

BRECHAS EN LA SALUD EVIDENCIA SOBRE DESIGUALDADES Y VULNERABILIDAD EN MÉXICO

Isaí Guízar y Willy W. Cortez
(coordinadores)



BRECHAS EN LA SALUD EVIDENCIA SOBRE DESIGUALDADES Y VULNERABILIDAD EN MÉXICO

Isaí Guízar y Willy W. Cortez
(coordinadores)



CUCEA

El mejor lugar para el talento

La realización de esta obra fue posible gracias al apoyo del Departamento de Métodos Cuantitativos y la Maestría en Economía, en colaboración con el Centro de Estudios de Problemas del Desarrollo y el cuerpo académico UDG-CA-981: Estudios sobre ciclos económicos, mercados financieros y seguridad humana.

Este libro fue sometido a un proceso de dictaminación doble ciego de acuerdo con las políticas editoriales de la Universidad de Guadalajara.

Primera edición, 2025

Brechas en la Salud.
Evidencia sobre Desigualdades y Vulnerabilidad en México
Isaí Guízar y Willy W. Cortez
(coordinadores)

Diseño de portada: CARIMEditores
Cuidado editorial: CARIMEditores

ISBN: 978-607-581-865-8

Todos los derechos son reservados. Esta publicación no puede ser reproducida en su totalidad ni en parcialidad, en español o en cualquier otro idioma, ni registrada, ni transmitida por cualquier sistema de reproducción de información, en ninguna forma ni por ningún medio, sean mecánicos, fotoquímico, electrónico, magnético, electroóptico, fotocopia o cualquier otro, inventado o por inventar, sin permiso expreso previo y por escrito del autor.

D.R. © 2025, Universidad de Guadalajara
Centro Universitario de Ciencias Económico Administrativas
Periférico Norte 799,
Núcleo Los Belenes 44100
Zapopan, Jalisco.

Editado y hecho en México / Edited and made in México

Índice

Hacia un sistema integral de salud pública <i>Isaí Guízar y Willy W. Cortez</i>	7
Pronóstico de niveles de glucosa en la sangre y eventos de hipoglucemia <i>Daniel Bedolla y Alejandro Islas-Camargo</i>	11
Factors that impact obesity prevalence in Mexico <i>Frida Fernández de la Rosa y Baruch Ramírez Rodríguez</i>	67
Malnutrición y desempeño académico en México: un análisis de niños en 6° grado de primaria <i>Cristian Cárdenas Mora y Willy W. Cortez</i>	107
Análisis descriptivo de la mortalidad por enfermedades metabólicas en poblaciones vulnerables de Jalisco a partir del Seguro Popular <i>Isaí Guízar, Daniel González Olivares y Fátima Housni</i>	165
Exploring setbacks of municipal life expectancies after COVID- 19 in Mexico <i>Eliud Silva y Guillermo Beick Tapia</i>	199

Hacia un sistema integral de salud pública

La salud pública en México ha enfrentado una creciente complejidad en cuanto al acceso y uso de servicios de salud en la última década. Desigualdades estructurales, el avance de enfermedades crónicas no transmisibles y la limitada capacidad institucional, son sólo algunos aspectos que enmarcan el tamaño de los desafíos que han impedido dar respuestas oportunas a las necesidades de salud de la población. A pesar de los avances normativos y de cobertura, amplios sectores de la sociedad continúan experimentando barreras significativas en el acceso, calidad y oportunidad de los servicios de salud. En este contexto, se vuelve urgente desarrollar investigaciones empíricas que permitan no sólo diagnosticar con precisión estos problemas, sino también aportar evidencia concreta sobre sus causas para diseñar políticas públicas más eficaces, equitativas y pertinentes.

Este libro surge como una contribución colectiva a ese esfuerzo. Desde distintos enfoques metodológicos y temáticos, los cinco capítulos que lo conforman abordan problemáticas

prioritarias en salud en México, con especial énfasis en poblaciones que tradicionalmente han sido marginadas o desatendidas. Empleando herramientas de análisis cuantitativo riguroso, los autores ofrecen una mirada crítica y propositiva que enriquece la literatura y que constituye una herramienta valiosa para tomadores de decisiones, diseñadores de políticas públicas y actores sociales comprometidos con las mejoras en salud pública.

La colección de trabajos se inicia con el estudio realizado por Bedolla e Islas-Camargo, cuyo objetivo es el desarrollo de un modelo predictivo de complicaciones agudas como la Hipoglucemia, en personas con diabetes tipo 1. Este modelo está basado en el pronóstico de los niveles de glucosa en personas con este tipo de padecimientos. Su valor radica en la aplicación de modelos en series de tiempo, ARIMA sobre datos de sensores de monitoreo continuo, logrando mejorar la anticipación de episodios de hipoglucemia. La propuesta va más allá de la evidencia diagnóstica y plantea caminos para una atención más personalizada mediante tecnologías accesibles e inteligentes.

El segundo capítulo, elaborado por Fernández de la Rosa y Ramírez, analiza cómo factores como ingreso per-cápita, transferencias sociales o el peso de la madre entre otros, aumenta la probabilidad de que una persona sea obesa o tenga sobrepeso. Su aporte reside en la estimación diferenciada de riesgos según quintiles de ingreso. Entre los resultados más sobresalientes están que el ingreso no afecta de manera uniforme a la probabilidad de obesidad de una persona, sino que cambia según el quintil: tiene un impacto positivo en el segundo y quinto quintil, pero negativo en los otros quintiles. También encuentran que, si la madre es obesa o con sobrepeso, la probabilidad de ser obeso o tener sobrepeso puede aumentar la probabilidad hasta en 29.8% en diferentes niveles de ingreso. Las recomendaciones de política se centran en diseñar intervenciones focalizadas que consideren el contexto socioeconómico de los hogares y promuevan

cambios sostenidos en hábitos alimenticios desde una perspectiva integral.

El trabajo de Cárdenas y Cortez, capítulo 3, analiza la relación entre malnutrición infantil y desempeño escolar, utilizando datos del Registro Nacional de Peso y Talla y de las pruebas PLANEA del año 2015, en niños de sexto grado de primaria a nivel nacional. El trabajo agrupa a los municipios en dos categorías, reprobados o aprobados. Un municipio es considerado reprobado si el porcentaje de alumnos que aplicaron el examen y fueron reprobados es mayor al 60% del total de estudiantes que presentaron el examen. Esta regla se aplica para cada una de las dos áreas del conocimiento que forman parte del examen PLANEA: Comprensión Lectora y Matemáticas. Uno de los primeros hallazgos es que confirman que un alto porcentaje de municipios con alumnos reprobados son municipios rurales. También encuentran que municipios con mayores porcentajes de niños con retraso en el crecimiento tienen una mayor probabilidad de ser un municipio reprobado en Comprensión Lectora. En términos de política, el trabajo plantea la necesidad de coordinar acciones entre los sectores salud y educación para atender la malnutrición como un factor limitante del desarrollo intelectual infantil.

El cuarto capítulo, escrito por Guízar, González y Housni, expone posibles efectos no intencionados del Seguro Popular sobre la mortalidad por enfermedades metabólicas. Este estudio parte de una posible paradoja en la que la ampliación del acceso a servicios de salud otorgada por el Seguro Popular podría haber impulsado la prevalencia de enfermedades metabólicas. Mediante el uso de modelos de conteo aplicados a series de tiempo, los autores señalan una correlación entre las coberturas con cambios en la mortalidad por estas causas. Este hallazgo plantea una contribución crítica a la evaluación de políticas públicas en salud, sugiere una línea de investigación en la

que la expansión de cobertura sin un fortalecimiento efectivo de la calidad podría resultar contraproducente. Se recomienda repensar el diseño de los programas de aseguramiento para que incluyan mecanismos efectivos de prevención y seguimiento.

El efecto devastador del COVID-19 en términos económicos (producción, empleo, inflación) ha sido ampliamente estudiado, lo mismo que el costo que la pandemia generó en términos de presión sobre los sistemas de salud pública a nivel mundial, que tuvo como consecuencia el aumento significativo de la tasa de mortalidad a nivel mundial. En ese sentido, el trabajo de Silva y Beick estiman la reducción de las expectativas de vida en México a consecuencia del COVID-19. Una contribución interesante del trabajo es que realizaron la estimación a nivel municipal. Ellos encontraron que los municipios con muy bajos índices de marginación tuvieron un retroceso promedio en la esperanza de vida de casi 23 años, mientras que los municipios con muy altos índices de marginación tuvieron un retroceso promedio de 8.6 años. Además, aquellos municipios con muy bajos grados de marginación exhibieron una baja dispersión, mientras que los municipios con muy alto grado de marginación mostraron una mayor variabilidad (7.7).

En conjunto, estos estudios confirman que las brechas en salud en México no sólo son persistentes, sino que también están profundamente ancladas en estructuras sociales, económicas y culturales. Al mismo tiempo, ofrecen caminos posibles para su reducción, mediante la articulación de evidencia empírica, sensibilidad social y voluntad política. Este libro es, en ese sentido, una invitación a mirar la salud con una perspectiva crítica y transformadora.

Pronóstico de niveles de glucosa en la sangre y eventos de hipoglucemia

*Daniel Bedolla**

*Alejandro Islas-Camargo***

RESUMEN

El objetivo de este trabajo es utilizar herramientas para el análisis de series de tiempo en el estudio de datos de 120 pacientes con Diabetes Mellitus Tipo 1 (DM1) que utilizaron sensores de Monitoreo Continuo de Glucosa (MCG) con el fin de proponer un algoritmo que pueda pronosticar los niveles de glucosa en este tipo de pacientes para prevenir complicaciones agudas como la hipoglucemia –que puede causar coma diabético o inclusive la muerte. La principal contribución del trabajo es que el algoritmo propuesto produce pronósticos más precisos comparados con los ya existentes en la literatura.

* Departamento de Matemáticas, Instituto Tecnológico Autónomo de México.

** Departamento de Estadística, Instituto Tecnológico Autónomo de México.

Palabras Clave: *Glucosa en la sangre, Modelos ARIMA, Diabetes tipo 1, hipoglucemia*

1. Introducción

La Organización Mundial de la Salud (OMS) define la diabetes como una enfermedad crónica que aparece cuando el páncreas no produce insulina suficiente, o cuando el organismo no utiliza eficazmente la insulina que produce. Esta enfermedad se divide principalmente en 2 tipos. Tipo 1 (DM1): se caracteriza por la ausencia de síntesis de insulina; Tipo 2 (DM2): tiene su origen en la incapacidad del cuerpo para utilizar eficazmente la insulina, lo que a menudo es consecuencia del exceso de peso o de la inactividad física, y Gestacional (DMG): corresponde a una hiperglucemia que se detecta por primera vez durante el embarazo.

La insulina es la hormona encargada de que el cuerpo aproveche la glucosa y la utilice como energía. Al impedir la producción de insulina o incapacitar al cuerpo para utilizarla eficazmente, la diabetes incrementa los niveles de glucosa en la sangre, lo que causa complicaciones agudas o crónicas que son perjudiciales para los pacientes, porque reducen su calidad de vida y aumentan el riesgo de muerte. Las complicaciones agudas son súbitas y surgen cuando los niveles de glucosa son demasiado altos o bajos.

En el informe mundial de la diabetes (OMS, 2016) se le atribuye buena parte de la mortalidad, los gastos elevados en el cuidado de la salud y la mala calidad de vida. Sus variantes son: (i) Cetoacidosis Diabética: cuando las células no están recibiendo la glucosa que necesitan, se producen cetonas, las cuales envenenan al cuerpo y pueden ocasionar un coma diabético o incluso la muerte; (ii) Síndrome hiperglucémico hiperosmolar no cetósico: se eleva el nivel de glucosa en la sangre y el cuerpo intenta eliminar este exceso por medio de la orina, lo que causa

convulsiones, coma y finalmente la muerte; (iii) Hipoglucemia: cuando los niveles de glucosa bajan de manera anormal, el paciente puede sufrir de convulsiones, pérdida del conocimiento o incluso la muerte; se puede presentar por un exceso de ejercicio o una dosis de insulina alta. Las complicaciones crónicas surgen con el transcurso de los años y son causadas por un constante descontrol de los niveles de glucosa, es decir, niveles altos o bajos. Ejemplos de este tipo de complicaciones son: daño al corazón, neuropatía, nefropatía, hipertensión, amputación de extremidades, accidentes cardiovasculares, entre otras.

Según cifras reportadas, la diabetes afecta al 8.8% de la población adulta en el mundo. Esto representa alrededor de 425 millones de personas que viven con diabetes, de las cuales aproximadamente el 90% tienen diabetes tipo 2 (International Diabetes Federation (IDF), 2017). En el mismo reporte se estimó que la carga económica de la diabetes en el mundo fue de 727 mil millones de dólares en 2017 y se espera que crecerá con los años. Se estima que para 2045, en un escenario conservador, la carga económica ascienda a 776 mil millones de dólares. De la carga económica mundial se identificó que Estados Unidos es el país que gasta más en el cuidado de la diabetes con 348 mil millones de dólares, lo que representa casi el 50% de la carga económica mundial, además también es el país con mayor gasto per cápita con 11,638 dólares. En el caso particular de México se reporta que alrededor de 12 millones de personas viven con diabetes, lo que representa una carga económica de 19 mil millones de dólares al año para el país, equivalente al 18% del gasto en salud (IDF, 2017).

La mejor manera que existe para controlar esta enfermedad es la medición de glucosa en sangre de manera rutinaria, con el fin de que los médicos puedan tener información con la cual decidir sobre el tratamiento de sus pacientes. Tradicionalmente, las mediciones de glucosa se hacen con ayuda de un glucómetro, una tira

reactiva y una lanceta. En algunos modelos el glucómetro mide milimol por litro (mmol/l) o miligramos por decilitro (mg/dl); un paciente controlado y en ayunas suele obtener niveles entre 70-160 mg/dl (4-6 mmol/l). Las guías clínicas para el tratamiento de la diabetes recomiendan diferentes frecuencias de mediciones para los diferentes tipos de pacientes; por ejemplo, en la guía clínica de la American Diabetes Association (ADA, 2019) se recomienda que los pacientes que estén bajo un tratamiento de múltiples inyecciones diarias de insulina se midan la glucosa antes de cada comida, antes de dormir, antes de hacer ejercicio, cuando sospechen de hipoglucemia, luego de tratarse la hipoglucemia y antes de manejar un automóvil o maquinaria pesada. En los últimos años han surgido nuevas tecnologías para el manejo de la diabetes, una de ellas es el Monitoreo Continuo de Glucosa (MCG). La tecnología consta de un sensor en forma de aguja que va por debajo de la piel (usualmente en el abdomen o brazo); un transmisor, el cual es un dispositivo de plástico conectado al sensor que almacena las mediciones obtenidas por éste, y un receptor, el cual recibe los registros almacenados del transmisor y le muestra al paciente su glucosa en sangre al momento, así como tendencias y registros históricos. Dependiendo del fabricante y el modelo de los sensores, estos pueden variar en la precisión de las mediciones, duración de los sensores, frecuencia de los registros de glucosa (cada 5 minutos usualmente) y la información que los receptores le otorgan al usuario. La guía de la American Diabetes Association (ADA, 2019) recomienda el uso de esta tecnología a pacientes con DM1 o DM2 insulín dependientes.

El objetivo de este trabajo es proponer un algoritmo que utilice los registros de glucosa en sangre que provee el MCG para predecir los niveles futuros de glucosa cada 5 minutos con el fin de alertar a los pacientes cuando la predicción indique niveles fuera de control y prevenir complicaciones agudas como la hipoglucemia.

Para lograr nuestro objetivo se proponen cuatro variantes del algoritmo de predicción continua propuesto por Yang *et al.* (2018). La medición del desempeño de las cuatro variantes se hizo a través del uso de datos de pacientes que utilizaron MCG, en condiciones de vida diaria en Estados Unidos y recolectados por el Centro de Investigación Jaeb Center for Health Research (JCHR) en el ensayo clínico titulado *A randomized clinical trial to assess the efficacy of real-time continuous glucose monitoring in the management of type 1 diabetes*.

Nuestros resultados indican que el algoritmo propuesto puede pronosticar con más de 20 minutos de anticipación cuando los niveles de glucosa de un paciente están propensos a descontrollarse; en particular, para prevenir eventos de hipoglucemia. El algoritmo tarda en promedio menos de un segundo en hacer el pronóstico de los niveles de glucosa; además, obtuvo resultados prometedores al prevenir hasta el 99% de los eventos de hiperglucemia en los casos que se estudiaron.

El resto de este capítulo está compuesto por cuatro secciones adicionales. En la sección 2 se hace una breve revisión bibliográfica de los trabajos que pronostican niveles de glucosa en la sangre, con especial énfasis en el trabajo de Yang *et al.* (2018), del cual se deriva nuestro algoritmo propuesto. La sección 3 presenta variantes del algoritmo de Yang *et al.* (2018) que produce pronósticos más precisos comparados con los ya existentes en la literatura, además de presentar conceptos básicos de la metodología de Box y Jenkins. La sección 4 presenta los resultados del análisis de un paciente ejemplo y de 120 pacientes que nos permiten realizar el análisis comparativo de nuestra propuesta con la de Yang *et al.* (2018). La sección 5 presenta las conclusiones y algunas recomendaciones.

2. Revisión de literatura

Los modelos usados para pronosticar los niveles de glucosa que se registran en la literatura usan las siguientes técnicas: redes neuronales artificiales (RNA), aprendizaje automático, técnicas mixtas / multi-modelo y series de tiempo (Oviedo *et al.*, 2017).

Pérez-Gandía *et al.* (2010) y Fernández de Canete *et al.* (2012) usaron un modelo de RNA para pronosticar los niveles futuros de glucosa; los primeros usaron sólo los datos históricos del MCG, mientras que los segundos además usan el modelo para identificar la dinámica del paciente y la regulación glicémica basada en los datos de MCG y las dosis de insulina. Por su parte, los modelos de aprendizaje automático, en los que se incluyen los bosques aleatorios (ver los trabajos de Georga *et al.*, 2015 e Hidalgo *et al.*, 2017) y los algoritmos de máquina de vectores de soporte (Georga *et al.*, 2015), han sido usados con múltiples entradas, como los datos históricos de los niveles de glucosa, la concentración de insulina y la ingesta de alimentos. También se han propuesto modelos de múltiples / técnicas mixtas combinados con métodos lineales y no lineales para pronosticar hipo/hiperglucemia (ver, por ejemplo, Botwey *et al.*, 2014 y Zarkogianni *et al.*, 2015).

Si bien es cierto que los modelos de múltiples entradas (ingesta de medicina y alimentos, niveles de insulina, actividad física del paciente y otras) ayudan a entender la causa y mejorar el pronóstico de los niveles futuros de glucosa en la sangre, el incremento en la precisión del pronóstico no es realmente significativo (Doherty y Greaves, 2015). Por el contrario, debido a que el proceso de recopilación de los datos de esas entradas depende en gran medida de las mediciones subjetivas proporcionadas por el paciente que usa el dispositivo de MCG y dado que pudiera no ser un profesional de la salud, los datos pueden ser inexactos y tener errores. Por lo tanto, la aplicación de estos modelos se complica debido a la dificultad que representa la

recopilación sistemática de las entradas. De estas limitaciones surgen aplicaciones de modelos de series de tiempo univariados para pronosticar de manera eficiente los niveles futuros de glucosa en la sangre sólo en función de información histórica.

Dentro de la aplicación de modelos univariados de series de tiempo está el trabajo de Sparacino *et al.* (2007), quienes, mediante el uso de un modelo AR(1), pronostican los niveles futuros de glucosa de 28 pacientes con DM1. Gani *et al.* (2010) proponen un modelo AR(30) para pronosticar los niveles de glucosa en 9 pacientes. El orden del modelo AR en estas aplicaciones se determinó por la precisión del pronóstico. Por su parte, Eren-Oruklu *et al.* (2009), pronostican eventos de hiperglucemia o hipoglucemia mediante la propuesta de un modelo adaptativo basado en el modelo $ARMA_{(p,q)}$. El orden del modelo se estableció mediante el criterio de información de Akaike (AIC), mientras que para capturar rápidamente las alteraciones glucémicas imprevistas y proporcionar una respuesta rápida a tales condiciones, se integró el algoritmo de mínimos cuadrados recursivos con método de detección de cambios. Dentro de la aplicación de modelos $ARIMA(p,d,q)$ se encuentran los trabajos de Ootom *et al.* (2015) quienes proponen un modelo $ARIMA(3,0,0)$ para pronosticar los niveles de glucosa en la sangre de 81 pacientes cuyas mediciones de glucosa se tomaron durante 24 horas en periodos de 1 minuto. Boiroux *et al.* (2012) establecen un modelo de control predictivo para pronosticar eventos de hipoglucemia o hiperglucemia con base en un modelo ARIMA en pacientes con DM1. Cabe mencionar que los modelos de series de tiempo arriba mencionados mantienen valores de p , d y q fijos.

Debido a que nuestro algoritmo para pronosticar los niveles de glucosa se basa en cuatro variantes del algoritmo de predicción continua propuesto por Yang *et al.* (2018), el trabajo de estos autores se revisa con mayor detenimiento en esta sección.

Yang *et al.* (2018) observaron que la relación entre la longitud y la estacionariedad de los datos de las MCG sugiere la no estacionariedad de éstos en el corto plazo, lo que podría explicarse por las actividades de vida cotidiana de los pacientes (ingesta de alimentos, la inyección de insulina, el ejercicio físico, entre otros). También observan que las MCG tienden a volverse estacionarias en el largo plazo, posiblemente debido a la regularidad de las actividades de vida diaria de los pacientes, concluyendo de esta forma, que la estacionariedad de las MCG varía con el tiempo. A partir de este comportamiento observado en las MCG, los autores sugieren el uso de modelos $ARIMA(p, d, q)$, con órdenes adaptativos, debido a que la diferenciación de las MCG cambia dependiendo de la estacionariedad de los datos en el tiempo.

El algoritmo propuesto por Yang *et al.* (2018) se resume como sigue:

Entrada: Valores de las MCG, N_w , p_l , p_m , q_l y q_m

Salida: Modelo óptimo para la realización a considerar

- Paso 1: Denote por k el instante actual de la realización del proceso de MCG $\{Z_k - N_w + 1, Z_k - N_w + 2, \dots, Z_k\}$
- Mediante la prueba de raíces unitarias de Dikey-Fuller Aumentada (DFA) se determina el número de diferencias (d_k^*) que se debe aplicar a las MCG
- Estimar mediante el Método de Mínimos Cuadrados Ordinarios (MMCO) los parámetros de todos los modelos $ARIMA(p, d, q)$, con $p_l \leq p \leq p_m$ y $q_l \leq q \leq q_m$
- Calcular el valor del Criterio de Información de Akaike (AIC) de todos los modelos $ARIMA(p, d_k^*, q)$ considerados en el paso anterior
- Determinar el orden óptimo (p_k^*, d_k^*, q_k^*) y estimar los parámetros del modelo ARIMA que resultó con el AIC mínimo.

- Una vez determinado el orden óptimo y estimados los parámetros, se pronostican los niveles de glucosa en la sangre.
- Actualizar k por $k+1$ y regresar al primer paso.

De acuerdo con este algoritmo, el valor de N_w y los rangos del orden del modelo $[p_l, p_m]$ y $[q_l, q_m]$ se determinaron con un grupo de entrenamiento de 10 personas con diabetes, 5 con DM1 y 5 con DM2. Mediante el uso de la Suma de Cuadrados de los Errores de Predicción de la glucosa (SCEP) y la Desviación Relativa Absoluta (DRA) y usando diferentes longitudes de las realizaciones de los MCG ($N_w = 50, 100, \dots, 1000$) se determinó que el valor óptimo para $N_w = 400$ y los rangos del orden $[p_l, p_m]$ y $[q_l, q_m]$ son $[1, 7]$ y $[1, 3]$ respectivamente.

Finalmente, Yang *et al.* (2018) proponen una alarma de hipoglucemia temprana bajo el siguiente criterio: Sean t_i y y_j el tiempo actual y el nivel de glucosa en la sangre, respectivamente. Entonces, si $y_{j-1} > 3.9 \frac{\text{mmol}}{\text{L}}$, $y_j \leq 3.9 \frac{\text{mmol}}{\text{L}}$, $y_{j+1} \leq 3.9 \frac{\text{mmol}}{\text{L}}$ y $y_{j+2} \leq 3.9 \frac{\text{mmol}}{\text{L}}$, esto es, si tres mediciones continuas de glucosa en la sangre son menores o iguales a $3.9 \frac{\text{mmol}}{\text{L}}$ se emitirá una alarma de hiperglucemia; la alarma durará hasta que $y_{j+k} > 3.9 \frac{\text{mmol}}{\text{L}}$ para algún entero $k > 2$.

Las propuestas encontradas en la literatura sobre la aplicación de modelos $ARIMA(p, d, q)$ para pronosticar los niveles de glucosa en la sangre presentan las siguientes características en común: (i) Uso de una transformación para estabilizar la varianza, (ii) se le da más relevancia a los últimos niveles de glucosa registrados sobre los más antiguos, (iii) se toma en cuenta que la dinámica de la glucosa cambia a lo largo del tiempo, (iv) se asume que el comportamiento de la glucosa es diferente entre individuos, (v) en los trabajos en donde se propone una alarma temprana de hipoglucemia, se usan pronósticos puntuales y no por intervalos y (vi) aunque la mayoría habla de usar el modelo óptimo para


realizar el pronóstico, ninguno menciona explícitamente la verificación de los supuestos del modelo $ARIMA(p,d,q)$.

3. Propuesta de variantes al algoritmo de Yang y metodología básica de series de tiempo

En esta sección se describe mediante un diagrama de flujo el algoritmo propuesto para realizar el pronóstico de la medición continua de glucosa en la sangre. El algoritmo de predicción continua de glucosa descrito en la Figura 1 propone el uso de una transformación que establezca la varianza de los datos; dar más importancia a la información proveniente de los últimos datos registrados y tomar en cuenta el cambio de la dinámica a través del tiempo y entre individuos, característica que es implementada por medio de una actualización de parámetros y de los valores (p,d,q) con cada registro nuevo. Además, basado en la metodología propuesta por Box & Jenkins (1970), el algoritmo se asegura de que los modelos $ARIMA(p,d,q)$ seleccionados cumplan con los supuestos, como sigue: media de los residuales estimados iguales a cero; residuos descritos por un proceso de ruido blanco; raíces de los polinomios de rezago fuera del círculo unitario; polinomios de rezago sin factores aproximadamente comunes y el principio de parsimonia.

La predicción continua consiste en aplicar el algoritmo descrito en la Figura 1 cada que haya un nuevo registro de glucosa, en este trabajo cada 5 minutos. Tal y como se indica en el algoritmo, el primer paso es identificar los datos que se analizarán con el fin de darle más relevancia a la información más reciente, el algoritmo se aplicará a los datos registrados en un último periodo definido, es decir, si el periodo elegido es la última hora, entonces los datos que se analizarán en el instante de tiempo k son la realización de $\{y_{k-11}, y_{k-10}, \dots, y_k\}$, donde y_t es el nivel de glucosa en el instante t .

