENTACIÓN	1.883	0.00%
ALTA CARENCIA DE CALIDAD DE VIVIENDA	2.276	0.00%
ALTA CARENCIA A LOS SERVICIOS BÁSICOS DE VIVIENDA	2.562	0.00%
CARENCIAS SOCIALES ALTAS	3.234	0.00%
CONSTANTE	-5.966	0.00%

Fuente: Elaboración con STATA con información de la investigación



**Figura 5.** Indicador de eficiencia del modelo de regresión logística con base en la prueba ROC (98.25%)

Fuente: Elaboración con STATA con información de la investigación

**Tabla 2.** Clasificación de los municipios en pobreza extrema (pobres) y otros, demostrando una eficiencia del 96.41% en la clasificación. (Modelo de regresión logística)

	TABLA DE EFICIENCIA		
	Pobres	No Pobres	Total
Pobres	195	50	245
No Pobres	38	2167	2205
Total	233	2217	2450

Fuente: Elaboración propia con información de la investigación

	CLASIFICACIÓN	
	Pobres	No Pobres
Pobres	7.96%	2.04%
No Pobres	1.55%	88.45%
	<b>EFICACIA</b>	<b>96.41%</b>

Fuente: Elaboración propia con información de la investigación

**Tabla 3.** Modelo de regresión logística. Variables significativas a un 95% de confianza para explicar la pobreza extrema, las betas del modelo y una breve interpretación de las mismas.

Característica	Beta	P>  z	Probabilidad para pertenecer a un municipio de alta marginación
BAJA CARENCIA EN SERVICIO DE SALUD	-0.975	2.40%	A menor carencia en servicios de salud, menor probabilidad
TASA DE DELITOS BAJA	-0.749	5.00%	Una menor tasa de delitos ayuda a disminuir la probabilidad
CARENCIAS SOCIALES PROMEDIO ALTO	0.774	2.00%	A mayores carencias sociales, mayor probabilidad
ALTA CARENCIA DE ACCESO A LA SEGURIDAD SOCIAL	1.177	0.00%	A menor acceso a la seguridad social, mayor probabilidad
INGRESO PER CAPITA BAJO	1.340	0.00%	A menor ingreso per capita, mayor probabilidad
ALTO REZAGO EDUCATIVO	1.519	0.00%	A mayor rezago educativo, mayor probabilidad
ALTA CARENCIA EN SERVICIO DE SALUD	1.683	0.00%	A mayor carencia en servicios de salud, mayor probabilidad
ALTA CARENCIA DE ACCESO A LA ALIMENTACIÓN	1.883	0.00%	A mayor carencia de alimentación, mayor probabilidad
ALTA CARENCIA DE CALIDAD DE VIVIENDA	2.276	0.00%	A mayor carencia de calidad de la vivienda, mayor probabilidad
ALTA CARENCIA A LOS SERVICIOS BÁSICOS DE VIVIENDA	2.562	0.00%	A mayor carencia de los servicios básicos de vivienda, mayor probabilidad
CARENCIAS SOCIALES ALTAS	3.234	0.00%	A mayores carencias sociales, mayor probabilidad
CONSTANTE	-5.966	0.00%	

Fuente: Elaboración propia con información de la investigación

**Tabla 4.** Modelo Random Forest. Variables significativas para explicar la pobreza extrema y su importancia para la explicación de las mismas.

Variable	Importancia
Ingreso Per cápita	29%
Vulnerables por carencia social	22%
Carencia por acceso a la seguridad social	16%
Población con tres o más carencias sociales	10%
Carencia por acceso a los servicios básicos en la vivienda	5%
Rezago educativo	4%
Carencia por calidad y espacios de la vivienda	4%
Carencia por acceso a los servicios de salud	3%
Tasa de Delitos	3%
Carencia por acceso a la alimentación	2%

Fuente: Elaboración propia con información de la investigación

**Tabla 5.** Tabla de eficiencia del modelo de Random Forest para la clasificación de los municipios por nivel de pobreza de la muestra de desarrollo.

Clase	Precisión
Pobreza Extrema	92%
Pobre	97%
Exactitud	96%

Fuente: Elaboración propia con información de la investigación

**Figura 6.** Mapa de los municipios con mayor y menor IDH



Bajo IDH

**Sur y Sureste:** Chiapas, Oaxaca, Guerrero y Veracruz presentan los niveles más bajos, afectados por pobreza, baja escolaridad y escasa infraestructura.

Alto IDH

**Áreas Metropolitanas:** CDMX, Monterrey y Guadalajara destacan por sus economías diversificadas y empleo formal.

**Centros Industriales y Turísticos:** Querétaro, Puebla y Cancún tienen alto IDH, aunque con desigualdades internas.

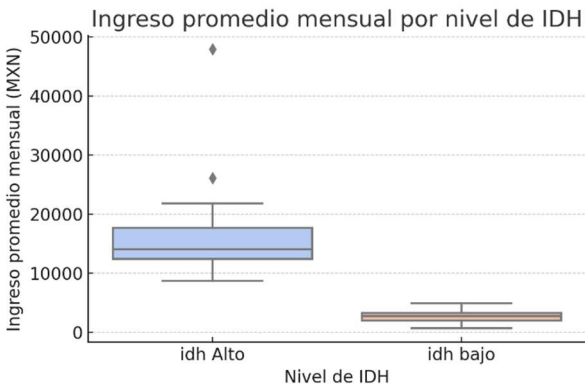
Fuente. Elaboración propia con información de la investigación

Tabla 6. Promedio de indicadores del IDH por clúster y sus componentes.

Indicador	Alto IDH	Bajo IDH
Índice de Educación (IE)	0.87	0.62
Índice de Salud (IS)	0.86	0.42
Índice de Ingreso (II)	0.90	0.62
IDH Promedio	0.88	0.55


Fuente: Elaboración propia con información de la investigación

Figura 7. Distribución del ingreso en los municipios con mayor y menor IDH



Fuente: Elaboración propia con información de la investigación

Figura 8. Matriz de correlación entre variables



Fuente: Elaboración propia con información de la investigación