Figura 1. Diagrama de flujo del algoritmo propuesto.



Para decidir el tamaño de la realización se aplicará el mismo criterio que en Yang *et al.* (2018), el cual consiste en elegir un paciente que cumpla con las siguientes características: (i) edad entre los 19 y 25 años, (ii) alrededor de 1.65 cm de estatura, (iii) aproximadamente de 65 Kg. de peso, (iv) raza no hispanica o latina y (v) con un nivel de Alc mayor a 7%. El algoritmo se aplicará a los datos de este paciente variando el tamaño de la

realización del proceso de los últimos niveles de glucosa, desde 1 hasta 26 horas de mediciones. Por último, se calcula la Raíz del Error Cuadrático Medio (RECM) y el Error Absoluto Medio (EAM) de las predicciones de glucosa a 30 minutos y se elegirá un tamaño de realización (N_m) que asegure la convergencia de las predicciones a su óptima precisión.

$$RECM = \sqrt{\frac{1}{N-N_m-5} \sum_{t=N_m+6}^N (y_t - \widehat{y}_t)^2}$$

$$EAM = \frac{1}{N-N_m-5} \sum_{t=N_m+6}^N |y_t - \widehat{y}_t|$$

donde N es el número total de mediciones de glucosa del paciente, N_m es el número de mediciones de la realización seleccionado, y_t es la medición real de la glucosa en el instante t y $\widehat{y}_t$ la predicción para dicha medición de glucosa. Es importante enfatizar que se “pierden” cinco mediciones de glucosa debido a que las predicciones son a 30 minutos y las mediciones tienen una frecuencia de cinco minutos.

El siguiente paso en el algoritmo es estabilizar la varianza. El método elegido para lograr dicho objetivo es el de Guerrero (1993). Es importante mencionar que la realización del proceso tendrá un tamaño N_m múltiplo de 12 mediciones de glucosa, esto debido a que el análisis que se hará para definir N_m variará el tamaño de la realización en periodos de horas (de 1 a 26). Entonces, siguiendo la sugerencia del número mínimo de posibles grupos homogéneos, la realización del proceso se dividirá en dos grupos de $N_m/2$ datos. Finalmente, siguiendo Guerrero (2003) se elige la transformación de las mediciones de glucosa que estabiliza su varianza.

Para estabilizar el nivel de las mediciones de glucosa se usarán dos métodos. El primero es el recomendado por Dickey *et al.* (1986), el cual consiste en aplicar pruebas aumentadas de raíces

unitarias de Dickey-Fuller (ADF) sucesivamente. La prueba de hipótesis a probar es la siguiente:

$$H_0: \phi_p(B)\nabla T(y_t) = \theta_q(B)a_t$$

vs.

$$H_a: \phi_p(B)(1 - \rho B)(T(y_t) - \mu) = \theta_q(B)a_t, \text{ con } |p| < 1$$

Donde $T(y_t)$ son las mediciones de glucosa transformadas para estabilizar su varianza, B es el operador de retraso que se define mediante la relación $By_t = y_{t-1}$ para todo instante de tiempo t . Por la aplicación sucesiva del operador B se obtiene $B^2y_t = B(By_t) = By_{t-1} = y_{t-2}$, así que, en general, se obtiene la siguiente expresión $B^ky_t = y_{t-k}$ para $k = 0, 1, 2, \dots$ y toda t . $\nabla = 1 - B$ es el operador diferencia, de tal manera que $\nabla^0y_t = y_t, \nabla y_t = y_t - y_{t-1}, \nabla^2y_t = \nabla(\nabla y_t) = \nabla(y_t - y_{t-1}) = y_t - 2y_{t-1} + y_{t-2}$ y así sucesivamente. Por lo tanto, $\nabla^d y_t$ denota la diferencia de orden d de $\{y_t\}$, con d un entero positivo. $\theta_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ y $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ son los operadores autorregresivos de orden p y de promedios móviles de orden q , respectivamente. $\{a_t\}$ es una sucesión de variables aleatorias independientes cuya media es constante y su varianza se denota por σ_a^2 .

Si no se rechaza la hipótesis nula (H_0), entonces las mediciones de glucosa necesitan al menos una diferenciación más para estabilizar su nivel.

El segundo método es el sugerido por Anderson (1976). Por lo tanto, el valor inicial de d será el que minimice la siguiente expresión

$$S^2(d) = \frac{1}{N-d-1} \sum_{t=d+1}^N \left[\nabla^d T(y_t) - \sum_{t=d+1}^N \frac{\nabla^d T(y_t)}{(N-d)} \right]^2, \text{ para } d = 0, 1, 2, 3 \text{ y.}$$

$$N = N_m$$

Posteriormente, se probará la hipótesis nula de raíces unitarias a la serie $w_t = \nabla^d T(y_t)$ aumentando el valor de d de uno en uno hasta rechazar H_0 .

Igual que para la estabilización del nivel de las mediciones de glucosa, para la selección del orden de los modelos $ARMA(p,q)$, también se consideran dos métodos, los cuales están basados en el principio de parsimonia. Esto es, este principio busca reducir el número de parámetros al mínimo posible.

El primer método sigue la siguiente estrategia. Paso 1: si $d = 0$ se debe contemplar la constante de nivel (μ) en todos los modelos que se propongan, en caso contrario no considerar dicha constante. Paso 2: Fijar $p = 0$, $q = 0$, $maxp = 7$ y $maxq = 3$. Paso 3: Estimar los parámetros del modelo $ARMA(p,q)$ y verificar sus supuestos. Si se cumplen los supuestos, el modelo seleccionado será $ARMA(p,q)$, en caso contrario continuar con el siguiente paso. Paso 4: Si $p = maxp$ y $q = maxq$, el modelo seleccionado será aquél con mínimo Criterio de Información de Akaike (AIC) entre todos los que se hayan analizado, de lo contrario, continuar con el siguiente paso. Paso 5: Actualizar los valores (p,q) según corresponda y regresar al Paso 3.

La actualización de los valores (p,q) en el Paso 5 seguirá el orden que se presenta en la matriz de la Figura 2; se irá incrementado de uno en uno el número total de parámetros a estimar. Dependiendo de la celda en turno, p será igual al valor de la fila menos uno y q igual al valor de la columna menos uno.

Figura 2. Orden de actualización de los valores (p,q) .

$q = \text{número de columna} - 1$

	1	3	6
$p = \text{número de fila} - 1$	2	5	9
	4	8	12
	7	11	15
	10	14	18
	13	17	20
	16	19	21

En caso de que ningún par de valores (p,q) cumpla con los supuestos, el criterio para elegir el modelo, así como los valores límite $maxp$ y $maxq$ (las dimensiones de la matriz) será el propuesto por Yang *et al.* (2018). Finalmente, es importante notar que en el paso 1 se toma en cuenta la constante de nivel (μ) cuando $d=0$ debido a que la glucosa de los pacientes con diabetes suele oscilar alrededor de un promedio en el largo plazo (niveles de A1c). Sin embargo, la alta frecuencia de las mediciones requerirá de al menos una diferenciación para estabilizar su nivel, haciendo que los niveles de glucosa oscilen alrededor de cero, indicando con esto que es necesario incluir la constante de nivel.

El segundo método para encontrar el orden del modelo $ARMA(p,q)$, además de basarse en el principio de parsimonia, tomara en cuenta el comportamiento de los niveles de glucosa a través de analizar la Función de Autocorrelación (FAC) y la Función de Autocorrelación Parcial (FACP). Siguiendo a Guerrero (2003) sección 4.1.5, se reproduce la Tabla 1 que resume las características de la FAC y FCAP del proceso $w_t = \nabla^d T(y_t)$.


Tabla 1. Comportamiento de la FAC y FACP para procesos AR, MA y ARMA

Proceso	FAC	FACP
AR(p)	Convergencia a cero, con comportamiento indicado por $\phi(B)\rho_k$, para $k \geq p$	Sólo las primeras p auto-correlaciones parciales son distintas de cero
MA(q)	Sólo las primeras q auto-correlaciones son distintas de cero	Sucesión infinita convergente a cero
ARMA(p,q)	Comportamiento irregular de las primeras q autocorrelaciones y después convergencia a cero de acuerdo con $\phi(B)\rho_k$, para $k \geq q$	Sucesión infinita convergente a cero

La idea de este método es primeramente evaluar cuál de las dos funciones tiene una convergencia más lenta a cero. Para esto se compara el número de autocorrelaciones y autocorrelaciones parciales muestrales que sean diferentes de cero. En caso de ser la FAC la que converja más lento, se asume que el proceso apropiado para modelar los niveles de glucosa es un $AR(p)$, ya que la FAC converge a cero y solo las primeras p autocorrelaciones parciales son distintas de cero. En caso de ser la FACP muestral la que converja más lento, se asumirá que el proceso de los datos puede ser $MA(q)$ o $ARMA(p,q)$, ya que la FACP es una sucesión infinita convergente a cero. Luego, siguiendo el principio de parsimonia, se elegirá el modelo que contenga menos parámetros. De esta manera, dependiendo del comportamiento de FAC y FACP muestral, se elegirá un modelo inicial.


Una vez elegido el modelo inicial que se usará como modelo pivote, se procederá a la verificación de supuestos siguiendo la estrategia del primer método, pero sólo sobre los modelos vecinos al modelo pivote y no sobre todo el universo de modelos. Por ejemplo, sean los valores pivote $p=2$ y $q=1$ los modelos que se evaluarán serán los siguientes y en el siguiente orden, tal y como se muestra en la Figura 3:

Figura 3. Evaluación de modelos vecinos al modelo pivote.



Igual que en el primer método, si se encuentra un modelo que cumpla con los supuestos, este será seleccionado y en caso contrario se elegirá el que tenga mínimo AIC sobre los modelos evaluados. En caso de que se elija el modelo con mínimo AIC, entonces este será el nuevo modelo pivote y se procederá a evaluar los modelos vecinos de este que no se hayan evaluado anteriormente. Por ejemplo, supongamos que en los primeros nueve modelos evaluados no se encontró ninguno que cumpliera los supuestos y el que tiene mínimo AIC es $p=3$ y $q=1$, entonces los siguientes modelos a evaluar serían los que se muestra en la Figura 4.

Figura 4. Evaluación de modelos vecinos al seleccionado en la iteración pasada.



De esta manera se seguirán evaluando modelos hasta encontrar alguno que cumpla los supuestos o haber evaluado los 21 modelos posibles y entonces se seleccionará aquél con mínimo AIC del universo completo de modelos. En caso de que en alguna iteración todos los vecinos del nuevo pivote ya se hayan evaluado, se seleccionará el siguiente modelo con mínimo AIC y así sucesivamente hasta encontrar un nuevo pivote que tenga vecinos sin evaluar. Por último, en caso de que todos los modelos analizados en la iteración pasada tengan sus vecinos ya evaluados, se elegirá al azar un modelo que no haya sido evaluado como nuevo pivote.

Es importante mencionar que mientras el primer método asegura el principio de parsimonia, el segundo es más eficiente para encontrar de manera más rápida un modelo que se ajuste a las mediciones de glucosa, puesto que hace uso de las funciones FAC y FACP muestrales. Finalmente, estos dos métodos para la selección de los valores (p,q) sumados a los dos métodos para estabilizar el nivel de las mediciones de glucosa, hacen que el algoritmo propuesto en la Figura 1 tenga cuatro variantes, las cuales se resumen en la Tabla 2.

Tabla 2. Variantes del algoritmo de predicción continua.

Método	Iniciar con $d=0$	Iniciar con $d = \operatorname{argmin}(S^2(d))$
Seleccionar modelo más parsimonioso.	I	II
Seleccionar modelo con base en el uso de la FAC y FACP	III	IV

La estimación de los parámetros del modelo $ARIMA(p,d,)$ seleccionado se realizará mediante el método de máxima verosimilitud. Para encontrar los parámetros óptimos se utilizará la función $ARIMA$ del paquete descrito en Hyndman *et al.* (2019), esta función encuentra los estimadores $\widehat{\phi}_p(B)y\widehat{\theta}_q(B)$ por medio del método de búsqueda propuesto por Nelder y Mead (1965) y utiliza como valores iniciales los estimadores con Error Cuadrático Medio (ECM) mínimo $(\widehat{\phi}_{pECM}(B)y\widehat{\theta}_{qECM}(B))$.

Luego de haber elegido el modelo y estimar sus parámetros, este será utilizado para pronosticar los niveles de glucosa. Con este fin, también se utilizará el paquete detallado en Hyndman *et al.* (2019) el cual contiene la función *forecast*. Una de las características de la función *forecast* es que modifica los vectores y matrices de las ecuaciones del sistema dinámico lineal para tomar en cuenta la aplicación del operador ∇ y así aplicar el algoritmo descrito en Harvey y McKenzie (1982) para realizar predicciones de las mediciones originales de glucosa.

El último paso del algoritmo propuesto en la Figura 1 es la prevención de eventos de hipoglucemia que se basa en la propuesta de alarma de Yang *et al.* (2018). A diferencia de este

trabajo en el que las medidas de glucosa fueron cada 3 minutos y estuvieron medidas en mmol/l, las nuestras son cada 5 minutos y están medidas en mg/dl.

Para identificar los eventos de hipoglucemia de los pacientes se siguen tres pasos: Primero, sea y_t el t -ésimo registro de glucosa, se considera que un paciente tuvo un evento de hipoglucemia en el tiempo de registro t si $y_{t-1} > 70 \frac{mg}{dl}$, $y_t \leq 70 \frac{mg}{dl}$ y $y_{t+1} \leq 70 \frac{mg}{dl}$, esto es, si el sensor de MCG registró que el paciente tuvo niveles bajos de glucosa por lo menos durante 10 minutos. Segundo, debido a la gran variabilidad de la glucosa, la cual podría cruzar de manera ascendente o descendente los $70 \frac{mg}{dl}$ de manera continua, se supondrá como un mismo evento de hipoglucemia a aquellos eventos continuos que tengan solo un registro por arriba de los $70 \frac{mg}{dl}$ de separación. Finalmente, luego de juntar los eventos continuos de hipoglucemia, se supondrá una duración máxima por evento de una hora, por lo que, si un evento dura más de 12 registros, este será dividido en $N_E = \left\lceil \frac{N_h}{12} \right\rceil$ eventos con una duración de 60 minutos para los primeros $N_E - 1$ eventos y una duración de $(N_h - N_E * 12) * 5$ minutos para el último evento, donde N_h es el número total de observaciones en hipoglucemia.

Ahora, utilizando los pronósticos puntuales de hipoglucemia, sea $\hat{y}_t(6)$ el pronóstico a 6 observaciones (30 minutos) realizadas en el tiempo de registro t , se le mandará una alarma de hipoglucemia al paciente en el tiempo de registro $t+1$ si $\hat{y}_{t-1}(6) > 70 \frac{mg}{dl}$, $\hat{y}_t(6) \leq 70 \frac{mg}{dl}$ y $\hat{y}_{t+1}(6) \leq 70 \frac{mg}{dl}$; esto es, si dos pronósticos consecutivos se encuentran en rangos de hipoglucemia. La alarma durará hasta que $\hat{y}_{t+k}(6) > 70 \frac{mg}{dl}$, para algún entero $2 \leq k \leq 13$, en el caso de que se hayan pronosticado niveles de hipoglucemia durante una hora, es decir, $\hat{y}_{t+k}(6) \leq 70 \frac{mg}{dl}$ para $k \in \{2, 3, \dots, 13\}$, se considera el tiempo de registro $t+13$ como el inicio de una nueva alarma. Es

importante notar que, aunque se realizan pronósticos a 30 minutos, la alarma se estará mandando 25 minutos antes del evento.

Una aportación más de nuestra propuesta es que a diferencia de los trabajos revisados en la literatura que solo producen pronósticos puntuales, el nuestro produce pronósticos por intervalos. Por lo tanto, se propone implementar la estrategia descrita en el párrafo anterior, pero utilizando el límite inferior del intervalo de confianza del pronóstico. Esto es, sea $L_{t,a}(6)$ el límite inferior del intervalo del $100(1 - \alpha)\%$ confianza del pronóstico a 6 observaciones realizado en el tiempo de registro t , entonces se enviará una alarma de hipoglucemia al paciente en el tiempo de registro $t+1$, si $L_{t-1,a}(6) > 70 \frac{mg}{dl}$, $L_{t,a}(6) \leq 70 \frac{mg}{dl}$ y $L_{t+1,a}(6) \leq 70 \frac{mg}{dl}$ esto es, si dos intervalos consecutivos contienen rango de hipoglucemia. Igual que en las estimaciones puntuales, se asumirá una duración máxima de una hora por alarma. Es importante notar que el uso de intervalos de confianza podría aumentar los minutos de anticipación en enviar una alarma, que se logran con las predicciones puntuales.

Para analizar la eficiencia de las alarmas se utilizará el mismo criterio que en Yang *et al.* (2018). Se clasificarán en tres tipos: (i) Verdaderos positivos (VP), cuando una hipoglucemia ocurra hasta 60 minutos después de que la alarma se active. (ii) Falsos positivos (FP), si no ocurre una hipoglucemia luego de 60 minutos de que se active la alarma. (iii) Falsos negativos (FN), si ocurre un evento de hipoglucemia, pero no se activó ninguna alarma. Posteriormente se calcularán las razones de sensibilidad (S) y proporción de falsa alarma (%FA)

$$S = \frac{\#VP}{\#VP + \#FN}, \%FA = \frac{\#FP}{\#FP + \#VP}$$

4. Análisis de resultados

Como ya lo indicamos, para medir el desempeño de las cuatro variantes del algoritmo propuesto, se usaron los datos de pacientes que utilizaron MCG. Estos datos fueron recolectados en Estados Unidos, en condiciones de vida diaria, por el centro de investigación *Jaeb Center for Health Research (JCHR)* en un ensayo clínico titulado *A randomized clinical trial to assess the efficacy of real-time continuous glucose monitoring in the management of type 1 diabetes*¹. El objetivo del ensayo fue evaluar si el uso del MCG influye en la reducción de hemoglobina glucosilada (HbA1c)² en pacientes con DM1; los resultados de los estudios fueron publicados por JDRF (2008 y 2009).

La base de datos publicada por el JCHR es extensa; contiene información sobre 444 pacientes que completaron la primera fase del estudio (26 semanas) y 436 pacientes que completaron la segunda fase del estudio (segundas 26 semanas). De los 444 pacientes que completaron la primera fase, 229 utilizaron MCG para la medición de glucosa, mientras que los otros 215 utilizaron glucómetro. Ahora, de los 229 pacientes que utilizaron MCG, el 54% utilizó un sensor que registra la glucosa cada 5 minutos, mientras que el otro 46% utilizó un sensor con frecuencia de medición de cada 10 minutos. El grupo de pacientes que se analiza en el presente trabajo consta del 54% de pacientes que utilizaron MCG con una frecuencia en los registros de glucosa de 5 minutos y reportados en mg/dl, los cuales provienen de una población con las características descritas en las Tablas 3 y 4

-
- 1 Los datos y el protocolo de ensayo pueden ser descargados en http://diabetes.jaeb.org/RT_CGMRCTProtocol.aspx
 - 2 La medición de la HbA1c es una prueba de laboratorio utilizada para saber si el control que realiza el paciente sobre su enfermedad ha sido bueno durante los últimos tres o cuatro meses.

Tabla 3. Características de los pacientes

Variable	Promedio	Mediana
Edad	25	19
Altura en cm	165	166
Peso en Kg.	66	65
Años con DM1	15	11
A1C	7.4%	7.3%

Tabla 4. Características de los pacientes

Variable	Categoría	No. de pacientes	% de pacientes
Tipo de DM	Tipo 1	124	100%
Edad	≥ 18	65 59	52% 48%
Raza	Blanca Más de una raza Desconocida	118 4 2	95% 3% 2%
Etnia	No hispánica o latina Hispánica o latina Desconocida	113 7 4	91% 6% 3%
Género	Femenino Masculino	71 53	57% 43%
A1c	< 7%	84 40	68% 32%


Esta población se compone de pacientes con DM1; casi el 50% de ellos son menores de edad y mayoritariamente son de raza blanca no hispánica o latina. La edad promedio es de 25 años, mientras que la mediana es de 19, lo que indica una distribución sesgada a la derecha. Este fenómeno se puede explicar si se toma en cuenta que la esperanza de vida de un paciente con DM1 es de 57 años para hombres y 61 años para mujeres³. El peso y estatura promedio de los pacientes son menores a los promedios de la población de raza blanca no hispánica en EUA⁴, esto se debe al padecimiento de la diabetes desde la infancia, como se explica en Khadilkar *et al.* (2013). La duración de la enfermedad en los pacientes con diabetes es de 15 años en promedio, lo que sugiere que la mayoría fueron diagnosticados durante su infancia, alrededor de los 10 años. Por último, la mayoría tiene niveles de glucosa en descontrol con un nivel de A1C mayor a 7%.

Con el fin de explicar el algoritmo de predicción continua, propuesto en la sección 3, se tomaron los datos de un paciente ejemplo con las siguientes características: edad 24 años, género femenino, raza blanca, etnia no hispánica o latina, altura en centímetros 166, peso en kilogramos 69, niveles de Alc 7.7% y 13 años de padecer DM1. En la Figura 5 se muestran tres días de registros de glucosa del paciente ejemplo.

3 Cifras reportadas por *The Global Diabetes Community* <https://www.diabetes.co.uk/diabetes-life-expectancy.html>


4 En Fryar *et al.* (2018) se reporta un peso promedio de 91.7 Kg y 77.5 Kg para hombres y mujeres respectivamente, y altura promedio de 177.4 cm y 163.3 cm.

Figura 5. Tres días de registros de niveles de glucosa en la sangre del paciente ejemplo.



Las mediciones de glucosa se analizaron para definir el número de últimos registros (N_m) necesarios para asegurar la optimización de la precisión de las predicciones a 30 minutos; el algoritmo se aplicó a realizaciones del proceso de distinto tamaño para pronosticar las últimas 24 horas de registros (13:37 horas del 21 de marzo a las 13:32 horas del 22 de marzo). La Figura 6 muestra las medidas de precisión *RECM* y *EAM* de los pronósticos estimados por las 4 variantes del algoritmo, donde el eje de las abscisas representa el número de horas de los últimos registros utilizados por el algoritmo y el eje de las ordenadas es el valor de las medidas de precisión.

Figura 6. Medidas de precisión por tamaños de realización N_m




En la Figura 6 se observa que, independientemente de la variante del algoritmo, a las 12 horas de datos se estabiliza la precisión de los pronósticos, esto es, el decrecimiento en las medidas de precisión ya no representa una mejoría relevante. Por lo tanto, el periodo de últimos registros de glucosa elegido fue de 12 horas, es decir, al momento de aplicar el algoritmo, este analizará los últimos 144 datos registrados. Es importante aclarar que este resultado se utilizó para definir el periodo de datos a utilizar en general y no sólo para el paciente ejemplo.

El siguiente paso del algoritmo es estabilizar la varianza de las primeras 12 horas de mediciones de glucosa del paciente ejemplo; esto es, los registros de las 12:00 horas del 20 de marzo a las 00:00 horas del 21 de marzo que se muestran en la Figura 5. Si se observaran estas mediciones sin conocer el resto de la serie, se podría especular que la varianza tiende a crecer con el tiempo y por lo tanto se debería aplicar una transformación estabilizadora de la varianza; sin embargo, en la práctica no se podrán observar las mediciones que el algoritmo analiza. Por esta razón, a cada realización del proceso se le aplicó una transformación. Después de efectuar los cálculos necesarios para seleccionar el

parámetro λ de la transformación potencia, se observó que el Coeficiente de Variación se minimiza para $\lambda = -1$, por lo que la transformación que se aplicó a las mediciones de glucosa es $T(y) = 1 - \frac{1}{y}$, lo que provoca que los datos oscilen entre 0.98 y 1, en lugar de 50 y 250 en su escala original.

La estabilización de los niveles de glucosa se realizó mediante los dos métodos propuestos. El método de Dickey *et al.* (1986) aplicado a las mediciones transformadas, $T(y_i)$, sugiere que estas ya son estacionarias y toma $d = 0$. Por su parte, el método sugerido por Anderson (1976) sugiere que la varianza muestral de las mediciones transformadas, $S(d)$, alcanza su valor mínimo cuando se aplica a ∇^2 a las mediciones transformadas, es decir, la serie estacionaria está dada por $\nabla^2 T(y_i)$. La Figura 7 muestra las mediciones de glucosa estacionarias encontradas con los dos métodos propuestos.

Figura 7. Mediciones de glucosa del paciente ejemplo transformadas con la aplicación de ∇^d



La elección de los modelos $ARIMA(p,q)$ que cumplieron con todos los supuestos, se llevó a cabo mediante los dos métodos propuestos en la sección 3. El primer método consiste en seleccionar el modelo más parsimonioso, esto es comenzando con $p = 0$ y $q = 0$. El algoritmo realiza iteraciones hasta encontrar

todos los modelos posibles y seleccionar el que cumpla con todos los supuestos. En la variante I del algoritmo, que surge de aplicar este método a los datos transformados con $d = 0$, el algoritmo necesitó de 7 iteraciones para seleccionar un modelo; se incluyó la constante μ en todos los modelos debido a que $d = 0$. En la variante II del algoritmo, que surge de aplicar este método a los datos transformados con $d = 2$, esto es a $\nabla^2 T(y_i)$, el algoritmo solo requirió de una sola iteración ya que con $p = 0$ y $q = 0$ se cumplen todos los supuestos; es decir, se puede asumir que la serie de mediciones de glucosa transformadas, $\nabla^2 T(y_i)$, se comportan como ruido blanco. El modelo seleccionado con la variante I fue un $ARMA(3,0)$, mientras que con la variante II se seleccionó un $ARMA(0,0)$.

El segundo método para seleccionar los modelos $ARMA(p,q)$ que cumplieron con todos los supuestos hace uso de las FAC y FACP muestrales para elegir valores iniciales de (p,q) y, a partir de estos valores iniciales, inicia a iterar todos los modelos vecinos hasta encontrar uno que cumpla con los supuestos. La variante III del algoritmo que surge de aplicar este método a los datos transformados con $d = 0$, seleccionó el mismo modelo que la variante I; sin embargo, éste fue más eficiente ya que sólo requirió de 2 iteraciones en lugar de 7. Por otra parte, la variante IV del algoritmo que surge de aplicar este método a los datos transformados $\nabla^2 T(y_i)$, sólo se requirió de una sola iteración ya que con $p = 0$ y $q = 0$ se cumplen todos los supuestos, eligiéndose el mismo modelo que seleccionó la variante II.

Los modelos seleccionados se usaron junto con las primeras 144 mediciones de glucosa del paciente ejemplo para realizar pronósticos a 30 minutos. Sean $\widehat{y}_{144}(6)$ los pronósticos a 30 minutos, $IC_{90\%}$ el intervalo de confianza del pronóstico de 90%, y_{150} el nivel real de glucosa que se pronostica y $e_{144}(6)$ el error entre el pronóstico y el nivel real de glucosa. Los resultados de este ejercicio se muestran en la Tabla 5.

Tabla 5. Pronósticos puntuales y por intervalos de los niveles de glucosa del paciente ejemplo

Modelo	$\widehat{y}_{144}(6)[IC_{90\%}]$	y_{150}	$ e_{144}(6) $
ARIMA (3,0,0)	199 [124,497]	236	37
ARIMA (0,2,0)	299 [127,23775]	236	63

Como se observa, el modelo *ARIMA*(3,0,0) obtuvo el menor error absoluto. Por otro lado, los intervalos de ambos modelos contienen al valor real, pero estos resultaron ser muy amplios, lo que podría dificultar su uso en la práctica. Sin embargo, esta fue la evaluación solo de la primera predicción. Este ejercicio será repetido 288 veces por paciente para evaluar los resultados de la predicción en un día completo, pues la alta variabilidad influye en la precisión de las predicciones. En el caso específico para este ejemplo, el ejercicio se repitió hasta utilizar todos los datos del paciente ejemplo, es decir, se hicieron 456 pronósticos a media hora, lo que es equivalente a pronosticar cada 5 minutos los registros desde el 21 de marzo a las 00:02 horas hasta las 13:27 del 22 de marzo. Los resultados de las medidas de precisión *EAM* y *RECM* que se muestran en la Tabla 6 se calcularon con $N = 456$ y $N_m = 144$. Ambas medidas de precisión indican que la variante II del algoritmo es la que obtiene pronósticos más precisos para predecir la glucosa del paciente ejemplo, esta variante es la que selecciona los valores más parsimoniosos de (p ; q). No obstante, aunque esta variante haya obtenido mejores resultados, no hay una diferencia considerable entre todas las variantes.


Tabla 6. Resultados de las medidas de precisión para las 4 variantes del algoritmo.

Variante	EAM	RECM
I	21.12	30.83
II	20.32	29.83
III	21.04	30.99
IV	20.57	31.14


La Figura 8 contiene las predicciones puntuales de cada variante y sus intervalos del 90% de confianza, de las cuales hay algunas observaciones a destacar. Primero, las predicciones puntuales de todas las variantes parecen ser acertadas, sin embargo, en las últimas 6 horas del 21 de marzo, las variantes II y IV tienen mejor desempeño. Segundo, los intervalos de confianza contienen a los valores reales casi durante todo el día y medio de predicciones, sin embargo, las variantes I & III lograron intervalos más estrechos. Tercero, la amplitud de los intervalos parece ser de 100 mg/dl o más, excepto en el último lapso con los niveles más bajos, donde los intervalos se vuelven más estrechos. Por último, transformar los datos provoca que, al momento de regresar las estimaciones a la escala original, los límites de los intervalos no tengan la misma distancia hacia la estimación puntual, más aún, los límites superiores parecen ser los causantes de la gran amplitud de los intervalos.

Figura 8. Pronósticos de las variantes del algoritmo a 30 minutos con $IC_{90\%}$


(a) Variante I




(b) Variante II



(c) Variante III



(d) Variante IV



A partir de esta última observación se decidió estudiar el caso de la aplicación de las 4 variantes del algoritmo, pero sin el paso de transformar los datos para estabilizar la varianza. Después de identificar las últimas 12 horas de registros se estabiliza el nivel con los registros sin transformar y luego se verificaron los supuestos. La Tabla 7 muestra las medidas de precisión de los pronósticos, mientras que la Figura 9 contiene las predicciones puntuales de cada variante y sus intervalos del 90% de confianza. Al omitir la transformación, la variante I resultó ser la más precisa, aunque con una diferencia casi nula


en comparación con la variante II. Por otro lado, al comparar las Tablas 6 y 7, el EAM no presenta cambios relevantes, pero el RECM sí lo hace, con un aumento entre 7 y 10 unidades, lo que indica una mejor precisión de los pronósticos puntuales cuando se usa la transformación para estabilizar la varianza. En relación con las estimaciones de los intervalos de confianza, la Figura 9 muestra una reducción notable en la amplitud de estos, a excepción del lapso con niveles bajos de glucosa, donde ocurre lo contrario. Por último, es importante mencionar que, independientemente de si se omite la transformación o no, sólo parece haber un cambio relevante en los resultados cuando se comparan las variantes con diferentes métodos para elegir d , mientras que los métodos para seleccionar los valores $(p; q)$ parecen obtener los mismos resultados.

Tabla 7. Resultados de las medidas de precisión para las 4 variantes del algoritmo sin transformación de los registros de glucosa

Variante	EAM	RECM
I_{st}	20.70	37.82
II_{st}	21.42	40.25
III_{st}	20.70	37.83
IV_{st}	21.40	31.14


El subíndice st hace referencia a que no se consideró la transformación de los datos.

Figura 9. Pronósticos de las variantes del algoritmo sin transformación de los niveles de glucosa a 30 minutos con $IC_{90\%}$



Para realizar los pronósticos de los niveles de glucosa y determinar eventos de hipoglucemia, se utilizó la variante II del algoritmo ya que fue la que obtuvo mejores resultados en la precisión de pronósticos. La Figura 10 muestra los datos reales de glucosa y sus pronósticos de las últimas 6 horas, lapso en el que se registró un evento de hipoglucemia; la línea roja está situada en 70 mg/dl, debajo de este valor se considera que el paciente tiene hipoglucemia.

Figura 10. Pronósticos, a 30 minutos de los niveles de glucosa del paciente ejemplo, mediante la variante II del algoritmo de predicción continua.



Como se puede observar, el sensor registró 76 mg/dl a las 9:32 horas seguido de dos valores por debajo o iguales a 70 mg/dl, por lo tanto, el evento de hipoglucemia ocurrió a las 9:37 horas. La hipoglucemia duró 25 minutos, puesto que a las 10:02 horas se registró 72 mg/dl y los niveles no volvieron a cruzar el límite marcado por la línea roja en la gráfica. Por otra parte, el algoritmo pronosticó el evento a las 9:27 horas con un valor de 29.76 mg/dl, dado que el pronóstico anterior fue de 127.54 mg/dl, mientras que el posterior fue de 27.68 mg/dl. Ahora, como el segundo pronóstico de hipoglucemia (9:32 horas) es el que confirma la predicción de un evento futuro, se mandó una

alarma a las 9:02 horas, la cual fue un verdadero positivo (VP) con un tiempo de reacción para el paciente de 35 minutos; esta alarma duró 50 minutos hasta que a las 9:52 horas se pronosticó un valor de 79.38 mg/dl para las 10:22 horas. Por último, como se observa en la gráfica, alrededor de las 11:00 horas se volvieron a pronosticar niveles de hipoglucemia, lo que ocasionó que se mandara una alarma a las 10:32 horas de una duración de 5 minutos, la cual fue considerada falso positivo (FP) debido a que no se registró otro evento en la hora siguiente al momento en que se mandó la alarma.

Los resultados obtenidos hasta ahora no pueden ser usados para plantear conclusiones respecto a toda la población de personas con diabetes, esto debido a que sólo se usaron los datos de un paciente ejemplo. A continuación, se describen los resultados del análisis para los datos de 120 pacientes; se descartaron 4 pacientes de los 124 originalmente considerados debido a que sus registros de glucosa no fueron suficientes para implementar el algoritmo y obtener predicciones durante un día entero. La muestra por analizar está compuesta de 120 realizaciones de mediciones con 438 registros de glucosa cada una. Los últimos 288 registros son las 24 horas de datos que se usaron para medir la precisión de los pronósticos, mientras que los primeros 150 registros son necesarios, ya que el algoritmo analiza 12 horas de registros (144 datos) y pronostica a 30 minutos (6 lapsos de 5 minutos), es decir, al elegir un modelo para los primeros 144 registros, la primera predicción se compara con el dato número 150, porque este fue registrado 30 minutos después.

Primero, se compararon todas las variantes del algoritmo propuesto, las 4 originales y 4 más sin tomar en cuenta la transformación de los datos y se eligió la más eficiente. Posteriormente, se comparó la versión más eficiente del algoritmo contra la propuesta de Yang *et al.* (2018).

En total, cada variante del algoritmo seleccionó 34560 modelos, uno cada 5 minutos durante 24 horas para cada uno de los 120 pacientes que se tomaron en cuenta, es decir, 288 modelos por paciente. La Tabla 7 contiene resultados en relación con las características de estos modelos y el tiempo requerido para calcularlos; los cálculos se hicieron en una Laptop ASUS S301LA con procesador Intel Core i5-4200U.

Tabla 8. Resultados de los modelos

Variante del algoritmo	Porcentaje de modelos que cumplen supuestos	Max. Mediana de número de parámetros ^a	Tiempo promedio del algoritmo ^b	Tiempo máximo del algoritmo ^c
I	98.8%	4	0.15 seg	06.81 seg
II	98.9%	5	0.20 seg	07.14 seg
III	99.0%	4	0.42 seg	27.14 seg
IV	98.9%	5	0.40 seg	17.65 seg
<i>I_{st}</i>	99.0%	3	0.13 seg	06.77 seg
<i>II_{st}</i>	99.2%	3	0.12 seg	09.51 seg
<i>III_{st}</i>	99.2%	4	0.30 seg	22.34 seg
<i>IV_{st}</i>	99.2%	3	0.38 seg	17.98 seg

^a Se calculó la mediana del número de parámetros usado por modelo entre los 288 modelos de cada paciente y se presenta la máxima mediana.

^b Se calculó el tiempo promedio que tardó el algoritmo entre los 288 modelos seleccionados para cada paciente y se presenta el promedio de promedios.

^c Tiempo máximo que tardó el algoritmo en seleccionar un modelo.

De los modelos seleccionados por el algoritmo, independientemente de la variante, el 99% cumple con los supuestos. Por otra parte, la segunda columna de la Tabla indica que las variantes que no consideran la transformación de los datos tienden

a seleccionar modelos con menos parámetros. Con relación al tiempo que tarda el algoritmo, es interesante notar que las variantes que basan la selección de los valores (p ; q) en las FAC y FACP (III y IV) muestrales, tardan más que las que buscan el modelo más parsimonioso. Por último, en promedio el algoritmo tarda menos de 1 segundo en seleccionar un modelo, mientras que el tiempo máximo que tardó fue de 27 segundos (variante II), por lo que se concluye que el algoritmo podría ser implementado en la vida real, ya que los registros de glucosa son cada 5 minutos; además, la velocidad de implementación se podría mejorar con el uso de alguna computadora especializada.

Luego de verificar la factibilidad de la implementación del algoritmo, se evaluó su precisión al momento de pronosticar. La Figura 11 muestra los diagramas de caja y brazos de las medidas de precisión EAM y RECM resultantes de comparar los pronósticos puntuales de las 120 series contra los datos reales; las variantes están ordenadas por sus medianas, de mayor a menor. Como se observa en la figura, la variante *III_{st}* es la que obtuvo mejores resultados, ya que el valor de su mediana, así como el del primer y tercer cuartil son menores que el resto de las variantes para ambas medidas. Por otra parte, es importante notar que hay un claro dominio de las variantes I y III sobre la II y IV y que contrario al paciente ejemplo, al no considerar la transformación de los datos, se mejoró la precisión de los pronósticos para todas las variantes del algoritmo. Además de identificar la manera en que el algoritmo propuesto es más preciso, también se evaluó la eficacia de las variantes para prevenir los eventos de hipoglucemia. En las 24 horas que se analizaron para cada uno de los 120 pacientes, se identificaron 161 eventos de hipoglucemia. Las Tablas 8 y 9 contienen los resultados de las alarmas para prevenir estos eventos, utilizando pronósticos puntuales e intervalos del 90% de confianza.

Figura11. Diagramas de caja y brazos para las medidas de precisión del pronóstico




Tabla 9. Resultados de alarmas utilizando estimaciones puntuales.


Variante del algoritmo	Número promedio de alarmas al día	Porcentaje de falsas alarmas	Sensibilidad	Tiempo de reacción promedio
I	1.7	44.2%	65.7%	21.1 min
II	2.3	48.4%	85.0%	23.4 min
II	1.7	46.5%	63.9%	21.0 min
IV	2.3	48.9%	83.1%	22.1 min
I_{st}	1.7	43.6%	69.5%	22.9 min
II_{st}	3.1	57.0%	88.5%	26.3 min
III_{st}	1.7	45.1%	68.9%	23.0 min
IV_{st}	3.0	56.5%	87.3%	27.0 min

Tabla 10. Resultados de alarmas utilizando intervalos de confianza del 90%.

Variante del algoritmo	Número promedio de alarmas al día	Porcentaje de falsas alarmas	Sensibilidad	Tiempo de reacción promedio
I	3.8	63.7%	98.2%	26.6 min
II	7.2	81.4%	95.9%	28.9 min
II	3.8	63.7%	98.2%	26.5 min
IV	7.0	80.7%	95.9%	27.6 min
I_{st}	6.1	78.1%	99.4%	29.5 min
II_{st}	10.3	86.9%	99.4%	30.0 min
III_{st}	6.1	78.1%	99.4%	29.1 min

IV_{st}	10.2	86.6%	99.4%	29.2 min
-----------	------	-------	-------	----------

Comparando las tablas se observa que al utilizar pronósticos por intervalos en lugar de pronósticos puntuales se mandan más alarmas, esto es evidente ya que, al abarcar más espacio, los intervalos son más sensibles a detectar la hipoglucemia. Por otro lado, es importante notar que, al omitir la transformación de los datos, aumenta de manera considerable el porcentaje de falsas alarmas. Por último, el uso de pronóstico por intervalos aumentó considerablemente la sensibilidad, que es el porcentaje de eventos reales que detectó el algoritmo, alcanzando alrededor del 99% con todas las variantes, sin embargo, el porcentaje de falsas alarmas es demasiado alto; en la variante con mejor escenario se mandarían alrededor de 4 alarmas al día, de las cuales entre 2 y 3 serían falsas. Entonces, con el fin de reducir el porcentaje de falsas alarmas, se decidió explorar los resultados alterando el nivel de confianza de los intervalos. La Figura 12 compara los resultados de las variantes I y I_{st} utilizando desde estimaciones puntuales hasta intervalos del 95% de confianza, aumentando el nivel de confianza en 5%; estas variantes fueron elegidas debido a que I es la que logró mejor porcentaje de falsas alarmas, mientras que I_{st} fue la que logró mejor sensibilidad, además la primera es la que logró mejor tiempo de reacción entre las variantes con menor tasa de falsos positivos y la segunda es la que logró menor tasa de falsos positivos y mejor tiempo de reacción, entre las variantes que lograron mejor la sensibilidad.

Figura 12. Resultados de las variantes I y I_{st} 

En el panel (A) se aprecia cómo la sensibilidad converge al 100% cuando se aumenta el nivel de confianza de los intervalos, sin embargo, la convergencia es más rápida en la variante I_{st} . Por otro lado, en el panel (B) se observa que luego de los intervalos con 30% de confianza, la variante I es más precisa con las alarmas que manda, ya que tiene un porcentaje menor de falsos positivos. El panel (C) fortalece la percepción de que la variante I es más precisa, ya que mientras ambas variantes convergen a una sensibilidad similar. La variante I_{st} aumenta la diferencia de alarmas que manda en comparación con I al incrementar el nivel de confianza de los intervalos. Por último, el panel (D) muestra cómo ambas variantes previenen los eventos de hipoglucemia con una anticipación de entre 20 y 25 minutos. Después de analizar estos resultados, se concluye que la variante I_{st} es más efectiva al momento de prevenir eventos, ya que logra mayor sensibilidad y tiempo de reacción; sin embargo, la variante I es más eficiente porque obtiene resultados de sensibilidad y tiempo de reacción similares con una considerable reducción de falsas alarmas. Por

lo tanto, esta variante es la que se recomienda para la aplicación del algoritmo de predicción continua en la vida real.

Después de analizar los resultados de la implementación del algoritmo con los datos de los 120 pacientes, se decidió analizar los resultados en una población más propensa a sufrir eventos de hipoglucemia. Con este fin, se identificaron aquellos pacientes que presentaron algún evento de hipoglucemia (53 pacientes), y con base en sus datos se obtuvieron las tasas de falsos positivos, así como los números de alarmas diarias promedio⁵. La Tabla 10 contiene los resultados de la variante I para todos los niveles de confianza analizados, las últimas dos columnas se refieren a los resultados obtenidos de analizar sólo a los pacientes que presentaron hipoglucemia. Al comparar los resultados de la población que presentó hipoglucemia contra los resultados de toda la población, el número de alarmas diarias aumenta aproximadamente al doble mientras que el porcentaje de falsas alarmas se reduce entre un 4% y 7%, es decir, para una población más propensa a sufrir hipoglucemia se mantendría la sensibilidad mientras que se reduce el número de falsas alarmas. Por otro lado, es relevante notar que, en algunos escenarios, al aumentar el nivel de confianza, la tasa de falsos positivos se reduce; esto se debe a que en algunas iteraciones el cómputo de los intervalos resultó en valores indeterminados para la computadora. Sin embargo, aunque estos problemas de cálculo reduzcan las falsas alarmas, la sensibilidad nunca decrece, lo que se podría interpretar como que el algoritmo tiene problemas de cómputo sólo al momento de pronosticar falsas hipoglucemias.

5 Ni la sensibilidad ni el tiempo de reacción cambian al acotar la población a estos pacientes.

Tabla 11. Resultados de la variante I para toda la población y la población con hipoglucemia.

Nivel de confianza	Sensibilidad	Tiempo de reacción promedio	Alarmas diarias promedio	Porcentaje de falsas alarmas	Alarmas diarias promedio Hipoglucemia	Porcentaje de falsas alarmas Hipoglucemia
0.0%	65.7%	21.1 min	1.7	44.2%	3.5	40.6%
5%	69.6%	21.2 min	1.8	44.7%	3.8	41.4%
10%	71.3%	21.0 min	1.9	45.3%	3.9	41.3%
15%	73.7%	20.9 min	1.9	44.0%	3.9	39.7%
20%	76.5%	19.4 min	1.9	42.7%	4.0	38.1%
25%	78.1%	19.2 min	1.9	42.6%	4.0	37.7%
30%	80.2%	19.6 min	2.0	43.0%	4.1	38.2%
35%	84.5%	19.2 min	2.0	41.6%	4.2	35.5%
40%	85.1%	18.9 min	2.1	42.8%	4.3	36.7%
45%	86.4%	18.7 min	2.2	43.6%	4.4	37.6%
50%	88.8%	18.0 min	2.2	43.6%	4.5	37.5%
55%	90.0%	19.0 min	2.4	46.5%	4.8	40.5%
60%	92.3%	20.4 min	2.5	47.3%	5.0	41.5%
65%	92.9%	21.8 min	2.6	49.4%	5.1	42.4%
70%	93.5%	22.4 min	2.7	51.2%	5.4	44.4%
75%	94.7%	19.9 min	2.9	53.5%	5.6	46.1%
80%	97.6%	21.1 min	3.1	57.3%	6.1	50.0%
85%	98.2%	24.8 min	3.5	60.9%	6.5	52.9%
90%	98.2%	26.6 min	3.8	63.7%	7.0	56.5%
95%	98.2%	26.6 min	4.5	69.9%	8.1	62.3%

Finalmente, es relevante destacar dos escenarios: el primero, que sólo con intervalos del 55% de confianza, el algoritmo alcanzó a prevenir el 90% de los eventos de hipoglucemia con una anticipación de 19 minutos, donde de cada 5 alarmas que se hubieran mandado a los pacientes más propensos a hipoglucemia, aproximadamente 3 anticiparían eventos reales; el segundo que con intervalos del 85% de confianza se alcanzó la máxima sensibilidad de 98.2% con un tiempo de reacción promedio de 25min y un promedio de entre 6 y 7 alarmas diarias para los pacientes propensos a hipoglucemia, de las que aproximadamente la mitad anticiparían eventos reales.

Comparación con el algoritmo propuesto por Yang et al.

Debido a que la variante III_{st} del algoritmo propuesto es la más precisa al momento de pronosticar y a que la variante I es la más eficiente para prevenir eventos de hipoglucemia, se decidió comparar ambas contra la propuesta de Yang *et al.* (2018). Para realizar la comparación, a las mediciones de los 120 pacientes que se analizaron se les aplicó la función *auto.arima* del paquete reseñado en Hyndman y Khandakar (2008). Con el propósito de atribuir la diferencia en los resultados únicamente al método para seleccionar los modelos, se utilizó el método de máxima verosimilitud para estimar los parámetros en ambas propuestas y se consideraron también los modelos con $p = 0$ o $q = 0$ para la propuesta de Yang.

La Tabla 11 contiene los resultados en relación con las características de los modelos estimados y el tiempo que le toma a los algoritmos seleccionarlos; tanto el algoritmo propuesto como el de Yang *et al.* (2018) fueron implementados en una Laptop ASUS S301LA con procesador Intel Core i5-4200U. Se puede observar cómo las dos variantes del algoritmo propuesto lograron

seleccionar más modelos que cumplen con los supuestos; sin embargo, es relevante notar que más del 90% de los modelos con mínimo AIC también cumplen estos supuestos. Por otro lado, aunque las tres propuestas seleccionaron un alto porcentaje de modelos que cumplen con los supuestos, el algoritmo sugerido tiende a seleccionar modelos más parsimoniosos, de las medianas del número de parámetros para cada paciente (288 modelos seleccionados por paciente), la máxima es menor en dos unidades que la conseguida por el algoritmo de Yang. Finalmente, en cuestión al tiempo para la selección de un modelo, los tres algoritmos parecen ser eficientes, ya que, en promedio, tardaron menos de 1 segundo en elegir cada modelo; sin embargo, al observar el tiempo máximo, lo que más tardó el algoritmo de Yang fue aproximadamente 4 minutos con 50 segundos, lo cual podría comprometer su aplicación en vida real, debido a que los registros de glucosa se toman cada 5 minutos.

Tabla 12. Resultados de los modelos

Algoritmo de predicción	Porcentaje de modelos que cumplen supuestos	Max. Mediana del número de parámetros ^a	Tiempo promedio del algoritmo ^b	Tiempo máximo del algoritmo ^c
Variante I	98.8%	4	0.15 seg	06.81 seg
Variante <i>III_{st}</i>	99.2%	4	0.39 seg	22.34 seg
Yang	91.6%	6	0.92 seg	288.96 seg

^a Se calculó la mediana del número de parámetros usado por modelo entre los 288 modelos de cada paciente y se presenta la máxima mediana.

^b Se calculó el tiempo promedio que tardó el algoritmo entre los 288 modelos seleccionados para cada paciente y se presenta el promedio de promedios

^c Tiempo máximo que tardó el algoritmo en seleccionar un modelo

La Figura 13 muestra los diagramas de caja y brazos de las medidas de precisión para las dos variantes del algoritmo propuesto y para el algoritmo de Yang. En la Tabla 12 se observa cómo la diferencia entre las tres variantes no es grande, sin embargo, la variante III_{st} fue la que obtuvo mejores resultados. La única diferencia de esta variante con el algoritmo de Yang es la selección de los valores $(p; q)$. Mientras que Yang elige el modelo con mínimo AIC, la variante III_{st} se basa en las funciones FAC y FACP muestrales para elegir un modelo que cumpla con los supuestos, es decir, la verificación de supuestos tiene un impacto positivo en la precisión de los pronósticos. Para confirmar este resultado, se observó que la variante I también logró mejores resultados que el algoritmo de Yang; esta variante sólo difiere en que se seleccionan los valores $(p; q)$ más parsimoniosos, en tanto que el modelo seleccionado cumpla los supuestos.

Figura 13. Diagramas de caja y brazos de las medidas de precisión para los 120 pacientes





Tabla 13. Medianas de las medidas de precisión de menor a mayor

Variante	EAM	RECM
III_{st}	14.15	20.12
Yang	14.25	20.85
I	14.54	21.06

En la Figura 14 se aprecia que el algoritmo de Yang y la variante *III_{st}* tienen un comportamiento casi igual para todos los niveles de confianza. Sin embargo, hay una ligera disminución tanto en las falsas alarmas como en el número de alarmas que se mandan al día, por lo que se podría pensar que la verificación de supuestos también influye de manera positiva en la eficiencia de las alertas. Finalmente, el algoritmo de Yang es más efectivo al momento de prevenir la hipoglucemia, pero la variante *I* resulta ser la más eficiente por lograr una sensibilidad similar con una reducción considerable del número de alarmas que se mandan al día, así como el porcentaje de falsas alarmas. Es relevante recordar que en Yang *et al.* (2018) los registros de glucosa están en una escala diferente (mmol/l) y su frecuencia es de 3 minutos, lo que provoca que los resultados de este análisis no sean comparables con los del artículo, el cual reporta 100% de sensibilidad y 10.7% de falsas alarmas para pacientes con DM1. Sería de interés evaluar si la diferencia en los sensores es lo que provoca mejores resultados y cuál es el desempeño del nuevo algoritmo propuesto con estos sensores, pero desafortunadamente no tenemos acceso a los datos usados por Yang *et al.* (2018).

Figura 14. Resultados de las variantes I, III_{st} y el algoritmo de Yang



5. Conclusiones

La diabetes es una enfermedad crónica que afecta alrededor de 425 millones de adultos en el mundo⁶, de los cuales aproximadamente el 10% padecen Diabetes Tipo 1. La diabetes tipo 1 es una enfermedad que no se puede prevenir y suele diagnosticarse desde la infancia, además de que es considerablemente más complicada de controlar que la Tipo 2. Con base en las nuevas tecnologías que se han desarrollado para el control de la diabetes, en este trabajo se propuso utilizar un algoritmo que podría ayudar de manera relevante a estos pacientes, al prevenir con más de 20 minutos de anticipación que sus niveles de glucosa están propensos a descontrolarse; en particular, a prevenir eventos de hipoglucemia. El algoritmo propuesto resultó ser factible, puesto que, en promedio, tarda menos de un segundo en hacer el pronóstico de los niveles futuros de glucosa; además, obtuvo resultados prometedores al prevenir hasta el 99% de los eventos

6 Prevalencia reportada en IDF (2017)

de hipoglucemia que se estudiaron. Sin embargo, se encontró que mientras más alto es el porcentaje de eventos que se previenen, más alto es el porcentaje de alarmas que resultan falsas, es decir, que pronostican hipoglucemia cuando no la hay. En consecuencia, más allá de enfocarse en prevenir este tipo de eventos, sería relevante investigar la percepción tanto de médicos como de pacientes sobre qué tantos falsos positivos son tolerables con el fin de prevenir un porcentaje determinado de hipoglucemias. De dicha investigación podría definirse el nivel de confianza adecuado de los intervalos, el cual sería aquél que logre la relación óptima entre la tasa de sensibilidad, la tasa de falsas alarmas y el número promedio de alarmas diarias.

El tema de cómo utilizar el análisis de series de tiempo para pronosticar niveles futuros de glucosa no es nuevo; sin embargo, el enfoque que se le dio en este trabajo es un intento de automatizar la metodología de Box y Jenkins (1970) para la selección de modelos ARIMA; perspectiva que no se había estudiado previamente. Al comparar este enfoque con el propuesto por Yang *et al.* (2018), el cual reporta los mejores resultados de la literatura actual, se obtuvo una precisión mejor o similar en los pronósticos (dependiendo de la variante del algoritmo), menor tasa de falsas alarmas y una sensibilidad similar, lo que sugiere que es mejor elegir un modelo que cumpla con los supuestos inherentes a los modelos ARIMA que elegir el modelo con menor AIC entre un universo de modelos; además, el enfoque propuesto resultó ser más eficiente en términos del tiempo que tarda una computadora en implementarlo. A pesar de estos resultados, es importante mencionar que las tasas de sensibilidad y falsas alarmas reportadas en Yang *et al.* (2018) son mejores a las reportadas en este trabajo, por lo que sería de interés investigar si el algoritmo propuesto podría obtener mejores resultados bajo las condiciones de pacientes analizados en este artículo, donde la principal diferencia fue que se utilizó un sensor de MCG con

una escala y frecuencia distinta. Es decir, habría que estudiar si el tipo de sensor influye de manera relevante en la prevención de eventos de hipoglucemia.

En este trabajo se estudió el caso de la prevención de hipoglucemia, pero también sería de interés analizar el desempeño del algoritmo para prevenir hiperglucemias; si se aplicará un método de alarmas similar al propuesto para prevenir niveles altos de glucosa. Se puede plantear la hipótesis de que se obtendrían mejores tasas de sensibilidad, pero también tasas más altas de falsas alarmas. Esto debido a que el algoritmo utiliza transformaciones potencia para estabilizar la varianza, luego al momento de regresar los intervalos de confianza a su escala original, los límites de los intervalos dejan de tener la misma distancia hacia el pronóstico puntual; más aún, el análisis del caso ejemplo sugiere que los límites superiores se desvían del valor central considerablemente más que los inferiores.

Finalmente, los resultados de este trabajo se pueden utilizar en términos económicos. La Diabetes Mellitus es una enfermedad crónica que afecta a alrededor de 12 millones de adultos mexicanos⁷, de los cuales se estima que el 10% padecen de DM1. Por otra parte, la Federación Mexicana de Diabetes reporta que, en promedio, un paciente que se trata con insulina sufre de 24 eventos de hipoglucemia al año⁸. Ahora, si se toma en cuenta que 33%⁹ de los pacientes con DM1 se atienden en el IMSS (396 mil pacientes), se concluye que el IMSS trata hasta 9.5 millones de eventos de hipoglucemia al año, con un costo anual aproximado por paciente de entre 31,700 y 51,400

7 Cifras reportadas en IDF (2017)

8 <http://fmdiabetes.org/hipoglucemia-1/>

9 Porcentaje de la población mexicana que es derechohabiente del IMSS, reportado en ENSANUT, 2016

pesos¹⁰; es decir, si asumimos que la implementación del algoritmo y los sensores podrían prevenir 90% de estos eventos y que todos los pacientes sabrían que acciones tomar para evitar la hipoglucemia, se podrían ahorrar entre 11 y 18 mil millones de pesos al año, lo que representa entre el 3% y el 5% del gasto total para el cuidado de la diabetes en México, que se estima en 372 mil millones de pesos¹¹. Este análisis económico es informal y además se basa en que las tasas de sensibilidad obtenidas en el trabajo serían similares en la población mexicana. Sin embargo, debido al potencial impacto económico, sería de interés investigar el desempeño del algoritmo en la población mexicana y más aún, ahondar en cómo implementar el uso de los sensores, ya que el resultado obtenido en el análisis de subgrupos sugiere que se pronostica de manera más precisa los niveles de glucosa de aquellos pacientes que dedican más tiempo al cuidado de su enfermedad, es decir, si se pensara en una política pública para implementar el uso de sensores, esta podría ser complementada con una campaña de educación sobre el cuidado de la diabetes, esto con el fin de alcanzar las mejores tasas de prevención de hipoglucemia posibles y asegurarse de que los pacientes sepan cómo actuar para evitar los eventos.

Agradecimiento: Alejandro Islas Camargo agradecen el apoyo económico de la Asociación Mexicana de Cultura, A.C. para la realización de este proyecto.

10 Costos reportados en http://www.senado.gob.mx/64/gaceta_del_senado/documento/67742 para el año 2014 y traídos a valor presente con inflación de 20.77%, según calculadora del INEGI.

11 Gasto en el cuidado de la diabetes por parte de México reportado en dólares en IDF (2017).

Bibliografía

- American Diabetes Association [ADA] (2019). Classification and diagnosis of diabetes: Standards of medical care in diabetes—2019. *Diabetes Care*. 42(Suppl.1), S13-S28. DOI: 10.2337/dc19-S002
- Anderson, O. D. (1976). *Time series analysis and forecasting: the Box-Jenkins approach*. London: Butterworth.
- Boiroux, D., Duun-Henriksen, A. K., Schmidt, S. *et al.* (2012). Overnight control of blood glucose in people with type 1 diabetes,” *IFAC Proceedings Volumes*, 45(18), 73-78. DOI: 10.3182/20120829-3-HU-2029.00106
- Botwey R. H., Daskalaki, E., Diem, P. *et al.* (2014). Multi-model data fusion to improve an early warning system for hypo-/hyperglycemic events. *Annual International Conference of the IEEE Engineering in Medicine and Biotechnology Society (EMBC)*, 4843-4846. DOI: 10.1109/EMBC.2014.6944708
- Box, G. E. P., y Jenkins, G. M. (1970). *Time series analysis: forecasting and control*. San Francisco, CA: Holden-Day.
- Doherty S. T., Greaves S. P. (2015). Time-series analysis of continuously monitored blood glucose: the impacts of geographic and daily lifestyle factors. *Journal of Diabetes Research*, 2015(1), 804341. DOI: 10.1155/2015/804341
- Dickey, D. A., Bell, W. R., and Miller, R. B. (1986). Unit roots in time series models: Tests and implications. *American Statistician*, 40(1), 12-26. DOI: 10.1080/00031305.1986.10475349
- ENSANUT (2016). *Encuesta nacional de salud y nutrición de medio camino 2016*. México: Secretaria de Salud. Instituto Nacional de Salud Pública. <https://www.gob.mx/cms/uploads/attachment/file/209093/ENSANUT.pdf>
- Eren-Oruklu M., Cinar A., Quinn L. *et al.* (2009) Adaptive control strategy for regulation of blood glucose levels in patients with type 1 diabetes. *Journal of Process Control*, 19(8), 1333-1346. DOI: 10.1016/J.PROCONT.2009.04.004

- Fernández de Canete J., González-Pérez, S., Ramos-Díaz, J. C. (2012). Artificial neural networks for closed loop control of *in silico* and *ad hoc* type 1 diabetes. *Computer Methods and Programs in Biomedicine*, 106(1), 55-66. DOI: 10.1016/j.cmpb.2011.11.006
- Fryar, C. D., Kruszon-Moran, D., Gu, Q., *et al.* (2018). Mean body weight, height, waist circumference, and body mass index among adults: United states, 1999–2000 through 2015–2016. *National Health Statistics Reports* (122). https://stacks.cdc.gov/view/cdc/61430/cdc_61430_DS1.pdf
- Gani, A., Gribok, A.V., Lu Y. *et al.* (2010). Universal glucose models for predicting subcutaneous glucose concentration in humans. *IEEE Transactions on Information Technology in Biomedicine*. 14(1), 157-165. DOI: 10.1109/TITB.2009.2034141
- Georga E. I., Protopappas V. C., Polyzos D. *et al.* (2015). Evaluation of short-term predictors of glucose concentration in type 1 diabetes combining feature ranking with regression models. *Medical & Biological Engineering & Computing*, 53(12), 1305-1318. DOI: 10.1007/s11517-015-1263-1
- Guerrero, V. M. (1993). Time-series analysis supported by power transformations. *Journal of Forecasting*, 12(1), 37-48. DOI: 10.1002/for.3980120104
- Guerrero, V. M. (2003). *Análisis estadístico de series de tiempo económicas*. México: Thomson.
- Harvey, A. C. y McKenzie, C. R. (1982). Algorithm AS 182: Finite sample prediction from ARIMA processes. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 31(2), 180-187. DOI: 10.2307/2347987
- Hidalgo, J. I., Colmenar, J. M., Kronberger, G. *et al.* (2017). Data based prediction of blood glucose concentrations using evolutionary methods. *Journal of Medical Systems*, 41(9), 142. DOI: 10.1007/s10916-017-0788-2

- Hyndman, R. J. y Khandakar, Y. (2008). Automatic time series forecasting: the forecast package for R. *Journal of Statistical Software*, 27(3), 1-22. DOI: 10.18637/jss.v027.i03
- Hyndman, R., Athanasopoulos, G., Bergmeir, C., *et al.* (2019). Forecast: Forecasting functions for time series and linear models. *R package version 8.7*
- International Diabetes Federation [IDF] (2017). *IDF Diabetes Atlas*. 8 ed. Brussels: International Diabetes Federation. <http://fmd diabetes.org/wp-content/uploads/2018/03/IDF-2017.pdf>
- Juvenile Diabetes Research Foundation Continuous Glucose Monitoring Study Group [JDRF]. (2008). Continuous glucose monitoring and intensive treatment of type 1 diabetes. *New England Journal of Medicine*, 359(14), 1464–1476. DOI: 10.1056/NEJMoa0805017
- Juvenile Diabetes Research Foundation Continuous Glucose Monitoring Study Group [JDRF] (2009). The effect of continuous glucose monitoring in well-controlled type 1 diabetes. *Diabetes Care*, 32(8), 1378-1383. DOI: 10.2337/dc09-0108
- Khadilkar, V. V., Parthasarathy, L. S., Mallade, B. B. *et al.* (2013). Growth status of children and adolescents with type 1 diabetes mellitus. *Indian Journal of Endocrinology and Metabolism*, 17 (6), 1057-1060. DOI: 10.4103/2230-8210.122623
- Nelder, J. A., y Mead, R. (1965). A simplex method for function minimization. *Computer Journal*, 7(4), 308-313. DOI: 10.1093/comjnl/7.4.308
- Organización Mundial de la Salud [OMS] (2016). *Informe mundial sobre la diabetes*. Ginebra: Organización Mundial de la Salud. <https://iris.who.int/bitstream/handle/10665/254649/9789243565255-spa.pdf>
- Otoom, M., Alshraideh, H., Almasaeid, H. M. *et al.* (2015). Real-time statistical modeling of blood sugar. *Journal of Medical Systems*, 39(10), 123. DOI: 10.1007/s10916-015-0301-8

- Oviedo, S., Vehí, J., Calm, R. *et al.* (2017). A review of personalized blood glucose prediction strategies for T1DM patients, *International Journal for Numerical Methods in Biomedical Engineering*, 33(6), e2833. DOI: 10.1002/CNM.2833
- Pérez-Gandía, C., Facchinetti, A., Sparacino, G. *et al.* (2010). Artificial neural network algorithm for online glucose prediction from continuous glucose monitoring. *Diabetes Technology & Therapeutics*, 12(1), 81-88. DOI: 10.1089/dia.2009.0076
- Sparacino, G., Zanderigo, F., Corazza, S. *et al.* (2007). Glucose concentration can be predicted ahead in time from continuous glucose monitoring sensor time-series. *IEEE Transactions on Biomedical Engineering*. 54(5), 931-937. DOI: 10.1109/TBME.2006.889774
- Yang, J., Li, L., Shi, Y. *et al.* (2018). An ARIMA model with adaptive orders for predicting blood glucose concentrations and hypoglycemia. *IEEE Journal of Biomedical and Health Informatics*, 23(3), 1251-1260. DOI: 10.1109/JBHI.2018.2840690
- Zarkogianni, K., Mitsis, K., Litsa, E. *et al.* (2015). Comparative assessment of glucose prediction models for patients with type 1 diabetes mellitus applying sensors for glucose and physical activity monitoring. *Medical & Biological Engineering & Computing*, 53(12), 1333-1343. DOI: 10.1007/s11517-015-1320-9

Factors that impact obesity prevalence in Mexico

*Frida Fernández de la Rosa**
*Baruch Ramírez Rodríguez***

Abstract

Obesity and overweight are health issues that affect Mexican society and, at the same time, are linked to underlying health conditions that represent a significant cost to the country's public health system. There is literature that attributes obesity to different causes such as an inadequate food intake and poor physical activity. However, there is enough evidence indicating that these behaviors at the same time have other causes. Different socioeconomic variables such as income, education level, and place of residence may determine the weight and health status of an individual. Using probabilistic models, this paper explains how different factors like income per capita, reception of social

* Departamento de Métodos Cuantitativos, Universidad de Guadalajara.

** Departamento de Métodos Cuantitativos, Universidad de Guadalajara.

transfers, and mother's weight, increase the likelihood of a person to be overweight or obese. Results show that the probability of a person experiencing weight alterations does not behave uniformly in all income quintiles, increasing in the second and the fifth but decreasing in the rest. Likewise, we find that individuals whose mothers are obese or overweight have a probability of up to 29.8% of being in either of these conditions among different income levels.

1. Introduction

It is estimated that 35% of children of school age and 38% of teenagers in Mexico are affected by either overweight or obesity (Shamah-Levy *et al.*, 2020). While most of the existing research focus on income as the explaining factor for the obesity problem, there is also research pointing to alternative explanations, most of these with some degree of interaction. Shamah-Levy *et al.* (2022) identified that a diet poor in vegetable and fruit consumption significantly contributed to childhood obesity in Mexico. However, others argue that parameters like income (Jo, 2014; Nghiem & Khanam, 2016), education level (Lamerz *et al.*, 2005), conditional cash transfers (Fernald *et al.*, 2008), social effects (Olvera-Ezzel *et al.*, 1990), and even globalization (Colchero *et al.*, 2015) can account for the increasing rates of obesity in middle-income countries.

Other socioeconomic variables often accompany the effects of income on obesity. Kaushal (2007) and Akee *et al.* (2013) analyzed the effect of receiving food stamps from federal programs¹²

12 The Supplemental Nutrition Assistance Program (SNAP) exists in the United States and provides individuals from low-income households with aid for purchasing food and groceries. The program often includes meals for children in school-age and senior citizens.

in the United States, finding positive transfer – BMI relationships. Similarly, Cawley (2015) found that the high cost of food in certain areas and the lack of proper recreational infrastructure in some neighborhoods negatively impacted low-income individuals, causing them to endure obesity-related problems. The effects of income on obesity could also behave differently depending on the country's income and development status (Dinsa *et al.*, 2012). For instance, Darmon & Drewnowski (2008) found a causal relationship between socioeconomic status and food quality, showing that individuals with higher education and income were consumers of high-quality diets.

The Problem of Obesity and Its Relationship to Income in Mexico

Obesity in Mexico has been described by many as a modern-day epidemic affecting its population. The Instituto de Seguridad y Servicios Sociales para los Trabajadores del Estado (ISSSTE, 2020) shows that around 77% of deaths by non-communicable chronic diseases in the Mexican population are linked to obesity or overweight. Mendoza-Herrera *et al.* (2019) concluded that being diagnosed with a CVD¹³ can cause problems that range from loss of productivity to outstanding expenses in medication, consultations, and hospitalizations. Additionally, obesity has been associated with a higher chance of adult Mexican women suffering mental health issues like depression or depression-related symptoms (Zavala, *et al.*, 2018).

Morales-Ruán *et al.* (2014) found a significant relationship between high BMI and mild food insecurity in adult Mexican women, while Flores, Carrión, and Barquera (2005) concluded

13 Cardiovascular disease

that maternal overweight and obesity can significantly increase the chances of their children being overweight or obese by up to 1.9%. Although research already establishes a relationship between income and obesity in low-income rural Mexican communities (Fernald, 2007), this relationship may not be concurrent for all income groups (quintiles) in the country. More research on the interaction between income-related variables is needed. Understanding how income impacts health may aid in developing more specific public health policies that improve people's health in unequal environments.

Research questions and hypothesis

Literature shows that several factors, such as food insecurity, gender, genetic predisposition, and deficient nutrient supply, have been accounted for as determinants of high obesity rates in the Mexican population. The conflicting results on the impact of income level on weight make way for questioning whether the per capita income reported in Mexican households can increase an individual's chances of being overweight or obese. That is, could an individual with a higher income be more or less likely to be overweight or obese than an individual with a lower income?

Previous literature about Mexico established some relationship between socioeconomic status. Morales-Ruán *et al.* (2014) and Raccanello (2020) show that low socioeconomic status translates into a higher risk of obesity and overweight. Additionally, Fernald (2007) describes an unequal income-obesity relationship for the different income groups. Based on these findings we can create the hypothesis that the income-obesity relationship may behave differently if analyzed in other income groups or quintiles. Unlike many data found in literature, this approach splits

the population into five equally distributed quintiles rather than only categorizing rich and poor.

Income per capita in Mexico has shown a non-linear relationship with international data on obesity (Grecu & Rotthoff, 2015; Aydin, 2019; Windarti, Hlaing, & Kakinaka, 2019), and a similar behavior could be proposed for income and obesity in Mexican households. This study aims to determine if income impacts the chances of an individual being overweight or obese in Mexico. We hypothesize that income, alongside elements like health insurance, peer effects, and social transfers, could significantly impact the prevalence of obesity among the Mexican population. In this work we introduce the topic of obesity and relate it to the different factors that literature has associated with obesity in several forms. We then introduce our analyzed survey and describe the variables and models used. Finally, we present the study's results, a discussion of the outcomes, and an overall conclusion.

2. Factors that Impact Obesity

The World Health Organization (2021) specifies different accepted BMI levels for adults and children depending on age; a person with a BMI greater than the defined standards is considered overweight or obese. As the twentieth century ended, health specialists started cataloging obesity as a global epidemic due to the dramatic global increase in overweight and obesity rates (Hill & Peters, 1998). In the United States, the increasing rates of chronic illnesses related to obesity led health professionals to try to understand its causes and find a solution (Catenacci *et al.*, 2009).

Among the factors associated with the increasing problem of overweight and obesity, biological factors are some of the first to come into play. Warden & Warden (2001) as well as Wilding

(2001) remark that although gene mutations play an important role in severely obese people's weight.

"Obesity-promoting environments" are far more decisive in a person's weight gain. These environments' characteristics include the availability of high-calorie, low-nutrient food, and a decline in physical activity.

In the Mexican context, Rivera *et al.* (2002) found an increase in the mortality rates for non-communicable chronic diseases associated with a person's weight as well as a quicker spread of these conditions among low-income individuals. Aceves-Martins *et al.*, (2016) attribute the increasing rates of cardiovascular conditions and obesity in low-income individuals principally to a nutritional transition in the average Mexican young population. This transition includes an increase in fast food consumption and food away from home, typically high in fat and low in protein and fiber.

This work's purpose is to expand on some other elements rather than genetics that may also be contributing to the rise of overweight and obesity rates in Mexico. Aceves-Martins *et al.* (2016) acknowledge that the socioeconomic status of modern Mexican society can mainly promote obesity-favoring conducts even when the original intent of these conducts is not to promote obesity. For example, traditional beliefs and misconceptions about health in Mexican households can promote obesogenic behavior.

Cash and non-cash transfers

Exposure to cash transfers to low-income individuals in Latin American countries caused an increase in BMI and increased odds of obesity (+1.07% in Colombia) (Forde *et al.*, 2012) and the consumption of high-calorie density foods in Brazil (Cotta & Machado, 2013). In Mexico, Fernald *et al.* (2008a, 2008b) and Andalón (2011) concluded that cash transfers resulted in less

obesity prevalence and better self-reported health in low-income children and adults. While Levasseur (2019) proposed that the programs' cash component was linked to increased abdominal fat, BMI, and obesity prevalence.

Education

A linear and negative relationship between education and obesity can be observed in high and middle-income countries (Monteiro *et al.*, 2001). In high-income countries studies agree that children of parents with higher education levels indicated having a less obesogenic lifestyle than their peers of lower educated parents (Lamerz *et al.*, 2005; Kistiansen *et al.*, 2012). Lamerz *et al.* (2005) found that maternal education and occupation were more determinant factors in children's obesity levels than paternal education.

Social Effects

Just as their parents' education may impact children's obesity, it could also be related to the children's peers, like classmates or family members. Trogon, Nonnemaker, and Pais (2008) found that the weights of peers (friends and classmates) were correlated with the weights of the teenagers. Bentley *et al.* (2018) introduced the "social multiplier effect"; learned behavior within social groups to consume high-calorie food items is attributed to offsetting a newly found negative relationship between household income, obesity, and diabetes. In low-income areas, unavailable sports facilities and lack of street safety may impede children from getting the recommended time for physical activity (Rodríguez-Oliveros, *et al.*, 2011).

Globalization

Salomón (2005) and Garza-Montoya & Ramos-Tovar (2017) found a change in the consumption patterns of Mexicans after Mexico's incorporation to the North American Free Trade Agreement. Vegetable and cereals consumption decreased by 18.20% and 9.82%, respectively, while the consumption of sugary beverages and food away from home increased by 240% and 228.69%. Fernald (2007) associated high BMI in poor people in rural communities with the consumption of carbonated drinks and alcohol, which was attributed to the expansion of supermarket chains and trading agreements. Otero *et al.* (2018) demonstrated that a non-expensive to produce and easy to commercialize low quality diet hindered poor and middle-class people access to fresh fruits, vegetables, and meats.

Income Level

Research has shown a significant association between income level and health in different contexts. Benzeval & Judge (2001) demonstrated that a reduction in long-term income in Great Britain could have a more significant detrimental effect on health than a rise in it could have a positive one. Before we delve into how income can be a concurring factor for high obesity risk, let us introduce how income can significantly impact an individual's health.

Income and Health

Income and socioeconomic inequalities translate into differentials in child mortality, nutrition status, and access to services that affect the population's health. Barros *et al.* (2010) found that children of poorer households were more likely to experience

diseases that increased in severity because of their poor nutrition status.

Income principally affects the quantity and quality of food a household can consume. Ahluwalia *et al.* (2019) show that high-income families consume healthier foods more and unhealthy foods less than low-income families. Low family income was also associated with nutrition problems such as stunting (low height for age) and wasting (low weight for height) in children (Miller & Korenman, 1994). Misra & Khurana (2008) propose that the recent accessibility of foods with high amounts of fat, salt, and sugar to these countries' populations hinders their nutrition status.

The effects of income on obesity prevalence are still somewhat unclear. Information is also somewhat scant in the Mexican context since most findings focus on food insecurity as a detonator of obesity (Morales-Ruán, *et al.*, 2014). Findings from Clément *et al.* (2021), showed a negative effect of income inequality on BMI, and Ponce-Alcalá *et al.* (2021), proposed that socioeconomic inequalities such as food insecurity may contribute to child obesity, are proof that such polarizing opinions could be observed for Mexican populations.

Income and Obesity

Studies have linked income level and obesity by analyzing different segments of a country's population. Broady and Meeks (2015) showed that individuals living in low-income neighborhoods are affected by limited physical activities, race, and fewer retail stores that offer healthy food options. These socioeconomic issues linked to low-income neighborhoods also impact children; obesity risk increases if they grow around low-income areas, or certain risk factors like single parents (Grow *et al.*,

2010; Kim & Landgraf, 2020) or parents with low education (Gordon-Larsen *et al.*, 2006).

Overall, the findings explaining the relationship between income and obesity can be classified positive and negative. Monteiro *et al.*, (2007) and Ogden *et al.*, (2018) established that men in high-income countries depict higher BMIs as their income increases; the same relationship shows a similar behavior when analyzing women in low-income countries and low-income children from developed nations (Nghiem & Khanam, 2016; Dinsa *et al.*, 2012). A positive income-obesity relationship was also found for low-income adults of both sexes in Mexico (Fernald, 2007).

Negative relationships were found among women (McLaren, 2007; Ameye & Swinnen, 2019) and children (Ogden *et al.*, 2017; Jo, 2014) from high-income countries, as well as men in low-income countries (Monteiro *et al.*, 2007, Ogden *et al.*, 2017).

The effects that income may have on obesity could also be explained by the uneven distribution of income in countries. Su *et al.* (2012) found that a positive relationship between income inequality and obesity among OECD (Organization for Economic Co-operation and Development) countries was only observable when Mexico and the United States (both countries with high rates of obesity and income inequality) were included in the analysis. However, after excluding both countries, the correlation disappeared. Murphy *et al.* (2018) found no relationship between the countries' GNI and the obesity prevalence. In Mexico, Clément *et al.* (2021) found a negative relationship between municipal income inequality and obesity.

Another approach that has been considered while studying the income-obesity relationship is the possibility that this relationship has had a turning point in some societies for a long time. Monteiro *et al.* (2001) describe a change in the income-obesity relationship in Brazilian men from positive to negative over a

28-year period. Additionally, Ogden *et al.* (2017) and Bentley *et al.* (2018) showed robust negative relationships between income and obesity in the United States, which did not previously exist in the 1990s.

3. Methods

Data

Data for BMI, obesity, and other anthropometric measures were obtained from *ENSANUT*'s 2018 edition. This survey is carried out by the Instituto Nacional de Salud Pública (*INSP*) in collaboration with the Mexican Ministry of Health and the Instituto Nacional de Estadística y Geografía (*INEGI*). This edition was the last to include in-person measurements for weight and height and is the only recent edition to have income as a continuous variable rather than a discrete one.

The continuity of the monthly income was used to compute the per capita income in each household. Additionally, respondents to the survey were weighted using high-precision devices¹⁴, which ensures accurate anthropometric data. *ENSANUT* uses Primary Sampling Units set on the National Census of Population and Housing to account for representativeness. The 2018 edition holds representativeness nationwide, in urban and rural areas, and for four regions: North, Center, Mexico City, and South (Shamah-Levy *et al.*, 2020).

The survey is divided into two main components: health and nutrition, with several questionnaires within them. This investigation will focus on the household and anthropometry questionnaires. The former contains information about the living places, and economic characteristics of households and their members; the latter includes anthropometric data useful

14 Electric scales and a stadiometer.

for BMI calculations. The survey also contains questionnaires regarding the frequency of food consumption, childhood development, blood samples, and breastfeeding.

The characteristics described above show that *ENSANUT* is the most suitable data source for the development of this investigation. While using a panel survey such as the *Encuesta nacional sobre niveles de vida de los hogares* (ENNViH, also known as *Mexican Family Life Survey*, *MxFLS*) would benefit the study, but the *MxFLS* was last held in 2012, resulting in more than ten years of information delay. On the contrary, *ENSANUT* 2018 provides more up-to-date information on households' income, expenditure, and anthropometric data. Sample design parameters of the survey indicate a maximum relative error of 10% with a confidence level of 90% and a no-answer rate of 15% at a national level.

Variables

Obesity Measurement

Obesity was determined based on the World Health Organization's thresholds that rely on the Body Mass Index (BMI) to determine whether a person is underweight, overweight, obese, or severely obese. The guidelines from the WHO establish that a BMI greater than or equal to 30 in adults and greater than two standard deviations above the growth reference median for children aged five to nineteen is considered obesity. Equation 1 shows how BMI is calculated, where w is the individual's weight in kilograms, and h is the person's height in meters.

$$bmi = \frac{w}{h^2} \quad (1)$$

The WHO (2010) has different nutritional status categories according to BMI for adults over 20 years old and children aged five to 19. For adults, underweight is indicated by a BMI below

18.5, and normal weight by a BMI between 18.5 and 24.9. A BMI from 25.0 to 29.9 suggests an adult is *overweight*. A BMI from 30.0 to 39.9 is considered obese. For children aged five to 19, *overweight* was defined as a BMI larger than one standard deviation from the WHO growth reference median while obesity was described as a value over two standard deviations over the threshold¹⁵. Pregnant women and people with amputations were excluded from the analysis.

On the household questionnaire of the survey, there is information about households and their members. Per-capita income was calculated for all household members as an average of the total monthly income brought in by the household's working members. Furthermore, individuals are divided into five equal-sized income quintiles to include the quintiles in the models.

Other variables were added to help with the analysis's robustness.

- The education level of the head of household was measured in 4 levels: 1 for no education and 4 for higher education (bachelor's degree equivalent or higher).
- Rural or urban: a dichotomous variable signaling 1 if the household is in a rural area or 0 if otherwise.
- Social transfers: a dichotomous variable with 1 if any member in the household receives social transfers or 0 otherwise. Transfers were considered as any monetary or in-kind help from *Prospera*¹⁶ such as scholarships, monetary incentives for senior citizens, milk, food served at schools, daycare or medical attention provided by the program.

15 This threshold changes depending on the sex of the child and their age in months.

16 Formerly known as *Oportunidades*, the Mexican government's social program aims to reduce poverty by providing monetary or in-kind assistance to low-income families to strengthen their health, nutrition, and education.

- Health insurance. If at least one household member counts with any kind of private or public (*IMSS*, *ISSSTE*, *Seguro Popular*, *PEMEX*)¹⁷ health insurance, this variable will be marked as 1.

Estimation Strategy

To fully describe the relationship between income and BMI at an individual's level, a series of probit regression models that estimate the probability that an individual falls into either of the three overweight-obesity categories was used.

The Model

Jo (2014) explains how the income-obesity relationship can be explained by using linear and non-linear models. In their study on child obesity, Nghiem & Khanam (2016) predict the probability of a child falling into obesity using a probit estimator. This study will use a similar technique to determine whether an individual is overweight, obese, or severely obese.

The model is a probit estimator represented by equations 2 and 3, below. Where P_i is the probability of an individual being overweight, obese, or severely obese and x_{ln_i} is the natural logarithm of the per capita income and x_{in} is a vector of regressors that may influence P. This vector consists of control variables from section 3.2 included in the linear regression.

$$P_i = pr(Y_i = 1|X) = \beta_1 x_{ln_i} + \beta_j X_{in} + \epsilon \quad (2)$$

17 Public health institutions that provide free medical care to their beneficiaries and their families.

Where:

$$Y_i = \{1 \quad \beta_1 x_{ln_i} + \beta_j X_{in} + \epsilon > 0 \quad 0 \quad otherwise\} \quad (3)$$

Sample Characteristics

This study comprises a sample of 158,048 observations representing 126,468,224 individuals in Mexico, of which 48.21% are male and 51.79% are female. Men report an average per capita monthly income of \$4,144.89, while women earn around \$3,715.53 monthly. Table 1 shows the distribution of the population's weight categories by several individuals' characteristics. As shown in Table 1, *obesity* and *severe obesity* are higher among women than among men, while *overweight* is higher on men than on women. Being underweight is more prominent among adolescent males, while child obesity is higher in male children. Adult women also present higher rates of *obesity* and *severe obesity* than adult males, while the rate of *overweight* male adults is higher than that of women.

The population in the highest quintile seems to have the greatest *overweight* rate and ties for the largest obesity rate with quintile 4. Similarly, quintiles 3 and 4 show the highest severe obesity rates, while quintile 2 shows the greatest underweight rate. Unsurprisingly, individuals living in urban areas report higher overweight, obesity, and severe obesity rates than rural areas. At the same time, the latter shows a higher rate of underweight and normal-weighted individuals in contrast. Table 2 shows the distribution of income quintiles across the sampled population. It includes the mean per capita monthly income in each quintile, the standard deviation, and the minimum and maximum values. Income was divided into five equally distributed quintiles to adequately analyze the weight-related variables and their behavior in the different income segments.

Table 1
Weight Characteristics of Individuals (in percentage)

	Underweight	Normal Weight	Overweight	Obesity	Severe Obesity	Total
Sex						
Women	4.03	33.29	31.16	27.50	4.02	100.00
Men	4.94	37.60	32.41	21.75	3.30	100.00
Women by age group						
Child	8.66	53.82	22.01	13.07	2.44	100.00
Adolescent	7.65	52.41	26.44	12.28	1.22	100.00
Adult	1.73	23.15	36.02	34.25	4.85	100.00
Men by age group						
Child	8.61	50.41	19.53	16.35	5.09	100.00
Adolescent	10.40	54.53	20.00	13.61	1.46	100.00
Adult	1.90	27.68	40.92	27.25	2.26	100.00
Income Quintiles						
1	4.83	42.11	29.83	20.55	2.68	100.00
2	4.91	38.58	30.42	23.27	2.82	100.00
3	4.58	35.32	30.42	25.15	4.53	100.00
4	4.1	33.5	31.94	26.07	4.39	100.00
5	2.65	29.2	37.00	27.61	3.54	100.00
Area						
Urban	3.38	30.67	34.53	27.72	3.70	100.00
Rural	4.51	37.95	31.89	23.21	2.44	100.00

Note: Own work using data from *ENSANUT, 2018*

Table 2
Division of Income Quintiles¹⁸

Income Quintile	n	Mean	Std. Dev.	Min	Max
1	18,471,883	819.21	322.71	3.63	1,270.12
2	18,471,883	1,639.01	224.55	1,270.12	2,032.19
3	18,471,883	2,505.31	299.29	2,032.19	3,048.28
4	18,471,883	3,868.93	537.30	3,048.28	5,080.46
5	18,471,883	10,792.56	17,198.78	5,080.46	655,379.80

Note: Own work using data from *ENSANUT, 2018*

Table 3
Characteristics of Individuals by Income Quintile
(in percentage)

	1	2	3	4	5	Total
Sex of Head of Household						
Female	20.5	19.73	20.74	20.13	18.9	100
Male	19.79	20.11	19.7	19.95	20.45	100
Age Group						
5-14	25.39	24.61	21.25	16.87	11.88	100
15-24	18.44	18.80	21.50	22.63	18.63	100
25-34	17.40	20.05	19.09	19.32	24.14	100
35-44	17.98	19.03	19.71	20.87	22.41	100
45-54	15.35	15.44	19.03	22.58	27.59	100
55-64	16.86	15.97	18.44	21.13	27.60	100
65 and older	24.51	20.29	17.44	18.04	19.72	100
Education of Head of Household						
No education	35.07	25.54	17.75	13.98	7.67	100

18 All values are shown in Mexican Pesos adjusted for inflation using 2018 as the base year.

Basic education	23.44	22.13	21.6	19.76	13.08	100
Middle education	13.5	18.06	21.23	23.24	23.97	100
High education	6.48	10.23	11.52	19.06	52.72	100
Weight Status						
Underweight	25.59	23.80	22.79	16.99	10.84	100
Normal Weight	26.42	22.15	20.83	16.46	14.14	100
Overweight	21.33	19.91	20.45	17.89	20.42	100
Obesity	19.16	19.86	22.05	19.05	19.88	100
Severe Obesity	17.10	16.46	27.12	21.92	17.40	100
Benefit of Social Transfers by Income Quintile						
Yes	66.17	54.17	43.87	35.54	21.31	100
No	33.83	45.83	56.13	64.46	78.90	100
Area						
Urban	15.56	18.49	20.45	21.99	23.51	100
Rural	35.17	25.18	18.47	13.18	7.99	100
Region						
North	10.95	16.31	20.04	24.3	28.39	100
Central	17.11	20.83	21.77	20.36	19.94	100
Mexico City	15.03	17.32	19.33	22.41	25.92	100
South	31.05	22.36	18.12	15.95	12.52	100

Note: Own work using data from *ENSANUT*, 2018

Table 3 shows the distribution of several population characteristics according to their income quintile. It shows that the individuals that live in households where the head only completed primary education are mainly distributed within the first income quintile. In contrast, heads of households that completed

higher education mainly distribute within the higher quintile. Regarding weight characteristics, 21.33% of *overweight* people are within the first income quintile, the highest rate in the overweight group, while the highest rates of *obese* and *severely obese* people are within the third income group, with 22.05 and 27.12 percent, respectively.

It is easy to notice that rural areas have a higher rate of individuals in the first quintile than urban areas, which seem more evenly distributed among the quintiles. Conversely, the North region of Mexico has the highest concentrated fifth quintile among the four regions, while the South has the highest concentrated first quintile. The Central region and Mexico City are more evenly distributed. Similarly, as income quintiles increase, the proportion of individuals in households that are recipients of social transfers decreases.

4. RESULTS

Probit estimation

Table 4 shows the results of probit regressions and their marginal effects on the probability of an individual being sorted into any category of the overweight–obese spectrum. The impact of income on the probability of having any of the characteristics mentioned is positive but minimal. Overall, being female and living in a rural area decreases the chances of someone being affected by the problem by 0.4 % and 1.7%.

Table 4
Probit Model for the Probability
of Being Overweight or Obese

Variables	Coefficient	Standard errors	Marginal effects	[95 % conf. Interval]	
Log of per capita income	0.039***	0.001	0.009	0.009	0.009
Female	-0.019***	0.001	-0.004	-0.005	-0.004
Obese mother	0.465***	0.002	0.107	0.106	0.107
HOH with higher education	0.075***	0.001	0.017	0.017	0.018
Rural	-0.076***	0.001	-0.017	-0.018	-0.017
Receives social transfers	0.046***	0.001	0.011	0.010	0.011
Has some type of health insurance	0.159***	0.002	0.037	0.036	0.037
Number of observations	7,408,427				
Pseudo R2	0.0183				

* p<0.1 ** p<0.05 *** p<0.01

Note: Own work using data from *ENSANUT*, 2018

On the contrary, receiving social transfers, having any form of health insurance, and living in a household where the head has achieved higher education, may increase the probability of someone being in the overweight-obesity spectrum. At the same time, having an obese or overweight mother impacts the change in probabilities the most, increasing an individual's chances by 10.7%.

Table 5 shows how the different variables impact an individual's chances of being overweight or obese. Living in a rural setting and having access to any health insurance are factors that decrease the probability of an individual being *overweight*.

Meanwhile, higher per capita income, being female, and mainly having an obese or overweight mother; are factors that increase an individual's chances of being *overweight*. Receiving social transfers is not a significant factor in determining a person's *overweight* status.

Table 5
*Probit Models for the Probability
of Being Overweight or Obese*

	Variables	Coefficient	Standard errors	Marginal effects	[95 % conf. Interval]	
Overweight	Log of per capita income	0.062***	0.001	0.018	0.017	0.018
	Female	0.059***	0.002	0.017	0.016	0.018
	Overweight or obese mother	0.325***	0.002	0.093	0.091	0.094
	HOH with higher education	0.012***	0.002	0.003	0.002	0.005
	Rural	-0.179***	0.002	-0.051	-0.052	-0.050
	Receives social transfers	-0.003	0.002	-0.001	-0.002	0.000
	Has any type of health insurance	-0.054***	0.003	-0.015	-0.017	-0.014
	Number of observations	2,920,879				
	Pseudo R2	0.0131				
Obesity	Log of per capita income	0.080***	0.001	0.018	0.017	0.018
	Female	-0.121***	0.002	-0.027	-0.027	-0.026
	Overweight or obese mother	0.498***	0.003	0.109	0.108	0.110
	HOH with higher education	-0.042***	0.002	-0.009	-0.010	-0.008
	Rural	0.070***	0.002	0.015	0.014	0.016
	Receives social transfers	0.028***	0.002	0.006	0.005	0.007
	Has any type of health insurance	0.060***	0.003	0.013	0.012	0.014
	Number of observations	2,920,879				
	Pseudo R2	0.0192				

* p<0.1 ** p<0.05 *** p<0.01

Note: Own work using data from *ENSANUT*, 2018

In addition, being a woman and living in a household in which the head achieved higher education are aspects that decrease the chances of someone being obese. In contrast, a higher per capita income, living in a rural area, and receiving social transfers and health insurance positively impact the probability of suffering from obesity. Like the *overweight* case, an individual with a mother in the overweight/obese spectrum has a 10.9% higher chance of being obese than someone without an overweight or obese mother.

Table 6
*Probit Model for the Probability
of Being Overweight or Obese by Income Quintile*

Income Quintile	Variables	Coefficient	Standard errors	Marginal effects	[95 % conf. Interval]	
1	Log of per capita income	-0.035***	0.002	-0.007	-0.008	-0.006
	Female	0.069***	0.002	0.014	0.013	0.015
	Overweight or obese mom	0.622***	0.003	0.127	0.126	0.129
	HOH with higher education	-0.159***	0.003	-0.033	-0.034	-0.031
	Rural	-0.033***	0.002	-0.007	-0.008	-0.006
	Receives social transfers	-0.088***	0.003	-0.018	-0.019	-0.017
	Has some type of health insurance	0.206***	0.004	0.042	0.041	0.044
	Number of observations	1,973,804				
	Pseudo R2	0.0309				
2	Log of per capita income	0.087***	0.009	0.021	0.017	0.024
	Female	-0.139***	0.002	-0.033	-0.034	-0.032
	Overweight or obese mom	0.457***	0.003	0.107	0.106	0.109
	HOH with higher education	0.026***	0.003	0.006	0.005	0.007
	Rural	-0.204***	0.003	-0.048	-0.049	-0.047
	Receives social transfers	-0.036***	0.002	-0.008	-0.010	-0.007
	Has some type of health insurance	0.186***	0.004	0.044	0.042	0.045
	Number of observations	1,750,975				
	Pseudo R2	0.0223				

3	Log of per capita income	-0.219***	0.011	-0.051	-0.056	-0.046
	Female	0.136***	0.002	0.032	0.031	0.033
	Overweight or obese mom	0.602***	0.004	0.141	0.139	0.143
	HOH with higher education	0.063***	0.003	0.015	0.014	0.016
	Rural	-0.017***	0.003	-0.004	-0.005	-0.003
	Receives social transfers	0.141***	0.003	0.033	0.032	0.034
	Has some type of health insurance	-0.035***	0.003	-0.008	-0.010	-0.007
	Number of observations	1,550,994				
	Pseudo R2	0.0258				
4	Log of per capita income	-0.143***	0.010	-0.033	-0.037	-0.028
	Female	-0.091***	0.003	-0.021	-0.022	-0.020
	Overweight or obese mom	0.483***	0.004	0.111	0.109	0.113
	HOH with higher education	0.251***	0.003	0.058	0.056	0.059
	Rural	0.045***	0.004	0.010	0.009	0.012
	Receives social transfers	0.021***	0.003	0.005	0.004	0.006
	Has some type of health insurance	0.223***	0.004	0.051	0.050	0.053
	Number of observations	1,248,844				
	Pseudo R2	0.0241				

* p<0.1 ** p<0.05 *** p<0.01

Note: Own work using data from *ENSANUT*, 2018

Table 6 (continuation)
Probit Model for the Probability of Being Overweight or Obese by Income Quintile

Income Quintile	Variables	Coefficient	Standard errors	Marginal effects	[95 % conf. Interval]	
5	Log of per capita income	0.034***	0.004	0.008	0.007	0.010
	Female	-0.111***	0.003	-0.028	-0.029	-0.026
	Overweight or obese mother	0.089***	0.004	0.022	0.020	0.024
	HOH with higher education	0.189***	0.003	0.047	0.045	0.049
	Rural	-0.134***	0.005	-0.034	-0.036	-0.031
	Receives social transfers	0.287***	0.003	0.072	0.070	0.073
	Has any type of health insurance	0.223***	0.004	0.056	0.053	0.058
	Number of observations	883,810				
	Pseudo R2	0.0203				

* p<0.1 ** p<0.05 *** p<0.01

Note: Own work using data from *ENSANUT*, 2018

Table 6 displays how the above-mentioned factors impact the probability of being in the overweight/obese spectrum depending on the income quintile in which an individual is located. To begin with, the impact of income on the probability of an individual being overweight or obese is not the same across all income quintiles. It starts negative in the first and lowest income quintile and changes to positive in the second. Next, it changes back to negative for the third and fourth quintiles, only to be positive again for the fifth income quintile, which encompasses the highest-earning population.

A factor that behaves similarly across all income quintiles is the variable that indicates whether someone has an obese

or overweight mother. For individuals in all income quintiles, having an overweight/obese mother increases their chances of being overweight or obese by up to 14.1% in the third quintile. The first, second, and fourth quintiles show marginal effects of 12.7%, 10.7%, and 11.1%, respectively, while the highest one demonstrates that having an obese mother increases an individual's *overweight* chances by only 2.2%.

The other factors behave differently across the income quintiles. In the first and third quintiles being a woman increases the overweight-obesity chances while the same factor decreases that probability for individuals in the other quintiles. Another factor that increases the *overweight* probability of a person is if they live in a household where the head has completed higher education; this occurs for all quintiles except the first one. Living in a rural rather than an urban setting can decrease the probability of being overweight or obese for individuals across all income quintiles except the fourth. The second and fifth quintiles show the highest probability reduction, 4.8% and 3.4%, respectively.

Receiving social transfers has been studied as a factor increasing the probability of being overweight or obese for individuals in different settings. These results show that for the two lowest income quintiles receiving social transfers such as food assistance programs or academic scholarships decreases the probability of obesity by 1.8% and 0.8%, respectively. For higher income quintiles, these programs increase the chances of being in the *overweight* spectrum. Meanwhile, access to health insurance (public or private) mainly increases the chances of someone being overweight or obese by up to 5.6% in the highest income quintile. This result is negative and the smallest on the third quintile, showing a 0.8% decrease in probability.

Table 7
Probit Model for the Probability of Being Overweight or Obese According to Mother's Weight Status

Mother's weight	Coefficient	Standard errors	Marginal effects	[95 % conf. Interval]	
Normal weight mother	-0.431***	0.0014	-0.0996	-0.1002	-0.0989
Number of observations	9,445,911				
Pseudo R2	0.0122				
Underweight mother	-0.804***	0.0074	-0.1876	-0.1909	-0.1842
Number of observations	9,500,578				
Pseudo R2	0.0020				
Overweight mother	-0.112***	0.0010	-0.0261	-0.0265	-0.0256
Number of observations	9,500,578				
Pseudo R2	0.0014				
Obese mother	0.366***	0.0010	0.0841	0.0873	0.0846
Number of observations	9,500,578				
Pseudo R2	0.0166				
Overweight or obese mother	0.456***	0.0014	0.1053	0.1046	0.1059
Number of observations	9,445,911				
Pseudo R2	0.0141				

* p<0.1 ** p<0.05 *** p<0.01

Note: Own work using data from *ENSANUT*, 2018

On the contrary, having a mother who is obese can increase someone's chances of being in the overweight/obese category by 8.41%; at the same time, if the mother is either overweight or obese, the chances go up by 10.53%. These probit models do not include control variables, and their only purpose is to illustrate how differently the weight status of the mother of an individual impacts their chances of being overweight or obese.

Table 7 shows how the mother's weight affects an individual's probability of being in the overweight/obese spectrum. As shown above, when an individual has an underweight, overweight, or

normally weighted mother, their chances of being overweight or obese decrease by 18.76% for those with underweight mothers, 9.96% for those with mothers in the standard weight threshold, and by only 2.61% for those with mothers who are only *overweight* but not any of the higher weight categories.

4.2 Discussion

All probit estimators show that the variable that has the most considerable impact on whether a person is overweight is not the income but whether the individual has an obese mother. This could signify that genetic and behavioral factors are more critical in determining overweight and obesity than income-related factors. Like the findings of Grow *et al.* (2010) mentioned before, results show that when the head of household has completed higher education (as opposed to lower education levels), individuals see their chances of being obese or overweight diminished. Nonetheless, it is essential to notice that Grow's study was done for children aged 6 to 18 in a primarily urban county in the United States. This may imply that the reasons why higher education may equal lower overweight-obesity rates in specific demographics may be completely different from one country to another.

Overall, increased per capita income lowers overweight-obesity chances for all quintiles except two and five. This is not enough information to claim that in recent years there has been a turning point in the income-obesity relationship for Mexico (a middle-income country), as Monteiro *et al.* (2007) proposed. Although the results of the marginal effects that income has on obesity are not uniform for all quintiles, they match the findings of Selçuk *et al.* (2023), where higher income also increases the chances of an individual being obese only in certain population

groups, in a study made for Turkey, another middle-income country like Mexico.

The differences among *ENSANUT*'s databases partially explain why analyzing the income-obesity relationship and how it has changed correctly is difficult. Since some editions of the survey report individuals' income as a categorical variable and others report it as a continuous one, it is difficult to unify the variable to a standard threshold. Pertinent income information would be beneficial in allowing us to understand if the income-obesity relationship has experienced a similar behavior to that previously found by Monteiro *et al.* (2001; 2007) for Brazil.

An individual's mother's weight is what most helps determine whether they will be on the overweight-obesity scale. Aceves-Martins *et al.* (2022) performed a comprehensive study regarding Mexican culture and childhood obesity; some mothers acknowledged that they would feed their children what they deemed *unhealthy* foods and drinks; otherwise, children would refuse to eat. This behavior likely leads mothers to feed their children what could be considered non-recommended food to get them to eat, even if it might be detrimental to their health in the long run.

Considering the results of Table 7, we now address how having an overweight or obese mother impacts children's probability of being overweight or obese themselves, by income quintile. Table 8 shows how likely it is for children under 18 years old in each income quintiles to be overweight or obese if their mother shares the same weight status.

Table 8
Probit Model for Children's Probability
of Being Overweight or Obese when Having
an Overweight or Obese Mother

Income Quintile	Variables	Coefficient	Standard errors	Marginal effects	[95 % conf. Interval]	
1	Overweight or obese mother	0.656***	0.004	0.225	0.222	0.228
	Number of observations	724,584				
	Pseudo R2	0.028				
2	Overweight or obese mother	0.434***	0.004	0.161	0.158	0.164
	Number of observations	688,679				
	Pseudo R2	0.013				
3	Overweight or obese mother	0.806***	0.005	0.298	0.294	0.301
	Number of observations	556,997				
	Pseudo R2	0.036				
4	Overweight or obese mother	0.603***	0.006	0.228	0.224	0.233
	Number of observations	405,451				
	Pseudo R2	0.022				
5	Overweight or obese mother	0.202***	0.006	0.079	0.075	0.084
	Number of observations	300,504				
	Pseudo R2	0.003				

* p<0.1 ** p<0.05 *** p<0.01

Note: Own work using data from *ENSANUT, 2018*

We can see how children in the middle-income quintile with an overweight or obese mother have up to 29.8% more chances of being in the overweight spectrum than their peers with underweight or regular weight mothers. Children in the highest-income quintile experience the smallest probability of being overweight or obese although they have an overweight or obese mother. It is not in the scope of this work to address

the mechanisms of how exactly a child may become overweight or obese depending on their mother's weight status. Still, we've established that their household's income level is integral to determining their weight. Reviewed literature suggests that the mother's education and cultural beliefs may partake in her choices towards her children's alimentary regime and leisure activities. Besides genetic patterns that are out of the limits of this research, societal factors can be considered a transmission mechanism of the mother's obesity to her children.

Moreover, Mexican mothers have been deemed the primary care and food providers, which means they are decision-makers on the types, quantity, and quality of food served to their children and other household members. Additionally, children's dietary habits often depend on their parent's schedules; this translates into fewer home-cooked meals and more food away from home, which the children themselves often purchase at school or other places. Overall, a main cultural factor that exacerbates the obesity problem is that obesity in children is often perceived as just an esthetic problem, for some Mexican mothers and grandmothers widely believe that overweight or "*chubby*" kids are healthier (Aceves-Martins, *et al.*, 2022).

5. Conclusion

During this study, we have established that there are several ways in which the relationship between income and obesity can be studied. It is firstly stated that income significantly impacts the health and nutrition status of families, given that low-income levels overburden a family's way of being in good health and consuming nutritious food. Nonetheless, it was made clear that although there is a consensus on how income level impacts health aspects like general well-being and nutrition deficiencies, there was not a general agreement on how income level affected

the overweight or obesity levels reported by health authorities in different groups of people in a specific country.

Next, we established that the relationship between income and obesity is an array of socioeconomic and demographic factors interacting to affect individuals' weight status. Just as relevant literature has examined how income and obesity interact with one another, income-related factors like cash transfers, globalization, the education level of individuals, especially heads of households have been able to affect obesity prevalence in specific areas.

This study aimed to demonstrate that income and obesity behaved differently across the various income groups in Mexico. To demonstrate the different impacts of income on the chances of an individual being obese or overweight depending on income quintiles, we used probit regressions. The results showed that the probability of someone being in the obesity spectrum increased with his/her per capita income in quintiles two and five. While the same probability decreased with higher income for quintiles one, three, and four, income's marginal effects on overweight/obesity were minimal.

Other variables that had a significant impact on obesity were having any type of health insurance, living in rural areas, and living in a household where its head achieved higher education. However, the factor that had the greatest impact across all quintiles was having an overweight or obese mother, which increased overweight and obesity probabilities by more than 10% in all income categories except the highest one, which only increased the probability by roughly 2%.

We showed that although income and socioeconomic variables are important when determining whether a person will be obese or overweight, in the end, the mother's weight status is a highly determinant variable on the matter. How socioeconomic factors impact mothers' decisions on the quantity and quality of

food they provide to their children and other household members is an inquiry that can be reserved for future investigations.

Among the limitations of this study were the nature of the data obtained from *ENSANUT* and the need for more consistency among different survey editions. Using regular and concurring surveys would help track how the relationship between an individual's income level and weight status behaves throughout the years. The probit regressions showed that, in most cases, higher income levels translated into a lower probability of obesity. This may have to do with how differently income is distributed among the population; Mexico ranks third in the countries with the highest income inequality amongst the members of the OECD. The distribution of income shown in Table 2 could serve to back this claim and possibly explain why the impact of income is so different across quintiles.

Given that the principal factor that was proven to increase the chances of being overweight or obese was having a mother who fell into either of these weight categories, forthcoming health, and social policies shall focus on improving mothers' dietary habits by bringing awareness of how important their well-being is for the health of their children and other household members. These policies should not be exclusive to lower-income families but to families of all income levels since the impact of a mother's weight was the variable with the most influence on weight.

In conclusion, we have made it evident that the relationship between income and obesity is not best represented as a positive or negative linear relationship. Still, it can be different depending on a person's income level. This shows us that upcoming policies to reduce overweight and obesity rates should be crafted according to the different income levels and socioeconomic statuses found nationwide.

REFERENCES

- Aceves-Martins, M., Llauradó, E., Tarro, L. *et al.* (2016). Obesity-promoting factors in Mexican children and adolescents: Challenges and opportunities. *Global Health Action*, 9(1). DOI: 10.3402/gha.v9.29625
- Aceves-Martins, M., López-Cruz, L., García-Botello, M. *et al.* (2022). Cultural factors related to childhood and adolescent obesity in Mexico: A systematic review of qualitative studies. *Obesity Reviews*, 23(9), e13461. DOI: 10.1111/obr.13461
- Ahluwalia, N., Herrick, K. A., Terry, A. L. *et al.* (2019). *Contribution of whole grains to total grains intake among adults aged 20 and over: United States, 2013–2016*. Hyattsville, MD: National Center for Health Statistics.
- Akee, R., Simeonova, E., Copeland, W. *et al.* (2013). Young adult obesity and household income: Effects of unconditional cash transfers. *American Economic Journal: Applied Economics*, 5(2), 1–28. DOI: 10.1257/app.5.2.1
- Ameye, H., & Swinnen, J. (2019). Obesity, income and gender: The changing global relationship. *Global Food Security*, 23, 267–281. DOI: 10.1016/j.gfs.2019.09.003
- Andalón, M. (2011). *Oportunidades* to reduce overweight and obesity in Mexico? *Health Economics*, 20(S1), 1–18. DOI: 10.1002/hec.1773
- Aydin, M. (2019). The effect of economic growth on obesity for the most obese countries: new evidence from the obesity Kuznets curve. *European Journal of Health Economics*, 20(9), 1349–1358. DOI: 10.1007/s10198-019-01099-2
- Barros, F. C., Victora, C. G., Scherpbier, R. *et al.* (2010). Socio-economic inequities in the health and nutrition of children in low/middle income countries. *Revista de Saúde Pública*, 44, 1–16. DOI: 10.1590/s0034-89102010000100001
- Bentley, R. A., Ormerod, P., & Ruck, D. J. (2018). Recent origin and evolution of obesity-income correlation across the United

- States. *Palgrave Communications*, 4, 146. DOI: 10.1057/s41599-018-0201-x
- Benzeval, M., & Judge, K. (2001). Income and health: the time dimension. *Social Science & Medicine*, 52(9), 1371-1390. DOI: 10.1016/S0277-9536(00)00244-6
- Broadly, K. E., & Meeks, A. G. (2015). Obesity and social inequality in America. *Review of Black Political Economy*, 42(3), 201-209. DOI: 10.1007/s12114-014-9202-1
- Catenacci, V. A., Hill, J. O., & Wyatt, H. R. (2009). The obesity epidemic. *Clinics in Chest Medicine*, 30(3), 415-444. DOI: 10.1016/j.ccm.2009.05.001
- Cawley, J. (2015). An economy of scales: A selective review of obesity's economic causes, consequences, and solutions. *Journal of Health Economics*, 43, 244-268. DOI: 10.1016/j.jhealeco.2015.03.001
- Clément, M., Lavasseur, P., Seetahul, S. *et al.* (2021). Does inequality have a silver lining? Municipal income inequality obesity in Mexico. *Social Science and Medicine*, 272, 113710. DOI: 10.1016/j.socscimed.2021.113710
- Colchero, M. A., Salgado, J. C., Unar-Munguía, M. *et al.* (2015). Price elasticity of the demand for sugar sweetened beverages and soft drinks in Mexico. *Economics and Human Biology*, 19(129), 37. DOI: 10.1016/j.ehb.2015.08.007
- Cotta, R., & Machado, J. (2013). The Bolsa Familia cash transfer programs and food and nutrition security in Brazil: A critical review of the literature. *Revista Panamericana de Salud Pública*, 33(1), 54-60. DOI: 10.1590/s1020-49892013000100008
- Darmon, N., & Drewnowski, A. (2008). Does social class predict diet quality? *American Journal of Clinical Nutrition*, 87(5), 1107-1117. DOI: 10.1093/ajcn/87.5.1107
- Dinsa, G. D., Goryakin, Y., Fumagalli, E. *et al.* (2012). Obesity and socioeconomic status in developing countries: a system-

- atic review. *Obesity Reviews*, 13(11), 1067-1079. DOI: 10.1111/j.1467-789x.2012.01017.x
- Fernald, L. C. H. (2007). Socio-economic status and body mass index in low-income Mexican adults. *Social Science & Medicine*, 64(10), 2030-2042. DOI: 10.1016/j.socscimed.2007.02.002
- Fernald, L. C. H., Gertler, P. J., & Neufeld, L. M. (2008a). Role of cash in conditional cash transfer programmes for child health, growth, and development: and analysis of Mexico's *Oportunidades*. *The Lancet*, 371(9615), 828-837. DOI: 10.1016/S0140-6736(08)60382-7
- Fernald, L. C. H., Hou, X., & Gertler, P. J. (2008b). *Oportunidades* program participation and body mass index, blood pressure, and self-reported health in Mexican adults. *Preventing Chronic Disease*, 5(3), A81. PMID: 18558031
- Flores, M., Carrión, C., & Barquera, S. (2005). Sobrepeso materno y obesidad en escolares mexicanos: Encuesta Nacional de Nutrición, 1999. *Salud Pública de México*, 47(6), 447-450. <https://www.scielosp.org/pdf/spm/v47n6/a09v47n6.pdf>
- Forde, I., Chandola, T., Garcia, S. *et al.* (2012). The impact of cash transfers to poor women in Colombia on BMI and obesity: Prospective cohort study. *International Journal of Obesity*, 36(9), 1209-1214. DOI: 10.1038/ijo.2011.234
- Garza-Montoya, B. G., & Ramos-Tovar, M. E. (2017). Cambios en los patrones de gasto en alimentos y bebidas de hogares mexicanos (1984-2014). *Salud Pública de México*, 59(6), 612-620. DOI: 10.21149/8220
- Gordon-Larsen, P., Nelson, M. C., Page, P. *et al.* (2006). Inequality in the built environment underlies key health disparities in physical activity and obesity. *Pediatrics*, 117(2), 417-424. DOI: 10.1542/peds.2005-0058
- Greco, A. M., & Rothhoff, K. W. (2015). Economic growth and obesity: findings of an obesity Kuznets curve. *Applied Economics Letters*, 22(7), 539-543. DOI: 10.1080/13504851.2014.955251

- Grow, H. M. G., Cook, A. J., Arterburn, D. E. *et al.* (2010). Child obesity associated with social disadvantage of children's neighborhoods. *Social Science and Medicine*, 71(3), 584-891. DOI: 10.1016/j.socscimed.2010.04.018
- Hill, J. O., & Peters, J. C. (1998). Environmental contributions to the obesity epidemic. *Science*, 280(5368), 1371-1374. DOI: 10.1126/science.280.5368.1371
- Instituto de Seguridad y Servicios Sociales de los Trabajadores del Estado [ISSSTE] (2020). *Mata la obesidad a 41 millones de personas cada año en el mundo*. <https://www.gob.mx/issste/prensa/mata-la-obesidad-a-41-millones-de-personas-cada-ano-en-el-mundo?idiom=es-MX>
- Jo, Y. (2014). What money can buy: Family income and childhood obesity. *Economics and Human Biology*, 15, 1-12. DOI: 10.1016/j.ehb.2014.05.002
- Kaushal, N. (2007). Do food stamps cause obesity? Evidence from immigrant experience. *Journal of Health Economics*, 26(5), 968-991. DOI: 10.1016/j.jhealeco.2007.01.006
- Kim, Y., Landgraf, A., & Colabianchi, N. (2020). Living in high-SES neighborhoods is protective against obesity among higher-income children but not low-income children: Results from the Healthy Communities Study. *Journal of Urban Health*, 97(2), 175-190. DOI: 10.1007/s11524-020-00427-9
- Lamerz, A., Kuepper-Nybelen, J., Wehle, C. *et al.* (2005). Social class, parental education, and obesity prevalence in a study of six-year-old children in Germany. *International Journal of Obesity*, 29(4), 373-380. DOI: 10.1038/sj.ijo.0802914
- Levasseur, P. (2019). Can social programs break the vicious cycle between poverty and obesity? Evidence from urban Mexico. *World Development*, 113, 143-156. DOI: 10.1016/j.worlddev.2018.09.003
- McLaren, L. (2007). Socioeconomic status and obesity. *Epidemiologic Reviews*, 29(1), 29-48. DOI: 10.1093/epirev/mxm001

- Mendoza-Herrera, K., Pedroza-Tobías, A., Hernández-Alcaraz, C. *et al.* (2019). Attributable burden and expenditure of cardiovascular diseases and associated risk factors in Mexico and other selected mega-countries. *International Journal of Environmental Research and Public Health*, 16(20), 4041. DOI: 10.3390/ijerph16204041
- Miller, J. E., & Korenman, S. (1994). Poverty and children's nutritional status in the United States. *American Journal of Epidemiology*, 140(3), 233-243. DOI: 10.1093/oxfordjournals.aje.a117242
- Misra, A., & Khurana, L. (2008). Obesity and the metabolic syndrome in developing countries. *The Journal of Clinical Endocrinology & Metabolism*, 93(11 supplement 1), s9-s30. DOI: 10.1210/jc.2008-1595
- Monteiro, C. A., Conde, W. L., & Popkin, B. M. (2001). Independent effects of income and education on the risk of obesity in the Brazilian population. *Journal of Nutrition*, 131(3), 881S-886S. DOI: 10.1093/jn/131.3.881S
- Monteiro, C. A., Conde, W. L., & Popkin, B. M. (2007). Income-specific trends in obesity in Brazil: 1975-2003. *American Journal of Public Health*, 97(10), 1808-1812. DOI: 10.2105/AJPH.2006.099630
- Morales-Ruán, M. C., Méndez-Gómez H., I., Shamah-Levy, T. *et al.* (2014). La inseguridad alimentaria está asociada con obesidad en mujeres adultas de México. *Salud Pública de México*, 56(c1), s54-s61. <https://www.scielo.org.mx/pdf/spm/v56s1/v56s1a9.pdf>
- Murphy, R., Stewart, A. W., Hancox, R. J. *et al.* (2018). Obesity, underweight and BMI distribution characteristics of children by gross national income and income inequality: results from an international survey. *Obesity Science and Practice*, 4(3), 216-228. DOI: 10.1002/osp4.169

- Nghiem, S., & Khanam, R. (2016). Childhood obesity and the income gradient: Evidence from Australia. *Applied Economics*, 48(50), 4813-4822. DOI: 10.1080/00036846.2016.1164827
- Ogden, C. L., Fakhouri, T. H., Carroll, M. D. *et al.* (2017). Prevalence of obesity among adults, by household income and education – United States, 2011-2014. *Morbidity and Mortality Weekly Report*, 66(50), 1369-1373. DOI: 10.15585/mmwr.mm6650a1
- Olvera-Ezzel, N., Power, T. G., & Cousins, J. H. (1990). Maternal socialization of children's eating habits: Strategies used by obese Mexican-American mothers. *Child Development*, 61(2), 395-400.
- Otero, G., Gürcan, E. C., Pechlaner, G. *et al.* (2018). Food security, obesity, and inequality: Measuring the risk of exposure to the neoliberal diet. *Journal of Agrarian Change*, 18(3), 536-554. DOI: 10.1111/joac.12252
- Ponce-Alcalá, R. E., Ramírez-García Luna, J. L., Shamah-Levy, T. *et al.* (2021). The association between household food insecurity and obesity in Mexico: a cross-sectional study of ENSANUT MC 2016. *Public Health Nutrition*, 24(17), 5826-5836. DOI: 10.1017/S1368980021003153
- Raccanello, K. (2020). Inseguridad alimentaria, sobrepeso y obesidad en la Ciudad de México. *Papeles de Población*, 26(104), 239-264. DOI: 10.22185/24487147.2020.104.18
- Rivera, J. A., Barquera, S., Campirano, F. *et al.* (2002). Epidemiological and nutritional transition in Mexico: Rapid increase of non-communicable chronic diseases and obesity. *Public Health Nutrition*, 5(1A), 113-122. DOI: 10.1079/PHN2001282
- Rodríguez-Olveros, G., Haines, J., Ortega-Altamirano, D. *et al.* (2011). Obesity determinants in Mexican preschool children: parental perceptions and practices related to feeding and physical activity. *Archives of Medical Research*, 42(6), 532-539. DOI: 10.1016/j.arcmed.2011.10.006

- Salomón, A. (2005). La industria alimentaria en México. *Comercio Exterior*, 55(3), 242-257. <http://revistas.bancomext.gob.mx/rce/magazines/76/4/RCE.pdf>
- Selçuk, I. Ş., Köktaş, A. M., & Toygar, Ş. A. (2023). Socioeconomic factors affecting the probability of obesity: Evidence from a nationwide survey in Turkey. *Quality & Quantity*, 57(1), 239-255. DOI: 10.1007/s11135-022-01362-4
- Shamah-Levy, T., Vielma-Orozco, E., Heredia-Hernández, O. et al. (2020). *Encuesta nacional de salud y nutrición 2018-19: Resultados nacionales*. Cuernavaca, Morelos: Instituto Nacional de Salud Pública.
- Shamah-Levy, T., Cuevas-Nasu, L., Gaona-Pineda, E. B. et al. (2022). Childhood obesity in Mexico: influencing factors and prevention strategies. *Frontiers in Public Health*, 10, 949893. DOI: 10.3389/fpubh.2022.949893
- Su, D., Esqueda, O. A., Li, L. et al. (2012). Income inequality and obesity prevalence among OECD countries. *Journal of Biosocial Science*, 44(4), 417-432. DOI: 10.1017/S002193201100071X
- Trogdon, J. G., Nonnemaker, J., & Pais, J. (2008). Peer effects in adolescent overweight. *Journal of Health Economics*, 27(5), 1388-1399. DOI: 10.1016/j.jhealeco.2008.05.003
- Warden, N. A. S., & Warden, C. H. (2001). Biological influences on obesity. *Pediatric Clinics of North America*, 48(4), 879-891. DOI: 10.1016/S0031-3955(05)70346-1
- Wilding, J. P. H. (2001). Causes of obesity. *Practical Diabetes International*, 18(8), 288-292. DOI: 10.1002/pdi.277
- Windarti, N. A. N., Hlaing, S. W., & Kakinaka, M. (2019). Obesity Kuznets curve: international evidence. *Public Health*, 169, 26-35. DOI: 10.1016/j.puhe.2019.01.004
- World Health Organization. (2021). *Obesity and overweight*. <https://www.who.int/news-room/fact-sheets/detail/obesity-and-overweight>

Zavala, G. A., Kolovos, S., Chiarotto, A. *et al.* (2018). Association between obesity and depressive symptoms in Mexican population. *Social Psychiatry and Psychiatric Epidemiology*, 53(6), 639-646. DOI: 10.1007/s00127-018-1517-y

Malnutrición y desempeño académico en México: un análisis de niños en 6° grado de primaria

*Cristian Cárdenas Mora**

*Willy W. Cortez***

Resumen

En este trabajo se analiza la posible relación que existe entre la malnutrición y el desempeño académico en niñas y niños de sexto grado de primaria en México para el año 2016. Para ello, se utiliza la información proporcionada por el Registro Nacional de Peso y Talla (RNPT) y la prueba de conocimientos del Plan Nacional para la Evaluación de los Aprendizajes (PLANEA). Utilizando un modelo Logit, los resultados sugieren que existe una relación positiva entre malnutrición y pobre desempeño académico.

* Departamento de Nómina del Resto del Ejecutivo, Tesorería General de la Secretaría de la Hacienda Pública del Gobierno de Jalisco.

** Departamento de Métodos Cuantitativos, CUCEA, Universidad de Guadalajara.

Introducción

Dos problemas que la población infantil en México ha venido enfrentando desde principios de siglo son, por un lado, el creciente número de niños(as) con sobrepeso y obesidad, y, por el otro, el mediocre desempeño académico. Existe un acuerdo generalizado que la malnutrición infantil es un problema serio de salud pública a nivel mundial por las consecuencias que ésta tiene sobre la salud posterior del niño(a) ya que lo vuelve más propenso a adquirir otro tipo de comorbilidades como presión sanguínea alta, problemas cardíacos, diabetes, cáncer, entre otros. El pobre desempeño académico también tiene serias consecuencias en el bienestar de los niños(as) al limitar el desarrollo de sus capacidades intelectuales que les permitan el acceso a mercados de trabajo bien remunerados.

De acuerdo con la organización Mundial de la Salud (OMS), la malnutrición se refiere a las carencias, los excesos y los desequilibrios de la ingesta calórica y de nutrientes de una persona. Existen cuatro grupos de afecciones que son catalogadas como malnutrición: i) la desnutrición que incluye peso insuficiente para la talla, retraso en el crecimiento (talla insuficiente para la edad), y un peso insuficiente para la edad; ii) la malnutrición relacionada con las carencias de nutrientes, (falta de minerales y vitaminas); iii) exceso de micronutrientes, el sobrepeso y la obesidad, y iv) las enfermedades no transmisibles relacionadas con la alimentación como las cardiopatías, la diabetes y algunos tipos de cáncer. Para propósitos de este estudio, malnutrición infantil se refiere a las afecciones de salud de niños(as) como el sobrepeso, obesidad o retraso en el crecimiento.

Soliman et al., (2021) encuentran que la malnutrición, particularmente el retraso en el crecimiento ocasiona diversos problemas como aumento en la mortalidad, en el riesgo a contraer infecciones más fácilmente, y limita las capacidades de aprendizaje del niño(a). Maluccio et al., (2009) y Gertler et al.,

(2021), por otro lado, sostienen que la nutrición y la estimulación temprana tienen un efecto importante en la escolaridad y el desarrollo humano, lo cual inciden de manera significativa sobre los ingresos y el salario cuando adultos.

Según datos obtenidos de la Encuesta Nacional de Salud y Nutrición (ENSANUT) del año 2018, cerca del 8.2% de niños de 0 a 4 años tienen sobrepeso. Entre los niños de 5 a 11 años, el 18.1% tiene sobrepeso y el 17.5% tiene obesidad. El problema de sobrepeso y obesidad persiste en la adolescencia ya que el 38.4% de jóvenes entre 12 y 19 años sufrían de sobrepeso u obesidad. Al hacer un análisis por género, se encuentra que el problema de sobrepeso y obesidad es mayor entre las mujeres comparado con los hombres: 41.1% vs 35.8%, respectivamente. En lo que se refiere al retraso en el crecimiento, se encontró que 12.7% de niños entre 0 y 2 años padecen de este problema, mientras que entre los niños entre 2 y 5 años el porcentaje es de 10.8%. Las entidades con los porcentajes más elevados son: estado de México (19.4%), Puebla (18.8%) y Coahuila (18.3%). El porcentaje de niños entre 0 y 5 años con desnutrición fue de 3.6% a nivel nacional. En un análisis a nivel estatal de este indicador se encuentra que el estado de México es la entidad con el porcentaje más alto de niños con desnutrición, 8.9%, seguido de Oaxaca, Coahuila y Quintana Roo con 5.7%, 5.6% y 5.3%, respectivamente.

En lo que respecta al desempeño académico de los jóvenes mexicanos, las diversas participaciones de los estudiantes en pruebas estandarizadas de conocimientos en matemáticas y en comprensión de lectura a nivel internacional no son nada halagüeñas. De acuerdo con los resultados del Programa para la Evaluación Internacional de Alumnos (PISA), que organiza la Organización para la Cooperación y Desarrollo Económico (OCDE), México ha terminado en los últimos lugares entre los 37 países que participan en dicha prueba.

El pobre desempeño académico está asociado al rezago educativo existente en México. De acuerdo con el reporte del Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONVEVAL), en los últimos años el porcentaje de personas que tienen algún tipo de rezago educativo aumentó de manera sistemática. En 2016 cerca de 18.5% de la población tenía rezago educativo, para 2018 éste aumentó a 19% y para 2020 fue aún mayor: 19.2%.

Diversos estudios han logrado identificar los factores de riesgo del desarrollo educativo. Estos factores se pueden agrupar en cuatro bloques. Primero, las características personales de los niños, jóvenes. Segundo, los antecedentes familiares y ambiente del hogar. Tercero, los factores asociados a la escuela, y, Cuarto, factores institucionales que inciden sobre el desenvolvimiento educativo de la región/ país. Hoyos, Espino y García (2012) hacen notar que aún no se ha logrado determinar cuál de estos grupos es el determinante. Es importante notar que la niñez es una etapa importante en el desarrollo de habilidades cognitivas. Cualquier retraso en el desarrollo infantil limita grandemente la formación de capital humano en el largo plazo (Attanasio, 2015; Soliman et al., 2021). Mayer Foulkes (2008) argumenta que la poca acumulación de capital humano en la sociedad mexicana ha traído consigo un desarrollo económico estancado, lo que se refleja en que una gran parte de la población no tiene la posibilidad de acceder a empleos mejor remunerados.

Los diversos estudios realizados sobre la relación entre ambos problemas encuentran que, en efecto, el sobrepeso y la obesidad representan factores de riesgo para un pobre desempeño académico. Sin embargo, una característica importante de estos estudios es que están basados en estudios de casos a diversos segmentos de la población. Hasta donde tenemos conocimiento, no existen estudios a nivel nacional que hayan encontrado algún tipo de relación entre malnutrición y desempeño académico para

el caso mexicano. En lo que sigue tratamos de proponer una metodología de análisis que nos permita evaluar de manera más clara la relación entre ambas variables, si es que existe.

El presente estudio busca responder a la siguiente pregunta de investigación: ¿existe alguna relación entre la malnutrición infantil y el desempeño académico de los niños? En la medida que los problemas de educación y de salud son más notorios en las regiones rurales, se plantea la pregunta de si la relación entre ambas variables es distinta a la existente en zonas urbanas. Debido a la falta de datos, el análisis se limita a estudiantes de sexto de primaria para el año 2016.

El presente trabajo se divide en cinco secciones. En la primera sección se presenta una breve descripción de la problemática que aborda la investigación. En esta sección se incluye una revisión de la literatura sobre malnutrición infantil y desempeño académico. La sección 2 extiende el análisis al presentar un panorama histórico de la evolución del desempeño académico y de la educación básica en México. La sección 3, Datos y Estadística, presenta y discute las distintas fuentes de información.

1. Malnutrición y Desempeño Académico en niños de educación primaria.

En esta sección se presenta una revisión de diversos artículos de investigación, así como informes en relación con el estudio de las condiciones de salud de la niñez, al igual que el análisis del desarrollo académico de los menores. Investigaciones sobre las consecuencias de la malnutrición, retraso del crecimiento y problemas de sobrepeso, concuerdan que padecimientos de este tipo en edades tempranas tienen consecuencias irreparables en la salud, además de que pueden persistir en la adultez (Grantham-McGregor *et al.*, 1999a, 1999b; Cornelio-Nieto, 2007; Dewey y Begum,

2011; Attanasio, 2015; Nasir, 2016; Wu *et al.*, 2017; Devaux y Vuik, 2019; Soliman *et al.*, 2021).

Grantham-McGregor *et al.* (1999b) realizan una revisión de literatura sobre los estudios realizados acerca de los problemas de salud en edades tempranas; consideran las deficiencias de yodo, de hierro, infecciones por parásitos, diarrea e infecciones respiratorias como factores de riesgo sobre el desarrollo intelectual de los niños. De acuerdo con la revisión de la literatura que realizan, concluyen que ciertas enfermedades tienen fuerte presencia en determinadas zonas y además, a pesar de las discrepancias en las metodologías de análisis, existen ciertas afectaciones y complicaciones en el desarrollo intelectual de los niños.

Siguiendo la misma línea de investigación, Cornelio-Nieto (2007) realiza una revisión acerca de estudios que se centran en desnutrición por deficiencia proteico-calórica y sus afectaciones al sistema nervioso central (SNC) de los niños. De acuerdo con la revisión, existen evidencias de alteraciones físicas y daños en el SNC. Estas alteraciones pueden ser desde anatómicas y funcionales, hasta retrasos en el desarrollo psicomotor, diferencias intelectuales y trastornos en el aprendizaje.

Dewey y Begum (2011), a su vez, identifican los factores por los cuales se puede padecer un retraso de crecimiento. Estos factores relacionan desnutrición en la etapa de gestación con infecciones crónicas durante la infancia. Abordando los factores de gestación, Nasir (2016) argumenta que la exposición a situaciones de estrés, como violencia, afecta la salud física y el desarrollo cognitivo de los niños en el largo plazo.

Soliman *et al.* (2021), por otro lado, realizan una explicación detallada sobre las consecuencias tempranas y de largo plazo de la malnutrición, principalmente el retraso del crecimiento. Estos autores encuentran diez consecuencias plenamente identificadas: 1) incremento en la morbilidad y mortalidad, 2) pobres capacidades de desarrollo y aprendizaje infantil, 3) mayor riesgo de

infecciones y enfermedades no transmitibles, 4) aumento de la susceptibilidad a acumular grasa, principalmente en la región central del cuerpo, 5) menor oxidación de grasas, 6) menor gasto de energía, 7) resistencia a la insulina, 8) aumento en el riesgo de desarrollar diabetes, hipertensión y dislipidemia, 9) disminución en las capacidades de trabajo y 10) resultados reproductivos maternos desfavorables en la edad adulta. Además, si niñas y niños con retraso del crecimiento experimentan después de los dos primeros años un acelerado aumento de peso, son propensos a tener sobrepeso u obesidad más adelante en la vida. Un aspecto importante sobre el retraso de crecimiento está dado por las etapas o ventanas de vulnerabilidad que se consideran durante la gestación y los primeros 24 meses posteriores al nacimiento debido a que son particularmente críticos en el desarrollo del cerebro, sin embargo, la adolescencia también es una etapa vulnerable (Attanasio, 2015).

Devaux y Vuik (2019) muestran los diferentes problemas que se relacionan al sobrepeso y la obesidad infantil. Los problemas se agrupan en tres grandes tipos: i) problemas biológicos, ii) problemas conductuales y iii) problemas emocionales y mentales. En el primer núcleo se relacionan ciertas enfermedades al síndrome metabólico –enfermedades cardiovasculares; presión alta, hiperglucemia y dislipidemia. En el segundo grupo, problemas conductuales, se relaciona el sobrepeso y/o obesidad con malos hábitos como falta de actividad física o patrones de consumo que conllevan a una nutrición deficiente. Por último, en el núcleo de los problemas emocionales y mentales se relacionan la obesidad y/o sobrepeso con baja autoestima y acoso. Además, en este trabajo también se describe cómo las consecuencias de la obesidad y el sobrepeso infantil funcionan como mecanismo de transmisión en la afectación al bajo logro académico y el abandono escolar.

Por último, Wu *et al.* (2017) encuentran que el sobrepeso y la obesidad infantil afectan al desempeño académico mediante un efecto parcial indirecto causado por un déficit de memoria mostrado por los niños que tienen obesidad, por lo que se puede considerar que la obesidad infantil está asociada parcialmente con el bajo desempeño académico mediante el déficit en las habilidades de memoria de los menores. Existe un consenso generalizado de que las etapas de vulnerabilidad, *i. e.*, cuando la malnutrición afecta el desarrollo futuro del niño, son principalmente el periodo de gestación y los primeros 24 meses después del nacimiento. También se puede identificar que los factores sociodemográficos tienen una fuerte incidencia en la desnutrición, diarrea e infecciones crónicas, los cuales limitan el desarrollo infantil (Grantham-McGregor *et al.*, 1999b; Soliman *et al.*, 2021).

*

En lo que respecta a los factores que determinan el desarrollo académico y su relación con la malnutrición infantil. Existe una vasta literatura que identifica los determinantes del desempeño. Estos factores operan a nivel individual, familiar y escolar (Hoyos *et al.*, 2012; Weiss y García, 2015). Weiss y García (2015), por ejemplo, realizan una serie de estimaciones de modelos multinivel de intersección aleatoria para explicar la relación entre el rendimiento académico y el compromiso que tienen los estudiantes con la escuela o con sus profesores. Este modelo considera el rendimiento académico con el puntaje obtenido en la prueba de Matemáticas de la prueba PISA de 2003 para México. Las estimaciones controlan por diversos factores como lo son los individuales, escolares y los antecedentes familiares. Al comparar los resultados de las estimaciones, los autores concluyen que el compromiso de los alumnos con la escuela tiene una relación positiva con el rendimiento académico; es decir, a mayor compromiso, mejor rendimiento académico de los

estudiantes. Aun más, el tamaño del efecto es comparable con factores socioeconómicos.

Hoyos *et al.* (2012) analizan el impacto de determinados factores sobre el logro académico de los estudiantes de Media Superior en la prueba ENLACE¹⁹. Estos autores agrupan a los factores en 4 grandes rubros: 1) características personales, 2) antecedentes familiares y ambiente del hogar, 3) factores asociados a la escuela y 4) factores institucionales. Ellos proponen una función de producción donde los resultados de la prueba ENLACE-MS del año 2008 es la variable dependiente. Los autores realizan un análisis de discriminante para no violar el criterio de parsimonia por cada factor, por lo que proceden a realizar estimaciones de mínimos cuadrados ordinarios para calcular el R^2 del modelo y contrastar el grado explicativo de cada factor mediante el contraste de modelos. Concluyen que los factores personales o individuales de los estudiantes explican gran proporción de la varianza de la función de producción educativa, seguido de los recursos escolares, el entorno institucional y finalmente los factores familiares.

Diversos estudios a nivel internacional han evaluado el impacto de intervenciones o programas para el desarrollo infantil sobre la escolaridad, el ingreso y empleo. Gertler *et al.* (2021), por ejemplo, analizan el impacto de una intervención domiciliaria de dos años diseñada para mejorar la calidad de las interacciones madre-hijo. El objetivo es desarrollar habilidades cognitivas, de lenguaje y psicosociales, dirigida a niños desfavorecidos con retraso del crecimiento que vivían en barrios pobres de Kingston en Jamaica. Estos autores evaluaron el efecto causal de este programa 29 años después de la intervención. El grupo de tratamiento fue definido como aquellos participantes

19 Evaluación Nacional del Logro Académico en Centros Escolares en Educación Media Superior (ENLACE-MS).

que recibieron estimulación temprana y suplemento nutrimental, mientras que el grupo de control, fueron los participantes que no recibieron estimulación temprana, pero que sí recibieron suplemento nutrimental. Entre los resultados se encontró que los ingresos por trabajo fueron mayores en las personas del grupo de tratamiento, 43% mayor en hombres y 37% en mujeres. Además, la escolaridad promedio de los participantes con tratamiento fue mayor a los participantes en el grupo de control. La probabilidad de recibir un diploma de educación superior también fue mayor en un 26% en el grupo de tratamiento con respecto al grupo de control.

Walker *et al.* (2005), en un estudio complementario al trabajo de Gertler *et al.* (2021), no encuentran efecto significativo de largo plazo del suplemento alimentario dado a los niños. La razón principal, según los autores, es que ambos grupos (el de tratamiento y el de control) recibieron dicho suplemento nutricional. En todo caso, los efectos positivos observados los atribuyen a la estimulación temprana recibida por el grupo de tratamiento. Sin embargo, Maluccio *et al.* (2009) realizaron una intervención similar a la realizada en Jamaica, pero en Guatemala. Ellos encuentran que sí existen beneficios de largo plazo atribuibles a la nutrición. Según los autores, la diferencia en los resultados se debe a la forma de implementación de los suplementos nutricionales, ya que en el caso de Jamaica los paquetes nutricionales se entregaban a las familias de los niños beneficiados, mientras que en Guatemala se administraban directamente a los niños en centros de salud.

Mayer-Foulkes (2008) realizó un estudio sobre la trampa de desarrollo humano en México, por lo que en un apartado de su trabajo estudia la relación de la salud con la probabilidad de seguir estudiando. Él propuso una metodología de estimación probit con datos de la Encuesta Nacional de Salud (ENSA) del año 2000 para jóvenes de 17 a 19 años de edad. Toma la variable de estatura

como indicador de nutrición infantil en los resultados de sus estimaciones –la estatura es estadísticamente significativa para el aumento en la probabilidad de seguir estudiando– y concluye que las mejoras en la nutrición tendrían un impacto considerable en la distribución de los estudios; es decir que con mejoras en la nutrición existen mayores probabilidades de seguir estudiando.

Mendoza (2019), por otro lado, realizó una estimación del efecto de la malnutrición en el desempeño escolar en las 25 regiones en Perú mediante un modelo econométrico. El autor tomó información de menores que cursaban el segundo año de educación básica para el periodo de 2010-2016. En su modelo, la variable dependiente es el desempeño escolar medido como el porcentaje de estudiantes de segundo año de educación básica con logro académico satisfactorio en Matemáticas y Comprensión de lectura en la prueba nacional. Como variables independientes se utiliza el porcentaje de niños menores de 5 años de edad con malnutrición crónica, las características de las escuelas y de las regiones, así como por el gasto del gobierno. Los resultados fueron los esperados, los signos de los coeficientes de malnutrición fueron negativos, para Matemáticas fue de -0.027 y para Comprensión de lectura fue de -0.518, a lo que concluye que la malnutrición tiene un efecto negativo en el desempeño escolar de los niños de Perú, y que la malnutrición tiene un efecto mayor sobre el logro escolar en Comprensión de lectura que en Matemáticas.

En resumen, basado en la literatura revisada se propone una función de producción del logro académico donde las variables independientes serán consideradas los factores individuales de los menores y las características de su entorno, tanto socioeconómicas como geográficas.

$$\varphi = f(I, SE, G) \quad (1)$$

Donde φ denota el logro académico, I representa las características antropométricas de los menores, donde se incluye si el menor tiene, o no, alguna de las tres condiciones que se están estudiando; a saber, retraso en el crecimiento, el sobrepeso y la obesidad; SE denota el entorno socioeconómico del niño, así como el nivel de pobreza o vulnerabilidad a la que se desenvuelve el menor; G , por último, denota las características geográficas del municipio en el que vive.

Se asume que las condiciones de salud desfavorables de los menores tienen efectos negativos en el logro académico. Además, las características de su entorno, tanto socioeconómicas como demográficas tendrían efectos negativos en el logro académico de los menores, si las características de su entorno son desfavorables. Si las características socioeconómicas de la región o localidad donde vive el menor reflejan un entorno con elevadas tasas de pobreza, o un alto nivel de rezago educativo, se espera que desarrollo educativo de la región o localidad sea limitado. Si el municipio en el que vive el menor tiene una población mayormente concentrada en localidades rurales, se espera que el nivel de desempeño académico sea deficiente.

2. Contexto Educativo y Nutricional en México

En esta subsección se presenta un panorama histórico general sobre el desarrollo en educación básica y del problema nutricional en niños de México. Empezaremos por discutir el problema educativo.


Como se mencionaba en un inicio, México no ha tenido un desarrollo favorable en la prueba PISA. A través de los años no ha mostrado un cambio significativo en la evaluación de logro académico, México ha participado en esta prueba desde el año 2000 hasta el año 2018 que ha sido la más reciente, a lo largo de estos 18 años se han realizado 7 pruebas (2000, 2003, 2006, 2012, 2015 y

2018), en las cuales se ha evaluado la Comprensión de lectura en cada una de ellas. Por otra parte, en Matemáticas se ha evaluado en 6 ocasiones (2003, 2006, 2012, 2015 y 2018) y por último, en 2006 se añadió la materia de ciencias contando con 5 evaluaciones (2006, 2012, 2015 y 2018). En las siguientes gráficas se muestran los valores comparativos de México con el resto de los países en esta misma prueba y su comparación con el resultado promedio de los países de la OCDE.

Las Figuras 1, 2 y 3, muestran los resultados promedio de las pruebas en Comprensión de lectura, Matemáticas y Ciencias de la prueba PISA en 2000 y 2018, respectivamente. Como se observa, en ambos periodos México se ubica en el penúltimo o en último lugar en valores promedios, mientras que Canadá y Estados Unidos están alrededor de la media o por encima de ella. Se debe notar, sin embargo, que Chile y Colombia tienen comportamientos similares a los de México. En la comparación agregada de la media general de los países de que integran la OCDE, observamos que esta media está uno o dos niveles por encima de la media de México, mientras la media de la OCDE esta un nivel por encima del nivel mínimo aprobatorio. Por ende, México se encuentra con un nivel mínimo aprobatorio o en niveles reprobatorios.

En resumen, el sistema educativo mexicano tiene un pobre o nulo desarrollo en el logro académico, es decir que, de acuerdo con los resultados de la prueba PISA, las niñas y niños de México, en promedio, no cuentan con las aptitudes requeridas para el grado educativo en el que se encuentran y, sobre todo, no ha existido un cambio favorable al menos en los 18 años que se ha llevado a cabo esta prueba para México.

Figura 1: Puntaje promedio en prueba PISA de Comprensión de lectura




Fuente: Elaboración propia con datos de la OCDE.

Nota 1: El valor mostrado es el nivel de logro al que corresponde el puntaje.

Nota 2: El puntaje medio internacional se representa con una línea roja punteada.

Figura 2: Puntaje Promedio en prueba PISA de Matemáticas




Fuente: Elaboración propia con datos de la OCDE.

Nota 1: El valor mostrado es el nivel de logro al que corresponde el puntaje.

Nota 2: El puntaje medio internacional se representa con una línea roja punteada.

Figura 3: Puntaje Promedio en prueba PISA de Ciencias



Fuente: Elaboración propia con datos de la OCDE.

Nota 1: El valor mostrado es el nivel de logro al que corresponde el puntaje.

Nota 2: El puntaje medio internacional se representa con una línea roja punteada.


En el ámbito nacional han existido distintas pruebas para medir el logro académico, como la prueba Examen Nacional del Logro Académico en Centros Escolares (ENLACE) que se implementó durante los años 2006 al 2013. Posteriormente, se implementó la prueba denominada Plan Nacional para la Evaluación de los Aprendizajes (PLANEA) que operó durante el periodo 2015-2019. Ambas pruebas se implementaron de manera censal en las escuelas públicas y algunas escuelas privadas. Previo a la prueba ENLACE, el gobierno ya venía implementando la prueba Exámenes de la Calidad y el Logro Educativo (EXCALE). Ésta operó durante los años 2005-2014. A diferencia de las pruebas

ENLACE y PLANEA, EXCALE era una prueba que se aplicaba a una muestra de la población estudiantil.

A grandes rasgos, estas pruebas tenían como finalidad evaluar el logro de aprendizaje en los estudiantes de educación básica, educación media y media superior. En las siguientes gráficas se muestran algunos de los resultados globales de las pruebas ENLACE y PLANEA. En el caso de la prueba ENLACE, se muestran los resultados de la primera y última edición, *i. e.*, los años 2006 y 2013. Si bien esos años se evaluaron a estudiantes de nivel secundaria, las gráficas sólo muestran los resultados a nivel primaria.

Las Figuras 4 y 5 presentan el porcentaje de niñas y niños por nivel de logro de aprendizaje, materia y grado escolar; en el eje abscisas están los niveles de logro tanto de español como de Matemáticas (Esp y Mat), respectivamente. La prueba clasifica resultados en cuatro niveles: el 0 insuficiente, 1 nivel elemental, 2 nivel bueno y 3 nivel excelente. En el primer año del levantamiento de la prueba se tiene el mayor porcentaje de niñas y niños en el nivel elemental, es decir, 1, el conocimiento mínimo necesario, siendo el porcentaje por encima del 50% en todos los grados y en ambas materias, con excepción de español de tercer grado, pero no es un porcentaje más favorable porque es cercano al 46%.


Figura 4: Nivel de Logro alcanzado, prueba ENLACE 2006 (6to de primaria)



Fuente: Elaboración propia con datos de la prueba ENLACE 2006.

En la Figura 5 que muestra los porcentajes del año 2013 de la prueba ENLACE (Sexto grado de primaria). Se nota una mejora con respecto a la prueba del año 2006; es decir, se redujo el porcentaje de niños en los dos primeros niveles de logro de aprendizaje. Sin embargo, el nivel elemental sigue siendo el que tiene la mayor persistencia en comparación. Este nivel cubre la mayor parte de los alumnos de 3° a 6° grado de primaria entre el 34 y 47%, lo cual sugiere la persistencia del problema educativo.

Figura 5: Nivel de Logro alcanzado, prueba ENLACE 2013




Fuente: Elaboración propia con datos de la prueba ENLACE 2013.

Siguiendo con las pruebas más recientes se cuenta con la prueba PLANEA, que, a diferencia de ENLACE, sólo cubre 6° grado de primaria y 3° de secundaria, por lo que sólo se muestran en las siguientes graficas los porcentajes de cada nivel de logro académico del 6° grado de primaria para 2015 y 2018. El nivel de logro académico con mayor porcentaje alcanzado en esta prueba es el nivel insuficiente, variando del 43.3% (español) al 53% (Matemáticas), lo que sugiere un retroceso en lugar de un avance en ambas materias y en ambos años. Por otro lado, mientras más alto el nivel de logro, menor el porcentaje de niños que alcanzan dicho nivel. Considerando que más del 70% se encuentran tanto en insuficiente como en elemental, alrededor del 10.5% en


Matemáticas logran el nivel excelente, mientras que en español tan sólo lo logran 5.4%.

Figura 6: Nivel de Logro alcanzado, prueba PLANEA 2015 (6° de primaria)



Fuente: Elaboración propia con datos de la prueba PLANEA 2015.

Figura 7: Nivel de Logro alcanzado, prueba PLANEA 2018 (6° de primaria)




Fuente: Elaboración propia con datos de la prueba PLANEA 2018.

Tanto el Nivel I como el Nivel II de logro académico no son deseables ya que se consideran como reprobatorios, mientras que los niveles III y IV son aprobatorios. Los siguientes gráficos (Figuras 8 y 9) muestran los porcentajes de niños en los niveles I y II a nivel estatal. Se observa que todos los Estados tienen al menos el 50% de niños en niveles reprobatorios en Matemáticas

y más del 60% en Comprensión de lectura. Si bien más del 50% de los niños tienen niveles reprobatorios en la mayoría de los estados, existen estados donde los porcentajes son mayores al 80%: estados como Oaxaca, Tlaxcala, San Luis Potosí, Zacatecas y Durango.

Figura 8: Porcentaje de niños con niveles de logro I y II, 6° grado (2015, 2018)



Fuente: Elaboración propia a partir del modelo vectorial del INEGI (Marco Geoestadístico Nacional, 2020) y datos del Plan Nacional para la Evaluación de Aprendizaje (PLANEA 2015 y 2018).


Contexto Malnutrición

Ahora, tratamos de presentar un panorama general sobre la situación y evolución de las condiciones de salud de los menores en México. De acuerdo con el reporte *Joint child malnutrition estimates*, en su edición 2023, presentado en colaboración por

el Fondo de las Naciones Unidas para la Infancia (UNICEF por sus siglas en inglés), la Organización Mundial de la Salud (OMS) y el Banco Mundial, con respecto a los niveles y tendencias en malnutrición infantil del 2023, alrededor de 148 millones de niños menores de 5 años fueron afectados por el retraso del crecimiento, así como 45 millones por desnutrición y 37 millones por sobrepeso en 2022. Particularmente en México se estimó que para 2022 había alrededor de un 1,213,000 menores afectados por el retraso del crecimiento y 665,000 con sobrepeso (OMS, 2023).

En la Figura 9 se muestra el comportamiento de la tendencia de la proporción de menores con retraso en el crecimiento en algunos países. Podemos observar, por ejemplo, que países como la India, que empezaron con niveles muy elevados, muestran una tendencia negativa a través de los años. Argentina es caso contrario a la India, ya que muestra una ligera tendencia al alza. En cambio, Alemania y Estados Unidos tienen niveles mínimos y mantienen sus porcentajes bastante estables. En México, al igual que en Colombia, el porcentaje de niños con retraso de crecimiento está entre 14% y 12%. Se observa que durante el periodo de 12 años hay una ligera tendencia decreciente. De hecho, la reducción del porcentaje apenas ha sido alrededor de 1 a 2%. En resumen, se puede decir que el avance en reducir el porcentaje de niños con retraso en el crecimiento ha sido prácticamente nulo.


Figura 9: Proporción de Niños con Retraso en el Crecimiento (2010-2022)



Fuente: Elaboración propia con datos de The Joint Malnutrition Estimates Working Group (OMS, 2023).

La Figura 10 muestra el comportamiento temporal del porcentaje de niños con sobrepeso en un grupo de ocho países incluyendo México. Observamos que Argentina, Brasil y Colombia muestran tendencias crecientes en el porcentaje de niños con obesidad, mientras que Alemania muestra una significativa tendencia decreciente. Estados Unidos, Japón y México no muestran tendencias significativas y han mantenido sus niveles de obesidad más o menos constantes con ligeras fluctuaciones. Los países con las tasas de obesidad infantil más altas son Brasil, Argentina y Estados Unidos. En resumen, a nivel internacional se observa que el problema de la obesidad infantil se ha convertido en un serio problema de salud pública. No solamente por los porcentajes significativamente altos, sino también por la tendencia creciente.

Figura 10: Proporción de niños con sobrepeso (2010-2022)




Fuente: Elaboración propia con datos de The Joint Malnutrition Estimates Working Group (OMS, 2023).

En los informes de ENSANUT 2018, la prevalencia nacional de retraso del crecimiento en 2018 fue de 14.2%, en 2012 fue de 13.6% y en 2006 de 15.5%. Estos porcentajes sugieren que no hubo progreso significativo en reducir este problema. En el caso de sobrepeso y obesidad la tendencia no es distinta, ya que para 2006 se observó un 8.3% de niños con sobrepeso u obesidad, mientras que para el año 2012 el porcentaje fue 9.7%, y en 2018 fue de 6.8%.

Al observar la Figura 11 se muestra que cada entidad federativa tiene un comportamiento particular, tanto en la proporción de niños con retraso en el crecimiento, así como con sobrepeso y obesidad, por lo que es necesario tener en consideración la

particularidad de la región para poder atender de manera detallada estos problemas de salud pública²⁰.

Figura 11: Niños con retraso del crecimiento y con sobrepeso u obesidad (%), 2012-2018



Fuente: Elaboración propia de los informes de ENSANUT 2018.

Nota: Los Estados sin información disponible se muestran en color gris.

20 (Encuesta Nacional de Salud y Nutrición ENSANUT 2018. Resultados de Aguascalientes., 2020; ENSANUT 2018. Resultados de Chihuahua., 2020; ENSANUT 2018. Resultados de Coahuila., 2020; ENSANUT 2018. Resultados de Estado de México., 2020; ENSANUT 2018. Resultados de Guanajuato., 2020; ENSANUT 2018. Resultados de Guerrero., 2020; ENSANUT 2018. Resultados de Hidalgo., 2020; ENSANUT 2018. Resultados de Jalisco., 2020; ENSANUT 2018. Resultados de Michoacán., 2020; ENSANUT 2018. Resultados de Puebla., 2020; ENSANUT 2018. Resultados de Querétaro., 2020; ENSANUT 2018. Resultados de San Luis Potosí, 2020; ENSANUT 2018. Resultados de Veracruz., 2020; ENSANUT 2018. Resultados de Zacatecas., 2020).

3. Datos y Estadística Descriptiva

En esta sección se presentan las bases de datos con las que se desarrolló este trabajo, así como la fuente de la información y las consideraciones por las cuales fueron elegidas estas bases de datos. La elaboración de este trabajo se enfrentó a un reto muy importante que es la recolección de datos que se puedan procesar para averiguar la relación entre la malnutrición infantil y su impacto en el logro académico, además, tener una cobertura amplia para poder contrastar la información en diferentes regiones de México.

Para México no existe un proyecto que unifique una prueba de logro académico con indicadores de medidas antropométricas infantiles. Si bien existen experimentos en muestras pequeñas, no existe un proyecto de escala nacional, por lo que se tuvo que construir una base de datos utilizando diferentes fuentes de información para lograr nuestro objetivo.

En las últimas dos décadas, México ha implementado una serie de pruebas académicas de cobertura nacional para educación básica como es el caso de la prueba ENLACE y la prueba PLANEA. También ha tenido algunas otras con levantamiento muestral como EXCALE y la prueba de la Organización para la Cooperación y el Desarrollo Económico, PISA. Tomando en cuenta las características de cada una de estas pruebas, la prueba de PLANEA 2016 para niñas y niños de 6to grado de primaria se adecua mejor para el análisis que se quiere llevar a cabo.

La principal razón por la que no se decidió trabajar con la prueba ENLACE es que los resultados de esta prueba, posteriores al año 2006, han sido muy cuestionados. Backho y Contreras (2014), por ejemplo, argumentan que la prueba ENLACE se corrompió y sufrió un proceso de inflación en los resultados debido a tres factores: i) la categorización de las escuelas según el puntaje de los alumnos, ii) la asociación de los estímulos económicos a los docentes según los resultados

de los exámenes, y iii) la falta de control externo de su aplicación. Este problema se detectó por medio del contraste de las tendencias de los resultados de las pruebas EXCALE y la prueba PISA con los resultados de la prueba ENLACE. Rodríguez-Gómez (2015) refrenda el problema de la forma de aplicación y administración de la prueba ENLACE, en particular el uso de la prueba como criterio en la determinación de los estímulos al desempeño de los profesores y para direccionar los programas de actualización docente. Estas decisiones sesgaron los resultados de las pruebas y generaron los incentivos para realizar actos indebidos que viciaron las pruebas.

Ante esto, se decidió utilizar la prueba PLANEA por varias razones. Entre las características de la prueba PLANEA, esta tiene una escala de logro académico de cuatro niveles; Nivel 1 representa un nivel insuficiente, es decir que, el(la) estudiante no cuenta con los conocimientos mínimos necesarios acordes al grado escolar que cursa, o no los maneja de con la habilidad supuesta, Nivel 2 que se refiere a un nivel mínimo necesario, Nivel 3 es un nivel bueno, y por último un Nivel 4 considerándose como excelente, de acuerdo con el programa del grado en curso.

Otra cualidad de la prueba es que tiene cobertura nacional, así como un nivel de desagregación geográfica por Entidad, Municipio y Localidad, lo que permite tener un gran detalle del comportamiento que se registró en esta prueba. Para efectos de este trabajo, se consideró adecuado trabajar con el porcentaje de niñas y niños de cada nivel de logro académico por municipio, lo que refleja un comportamiento generalizado de cada delimitación política.

El indicador de la malnutrición infantil fue obtenido del *Registro Nacional de Peso y Talla* (RNPT), una estadística que lleva a cabo el Instituto Nacional de Ciencias Médicas y Nutrición Salvador Zubirán (INCMNSZ, 2016), y que tiene como

objetivo conocer el estado de nutrición de todas las niñas y niños de educación primaria. Para el análisis de este trabajo se toma en cuenta el levantamiento de datos que corresponden al ciclo escolar 2015-2016 para 6to grado de primaria, al igual que la prueba PLANEA. Este registro ofrece los valores estandarizados de las medidas antropométricas del índice de masa corporal y la talla para la edad. Con base en estos valores se procedió a determinar el estado de malnutrición de niñas y niños, considerando aquellos que tienen retraso del crecimiento y los que no tienen esta condición, es decir que aquellas niñas y niños que tengan un valor estandarizado de talla para la edad menor a -2 , se catalogan como niñas y niños con retraso del crecimiento, es decir que están dos desviaciones estándar por debajo de la mediana de los patrones de crecimiento infantil. Posteriormente se calcula el porcentaje de niñas y niños con retraso del crecimiento por municipio. También se consideran otras medidas como el sobrepeso y la obesidad, estas se toman con el valor estandarizado del IMC, es decir que aquellas niñas y niños con un valor estandarizado del IMC por encima de uno, se consideran con sobrepeso y aquellos con un valor por encima de dos se consideran con obesidad, es decir que están por una o dos desviaciones estándar por encima de la mediana de los patrones de crecimiento infantil e igualmente se calcula el porcentaje de niñas y niños con estas condiciones por municipio.

Ahora bien, el logro académico, de acuerdo con las investigaciones, se considera que depende de varios factores más allá de las habilidades de la persona, de manera que es necesario tratar de controlar el modelo por medio de otras variables. En la literatura clasifican cuatro grandes rubros de factores que afectan el logro escolar que son: las características personales, antecedentes familiares y ambiente del hogar, factores asociados a la escuela, y factores institucionales.

Nuestra unidad de observación son los municipios y para ello se generan datos municipales a partir de información individual. Se decidió por datos a nivel municipal debido a que algunas covariables están solamente a este nivel. En particular, los índices de medición de la pobreza del año 2015 por parte del Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL). Entre los determinantes de los antecedentes familiares se considera el porcentaje de la población en el municipio con rezago educativo (PRE), con este indicador se capta, en lo general, el nivel de aprovechamiento académico de la comunidad en la que viven. En el caso de los determinantes institucionales, se consideran indicadores que pueden capturar el contexto social de la comunidad en la que viven, como son: i) el porcentaje de personas vulnerables por carencia social (PVCS), ii) el porcentaje de personas vulnerables por ingreso (PVI), iii) porcentaje de personas con carencia alimentaria (PCA).

Ahora bien, para el problema de la regionalización, existen distintas formas para segmentar regiones, como regiones económicas, regiones territoriales, etc. Sin embargo, estas regionalizaciones no son de tanta utilidad debido a que no hay un factor común para el estudio de nuestro caso. En este sentido se realizó una regionalización por el porcentaje de población que vive en zonas rurales por municipio; es decir, municipios rurales y municipios no rurales. Para hacer esta segmentación se consideró la estructura establecida por el Instituto Nacional de Estadística y Geografía (INEGI). INEGI define como localidad rural a aquella localidad en la que habitan hasta 2500 personas, por lo que aquellos municipios en los que más del 60% de la población habitan en localidades rurales se les consideró un municipio rural. Para la regionalización se utilizó la encuesta intercensal del 2015 para estimar el porcentaje de la población que vive en zonas rurales, que, como definió el INEGI, una localidad rural es aquella donde habitan menos de

2500 personas. Se tomó el factor de expansión de esta encuesta para poder estimar la población total por municipio, PT_m , así como el porcentaje de población que vive en una localidad rural por municipio (PPR_m). El municipio rural (R) se define cuando el 60% o más de la población vive en localidades rurales, $PPR_m = \left(\frac{Pob_{Rural}}{PT_m} \right) * 100$. Entonces, R es una variable dicotómica que toma el valor de 1 si el porcentaje de la población que vive en localidades rurales es mayor al 60% del total de la población del municipio, i.e., $R = 1$ si $PPR \geq 60\%$. Tiene el valor de cero, si es menor que 60%; es decir, es entonces un municipio no rural.

La variable dependiente, Municipio Reprobado (MR_m), es una variable dicotómica que tiene el valor de 1 si el porcentaje de niños reprobados en el municipio “m” es mayor al porcentaje de niños reprobados a nivel nacional. Esto para cada tipo de examen (Matemáticas, Comprensión de lectura). Entonces,

$$\begin{aligned} MR_m &= 1, \text{ si } PNI_m > PNI_N \\ MR_m &= 0, \text{ si } PNI_m \leq PNI_N \end{aligned} \quad (2)$$

Donde PNI_m es el porcentaje de niños con nivel insuficiente en el municipio “m”, PNI_N es el porcentaje de niños reprobados a nivel nacional.

Las variables socioeconómicas son tomadas de la base “Pobreza a nivel municipio 2010-2020”. Los valores considerados corresponden al año 2015 (CONEVAL, 2022). En particular, se utiliza el porcentaje de personas con rezago educativo, esto como asociación a las características de la familia; es decir, describe el entorno académico en el que el menor se desarrolla, asumiendo que a mayor porcentaje de personas con rezago educativo esto afectará de manera negativa al logro académico del menor. También, se utilizan indicadores de vulnerabilidad para controlar los factores socioeconómicos, como son el porcentaje de personas

que son vulnerables por ingresos o por carencias sociales, y por último, el porcentaje de personas con carencia por acceso a la alimentación, ésta en asociación a la complicación a la que se pueden enfrentar en acceder a una alimentación suficiente para llevar una vida sana²¹.

Estadística Descriptiva

Las Tablas 1 y 2 muestran el número de observaciones, la media, la desviación estándar de las variables utilizadas en el análisis. También incluyen los valores de los percentiles 25, 50 y 75. Se muestran estas medidas en tres diferentes grupos para cada variable, las medidas con la información total y por estrato en función si la variable es un municipio rural o un municipio no rural. Una gran utilidad de tener la comparativa en estos tres grupos es que se pueden notar las diferencias en los comportamientos de las variables. Para los dos indicadores de aprovechamiento académico se muestra que en los municipios rurales el porcentaje de reprobados en Comprensión de lectura es mayor al promedio nacional, mientras que en Matemáticas son relativamente similares.

De acuerdo con los datos, comparado con el promedio nacional, los municipios rurales tienen un mayor porcentaje de niños con retraso de crecimiento, porcentaje de personas con rezago educativo y porcentaje de personas con carencia alimentaria. Por otro lado, los municipios no rurales tienen una media mayor en porcentaje de niños con sobrepeso y obesidad, en el porcentaje de personas vulnerables por carencia social y vulnerables por ingreso.

21 Las características de estos indicadores se desarrollan en la Metodología para la medición multidimensional de la pobreza en México (CONEVAL 2019).

Tabla 1: Estadísticas Descriptivas

Variable	Tipo Municipio	Núm. de Municipios	Media	SD	Reprobado	No Reprobado
Matemáticas	Total	1550	51.70%	50%	802	748
	Urbano	834	50.5%	50.0%	421	413
	Rural	716	53.2%	49.9%	381	335
Comprensión de lectura	Total	1550	45.3%	49.8%	702	848
	Urbano	834	35.4%	47.8%	295	539
	Rural	716	56.8%	49.6%	407	309

Fuente: Elaboración propia con datos del RNPT 2015-2016, Prueba PLANEA 2016, Encuesta Intercensal INEGI 2015 y CONEVAL 2010-2020.


Tabla 2: Estadísticas Descriptivas

Variable	Tipo de Municipio	N	Media	SD	p25	p50	p75
Retraso de Crecimiento (RC)	Ambos	1550	12.6%	14.4%	3.8%	8.3%	15.4%
	No	834	9.8%	10.5%	3.7%	7.1%	12.3%
	Si	716	15.9%	17.4%	4.3%	10.2%	21.7%
Sobrepeso (SO)	Ambos	1550	22.1%	11.4%	17.6%	22.7%	26.5%
	No	834	24.3%	10.4%	21.2%	24.2%	27.7%
	Si	716	19.6%	12.0%	14.0%	19.6%	24.4%
Obesidad (PO)	Ambos	1550	11.6%	9.7%	5.9%	10.6%	15.6%
	No	834	13.4%	9.0%	8.9%	12.7%	17.2%
	Si	716	9.5%	10.0%	3.2%	7.7%	12.8%
Rezago Educativo (RE)	Ambos	1550	26.2%	10.2%	17.9%	26.1%	33.6%
	No	834	21.4%	8.9%	14.1%	20.3%	27.4%
	Si	716	31.8%	8.6%	25.8%	31.9%	37.8%
Población con carencia alimentaria (PCA)	Ambos	1550	23.3%	10.7%	16.1%	22.3%	28.3%
	No	834	22.4%	9.0%	16.6%	21.4%	26.3%
	Si	716	24.3%	12.2%	15.5%	23.3%	30.6%
Vulnerables por carencia social (PVCS)	Ambos	1550	23.6%	12.5%	15.8%	23.2%	30.1%
	No	834	24.4%	8.6%	18.9%	24.5%	29.7%
	Si	716	22.7%	15.8%	11.1%	20.1%	31.1%
Porcentaje de personas Vulnerables por ingreso (PVI)	Ambos	1550	4.2	4.4%	0.87%	2.5%	6.3%
	No	834	6.4%	4.8%	2.4%	5.4%	9.4%
	Si	716	1.7%	2.1%	0.4%	1.0%	2.2%

Fuente: Elaboración propia con datos del RNPT 2015-2016, Prueba PLANEA 2016, Encuesta Intercensal INEGI 2015 y CONEVAL 2010-2020.

El mapa en la Figura 12 muestra los municipios acerca de los cuales se pudieron tener observaciones. Fueron 1550 municipios de los cuales 716 son considerados municipios rurales, mientras que 834 son considerados municipios no-rurales; De 919 municipios no se pudo obtener información. Entre los municipios que no se obtuvieron datos se encuentran estados completos como Jalisco, Michoacán, Tabasco y Zacatecas. A su vez, las figuras 13 y 14 muestran los municipios con alta proporción de reprobados en Matemáticas y Comprensión de lectura, respectivamente.


Figura 12: Municipios rurales y no rurales de México



Fuente: Elaboración propia de los informes de INEGI 2015.

Nota: Los Estados sin información disponible se muestran en color gris.


Figura 13: Municipios reprobados en Matemáticas



Fuente: Elaboración propia con datos del *Registro Nacional de Peso y Talla 2015-2016* (INCMNSZ, 2016).

Nota: Los Estados sin información disponible se muestran en color gris.

Figura 14: Municipios reprobados en Comprensión de lectura



Fuente: Elaboración propia con datos del *Registro Nacional de Peso y Talla 2015-2016* (INCMNSZ, 2016).

Nota: Los Estados sin información disponible se muestran en color gris.

Ahora bien, en la Tabla 3 se muestran las correlaciones Pearson entre las diferentes variables consideradas en el análisis. Se observa que la correlación entre el porcentaje de personas con rezago educativo y el porcentaje de personas vulnerables por ingreso es la única que destaca; sin embargo, como cada uno de los indicadores busca explicar distintas características del entorno, se decidió mantener estos dos indicadores para una mejor interpretación del modelo.

Tabla 3: Matriz de Correlaciones (Pearson)

Correlaciones	MRM	MRCL	PRC	PSP	PO	PRE	PCA	PVCS	PVI	MR
MRM	1.00 (<0.01)									
MRCL	0.60 (<0.01)	1.00 (<0.01)								
PRC	0.12 (<0.01)	0.23 (<0.01)	1.00 (<0.01)							
PSP	-0.10 (<0.01)	-0.16 (<0.01)	-0.22 (<0.01)	1.00 (<0.01)						
PO	-0.05 (<0.01)	-0.13 (<0.01)	-0.25 (<0.01)	0.09 (<0.01)	1.00 (<0.01)					
PRE	0.15 (<0.01)	0.35 (<0.01)	0.40 (<0.01)	-0.29 (<0.01)	-0.30 (<0.01)	1.00 (<0.01)				
PCA	0.10 (<0.01)	0.18 (<0.01)	0.28 (<0.01)	-0.12 (<0.01)	-0.15 (<0.01)	0.37 (<0.01)	1.00 (<0.01)			
PVCS	-0.12 (<0.01)	-0.22 (<0.01)	-0.45 (<0.01)	0.17 (<0.01)	0.36 (<0.01)	-0.43 (<0.01)	-0.33 (<0.01)	1.00 (<0.01)		
PVI	-0.03 (<0.01)	-0.25 (<0.01)	-0.32 (<0.01)	0.22 (<0.01)	0.25 (<0.01)	-0.70 (<0.01)	-0.35 (<0.01)	0.15 (<0.01)	1.00 (<0.01)	
MR	0.03 (<0.01)	0.22 (<0.01)	0.21 (<0.01)	-0.20 (<0.01)	-0.20 (<0.01)	0.51 (<0.01)	0.09 (<0.01)	-0.07 (<0.01)	-0.52 (<0.01)	1.00 (<0.01)

Fuente: Elaboración propia con datos del RNPT 2015-2016, Prueba PLANEA 2016, Encuesta Intercensal INEGI 2015 y CONEVAL 2010-2020.
Nota: Debajo del coeficiente se encuentra la significancia de la correlación Pearson.

4. Análisis Empírico

Como se comentó anteriormente, el modelo probit es el seleccionado para medir la probabilidad de que un municipio determinado tenga una alta tasa de reprobados en las áreas de Matemática o Comprensión de Lectura.

$$P[MR_A = 1|x] = G(\beta_0 + X\beta) \tag{3}$$

Donde G es una función de densidad (probabilidad) que depende del vector de variables explicativas X . Por su parte, β_0 y β son los parámetros por estimar. En este caso se utiliza la función de distribución acumulada de la Normal estándar que se denota como Φ . Donde

$$\Phi(X) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{x^2}{2}} \quad (4)$$

El vector X está integrado por los indicadores de malnutrición infantil, como rezago en el crecimiento (PRC), Rezago Educativo (PRE), Carencia Alimentaria (PCA), Porcentaje de Viviendas con Carencia Social (PVCS), porcentaje de personas vulnerables de ingreso (PVI). R es una variable dicotómica que tiene el valor de 1 si el municipio es rural, de otra manera, tiene el valor de cero.

$$MR_m = \Phi(\beta_0 + \beta_1 PRC_m + \beta_2 PRE_m + \beta_3 PCA_m + \beta_4 PVCS_m + \beta_5 PVI_m + \beta_6 R_m) \quad (5)$$

La estimación de los parámetros nos permitirá conocer la dirección y la magnitud de los efectos de cada variable independiente sobre la variable dependiente que, en este caso, es la variable dicotómica de que el municipio m^{tb} tenga una tasa de reprobados mayor a la media nacional. La dirección se determina al estimar el modelo y conocer el signo del coeficiente, mientras que para determinar la magnitud de los efectos es necesario tomar la derivada parcial de la función de probabilidad del modelo para cada variable explicativa en el vector X . Usando la ecuación 4, los efectos marginales serían

$$\frac{\partial P(x)}{\partial x_j} = g(\beta_0 + x\beta)\beta_j \quad (6)$$

$$g(x) = \frac{\partial G}{\partial x}(x) \quad (7)$$

De esta manera se identifican los efectos marginales de las variables independientes a distintos niveles de las variables que forman el vector X ; es decir que, para conocer los efectos marginales de las variables de interés, es necesario mantener todas las demás variables fijas (*ceteris paribus*).

Principales Resultados

Los resultados de las estimaciones para la prueba de Comprensión de lectura se muestran en la Tabla 4, mientras que los resultados para la prueba de Matemáticas se muestran en la Tabla 5. En ambos resultados se muestran con y sin la incorporación de la variable vulnerable por ingreso (*PVI*) debido a las consideraciones de la correlación que mantenía con la variable rezago educativo (*PRE*).

En el caso de Comprensión de lectura, Tabla 4, se observa que el retraso en el crecimiento, como se considera en la literatura, tiene el signo esperado; es decir que a mayor porcentaje de menores con retraso del crecimiento, la probabilidad de ser un municipio reprobado en Comprensión de lectura es mayor. De la misma manera, las variables que buscan controlar el entorno de los menores siguen el mismo patrón; es decir, las variables como rezago educativo (*PRE*) y familias con carencia alimentaria (*PCA*), mientras mayores sean, aumentan la probabilidad de constituir un municipio reprobado en Comprensión de lectura. La variable de municipio rural es también una variable relevante en este modelo, ya que al estar en un municipio rural la probabilidad de ser un municipio reprobado aumenta. En el caso de las variables que tratan de controlar el entorno socioeconómico, que son personas vulnerables por carencia social (*PVCS*) y las personas vulnerables por ingreso (*PVI*) no tienen los resultados esperados. La variable personas vulnerables por carencia social (*PVCS*), contrario a lo esperado, presenta signo

negativo, lo que quiere decir que a mayor porcentaje de personas vulnerables por carencia social, se reduce la probabilidad de ser un municipio reprobado. Además, la variable porcentaje de personas vulnerables por ingreso (*PVI*) no es significativa. Si bien estos indicadores permiten tener un panorama general de la situación de la pobreza en México y sus municipios, en particular, la variable del porcentaje de personas vulnerables por carencia social no representa un panorama homogéneo entre los municipios, debido a que este indicador está construido a partir de diferentes consideraciones, por lo que será necesario realizar un análisis con mayor desagregación. Sin embargo, este análisis queda fuera de los alcances de este trabajo.²²

22 Este indicador está construido a partir de la consideración de las dimensiones constitutivas de la pobreza, asociadas a las dimensiones de derechos sociales, lo que consta de 6 indicadores de carencia social, como son: la educación, la salud, la seguridad social, la alimentación nutritiva y de calidad, la vivienda y sus servicios. (CONEVAL, 2018)

*Tabla 4: Municipios reprobados
en Comprensión de lectura*

	MRCL					
	(1)	(2)	(3)	(4)	(5)	(6)
PRC	0.008*** (0.003)	0.008*** (0.003)				
PSO			-0.007** (0.003)	-0.007** (0.003)		
PO					0.001 (0.004)	0.001 (0.004)
PRE	0.036*** (0.006)	0.033*** (0.005)	0.035*** (0.006)	0.034*** (0.005)	0.036*** (0.005)	0.035*** (0.005)
PCA	0.007* (0.004)	0.006* (0.004)	0.008** (0.004)	0.007** (0.003)	0.008** (0.004)	0.007** (0.003)
PVCS	-0.006* (0.003)	-0.006** (0.003)	-0.008*** (0.003)	-0.009*** (0.003)	-0.009*** (0.003)	-0.009*** (0.003)
PVI	0.010 (0.012)		0.006 (0.012)		0.005 (0.012)	
R	0.193** (0.081)	0.177** (0.079)	0.189** (0.081)	0.179** (0.078)	0.204** (0.081)	0.196** (0.079)
Constant	-1.321*** (0.250)	-1.170*** (0.169)	-0.981*** (0.255)	-0.898*** (0.186)	-1.166*** (0.243)	-1.096*** (0.170)
Observaciones	1,550	1,550	1,550	1,550	1,550	1,550
Log Likelihood	-953.117	-953.452	-954.829	-954.942	-957.258	-957.338
Akaike	1,920.234	1,918.903	1,923.658	1,921.884	1,928.517	1,926.677

Fuente: Estimados propios. Nota: *p<0.1; **p<0.05; ***p<0.01

Si bien la variable del porcentaje de menores con retraso del crecimiento tiene el signo esperado, la variable del porcentaje de menores con sobrepeso tiene el signo opuesto al esperado. Se

debe notar que en la literatura no se encuentra un consenso en la relación entre la obesidad y desempeño académico, como describen Caird *et al.* (2014). En cambio, parece no tener incidencia sobre el desempeño académico ya que los parámetros estimados no resultaron estadísticamente significativos.

Tabla 5: Municipios reprobados en Matemáticas

MRM						
	(1)	(2)	(3)	(4)	(5)	(6)
PRC	0.007*** (0.003)	0.006** (0.003)				
PSO			-0.007** (0.003)	-0.007** (0.003)		
PO					-0.0001 (0.004)	0.001 (0.004)
PRE	0.029*** (0.005)	0.017*** (0.004)	0.028*** (0.005)	0.016*** (0.004)	0.029*** (0.005)	0.018*** (0.004)
PCA	0.007* (0.003)	0.003 (0.003)	0.007** (0.003)	0.004 (0.003)	0.007** (0.003)	0.004 (0.003)
PVCS	0.001 (0.003)	-0.003 (0.003)	-0.002 (0.003)	-0.005 (0.003)	-0.002 (0.003)	-0.005* (0.003)
PVI	0.045*** (0.011)		0.042*** (0.011)		0.041*** (0.011)	
R	-0.069 (0.080)	-0.148* (0.077)	-0.074 (0.080)	-0.149* (0.077)	-0.059 (0.080)	-0.130* (0.077)
Constant	-1.121*** (0.240)	-0.403** (0.160)	-0.790*** (0.246)	-0.148 (0.177)	-0.979*** (0.234)	-0.354** (0.161)
Observaciones	1,550	1,550	1,550	1,550	1,550	1,550
Log Likelihood	-1,040.211	-1,048.333	-1,040.863	-1,047.990	-1,043.796	-1,050.623
Akaike	2,094.422	2,108.666	2,095.727	2,107.980	2,101.592	2,113.247

Fuente: Estimados propios. Nota: *p<0.1; **p<0.05; ***p<0.01

Al concentrarse en los resultados en función de un municipio reprobado en Matemáticas que se muestran en la Tabla 5, la variable rezago en el crecimiento (*PRC*) se mantiene significativa y positiva; es decir, a mayor porcentaje de menores con retraso del crecimiento, mayor probabilidad de ser un municipio reprobado. Si bien se mantiene cierta consistencia en los datos en relación con los modelos realizados para municipios reprobados en Comprensión de lectura, las variables rezago educativo (*PRE*) y carencia alimentaria (*PCA*) tienen efectos positivos. No obstante, siguiendo la misma lógica que en los modelos anteriores, las variables carencia social (*PVCS*), y municipio rural (*R*), tienen comportamientos distintos. Los municipios rurales muestran un coeficiente negativo, lo cual sugiere que en la materia de Matemáticas se tiene un efecto contrario. En cambio, la variable de vulnerabilidad por carencia social (*PVCS*) no tiene efectos estadísticamente significativos. Los resultados que se presentan en las Tablas 4 y 5 indican que el sobrepeso (*PSO*) tiene el mismo efecto en la prueba de Matemáticas y en la de Comprensión de Lectura, i.e, a mayor proporción de niños con sobrepeso menor es la probabilidad de que el municipio sea un municipio reprobado.

Se realizaron pruebas de robustez en los modelos; estas pruebas se muestran en el anexo. Se realizó la estimación de los modelos cambiando la definición de municipio reprobado, se considera municipio reprobado aquel en que el porcentaje de menores en el nivel uno de logro académico es mayor a la mediana nacional, en lugar de la media, lo que ofreció resultados interesantes, porque reafirma la consistencia del modelo para porcentaje de menores con retraso del crecimiento para ambas materias, manteniendo las mismas dinámicas en las variables.

Por otro lado, para los modelos de porcentaje de menores con sobrepeso, estos pierden significatividad, y el modelo de porcentaje de menores con obesidad se mantiene sin significatividad

en la variable. Estos resultados refieren que estos modelos son sensibles. En las tablas siguientes se muestran los efectos marginales medios de cada variable de los modelos. Primeramente, en los municipios reprobados en Comprensión de lectura, la Tabla 6 muestra que en promedio el aumento de la probabilidad de ser un municipio reprobado en Comprensión de lectura es de 0.27% si aumenta el porcentaje de menores con retraso del crecimiento, mientras que si aumenta el porcentaje de personas con rezago educativo el aumento en la probabilidad es de 1.17%. Por último, el aumento del porcentaje de personas con carencia alimentaria es del 0.22%.

Tabla 6: Efectos marginales medios, Comprensión de lectura (PCR).

Variable	Efectos Marginales Medios	SE	z	p	Mínimo	Máximo
PRC	0.0027	0.0010	2.2351	0.0062	0.0008	0.0046
PRE	0.0117	0.0015	7.7129	0.0000	0.0087	0.0146
PCA	0.0022	0.0012	1.7848	0.0743	-0.0002	0.0046
PVCS	-0.0022	0.0011	-1.9893	0.0467	-0.0045	0.0000
R	0.0618	0.0274	2.2594	0.0239	0.0082	0.1155

Siguiendo con los efectos marginales medios de los municipios reprobados en Matemáticas, éstos se muestran en la Tabla 7, donde se nota que en promedio los efectos del porcentaje de menores con retraso del crecimiento son similares en ambos modelos. Para estos modelos el aumento de la probabilidad de ser un municipio reprobado en Matemáticas es de 0.22% al aumento del porcentaje de menores con retraso del crecimiento. El comportamiento también es similar para el porcentaje con rezago educativo; por el aumento de éste la probabilidad aumenta en

0.65%, mientras que para el porcentaje de personas con carencia alimentaria, el aumento de la probabilidad es de 0.13%.

Tabla 7: Efectos marginales medios, Matemáticas (PCR).

Variable	Efectos Marginales Medios	SE	z	p	Mínimo	Máximo
PRC	0.0022	0.0010	2.1696	0.0300	0.0002	0.0043
PRE	0.0065	0.0017	3.8699	0.0001	0.0032	0.0097
PCA	0.0013	0.0013	1.0009	0.3169	-0.0013	0.0039
PVCS	-0.0011	0.0012	-0.9245	0.3552	-0.0035	0.0013
R	-0.0573	0.0299	-1.9152	0.0555	-0.1159	0.0013

Fuente: estimación propia.

Ahora bien, los efectos marginales medios del porcentaje de menores con sobrepeso se muestran en las Tablas 8 y 9. Los efectos del porcentaje de menores con sobrepeso (PSO) son negativos; es decir, que disminuyen la probabilidad de ser un municipio reprobado en 0.24% para Comprensión de lectura (Tabla 8) y en 0.27% para Matemáticas (Tabla 9).

Tabla 8: Efectos marginales medios, municipios reprobados en Comprensión de lectura (PSO).

Variable	Efectos Marginales Medios	SE	z	P	Mínimo	Máximo
PSO	-0.0024	0.0011	-2.2324	0.0256	-0.0046	-0.0003
PRE	0.0118	0.0015	7.7819	0.0000	0.0088	0.0148
PVCA	0.0025	0.0012	2.0435	0.0410	0.0001	0.0049
PVCS	-0.0030	0.0011	-2.8381	0.0045	-0.0051	-0.0009
R	0.0629	0.0274	2.2985	0.0215	0.0093	0.1166

Fuente: Estimación propia.


Tabla 9: Efectos marginales medios, municipios reprobados en Matemáticas (PSO).

Variable	Efectos Marginales Medios	SE	z	p	Mínimo	Máximo
PSO	-0.0027	0.0012	-2.3305	0.0198	-0.0050	-0.0004
PRE	0.0064	0.0017	3.8355	0.0001	0.0031	0.0097
PVCA	0.0016	0.0013	1.2014	0.2266	-0.0010	0.0041
PVCS	-0.0018	0.0012	-1.5459	0.1221	-0.0040	0.0005
MR	-0.0579	0.0299	-1.9381	0.0526	-0.1165	0.0007

Fuente: Estimación propia.

En las siguientes figuras se muestran los cambios marginales de la probabilidad de ser un municipio reprobado en las pruebas de Comprensión de lectura y Matemáticas cuando cambia la proporción de rezago educativo (Figura 15) y cuando cambia el sobrepeso de los niños. En ambos casos, se visualiza el cambio de la probabilidad de ser un municipio reprobado cuando cambia la naturaleza del municipio *i. e.*, el municipio pasa de no rural a rural.

*Figura 15: Efectos marginales.
Niños con rezago educativo*




Nota: Se muestran los distintos percentiles de PRC. NR son municipios no rurales y R municipios rurales.

En la Figura 15 se observa que mientras mayor sea el porcentaje de menores con retraso del crecimiento, la probabilidad de ser un municipio reprobado aumenta. Además, si el municipio es rural esta probabilidad aumenta aún más. En contraste, la Figura 16 muestra que, a mayor porcentaje de menores con sobrepeso, la probabilidad de ser un municipio reprobado es menor. Sin embargo, si es un municipio rural, también aumenta la probabilidad. Cabe recalcar que estos cambios se reflejan sólo en las pruebas de español.

Esto permite entrar en debate debido a que el porcentaje de menores con sobrepeso no tiene el efecto esperado. Con base en

la revisión literaria en Caird *et al.* (2014), no existe un consenso acerca de la relación entre sobrepeso y logro académico, lo cual afirman también Devaux y Vuik (2019) y Wu *et al.* (2017). Ellos encuentran que los mecanismos de transmisión de la obesidad y el sobrepeso en el logro académico pueden ser por cuestiones biológicas, conductuales o emocionales y mentales (Devaux y Vuik, 2019) o por afectaciones en la memoria del menor (Wu *et al.*, 2017), lo que podría referirse a que el menor experimentara por un periodo considerable la obesidad y sobrepeso para así adquirir estas afectaciones.

Figura 16: Efectos marginales. Niños con sobrepeso



Nota: Se muestran los distintos percentiles de PSO evaluados. NR hace referencia a municipios no rurales y R a municipios rurales

5. Conclusiones

El objetivo central del presente trabajo ha sido la de analizar el impacto de la malnutrición infantil sobre su desempeño académico. Se elaboró una base de datos única a nivel municipal con información antropométrica de los niños en Educación Básica elaborado por el Instituto Nacional de Ciencias Médicas y Nutrición Salvador Zubirán y los resultados de los exámenes en Matemáticas y Comprensión de Lectura que se obtuvieron en la prueba PLANEA. Debido a la disponibilidad de información, sólo se pudo construir esta base de datos para alumnos en el 6to grado de educación primaria en el año 2016.

Se utilizó un modelo Logit a nivel municipal para cada prueba de conocimiento, donde la variable dependiente fue una variable dicotómica donde 1 representa el municipio con una proporción de estudiantes reprobados mayor al promedio nacional y 0 todo lo demás. Una de las primeras conclusiones es que la relación entre malnutrición infantil y logro académico no es única, es una relación compleja que depende del tipo de malnutrición que estemos analizando. Por ejemplo, en el caso de retraso en el crecimiento, se muestra que éste está asociado de manera positiva con el pobre desempeño académico del municipio tanto en Matemáticas como en Comprensión de Lectura. Es decir, la probabilidad de que el municipio sea un municipio reprobado aumenta con el porcentaje de niños con rezago en el crecimiento en el municipio.

El sobrepeso y la obesidad, en su conjunto, parecen no tener una relación clara con el desempeño académico. Sin embargo, cuando se considera solamente el sobrepeso se encuentra una relación positiva con el desempeño académico, es decir, municipios con una mayor proporción de niños con sobrepeso presentan una menor probabilidad de ser un municipio reprobado. La obesidad, por su lado, parece no tener algún efecto sobre el desempeño académico en ninguna de las dos pruebas (Matemáticas

y Comprensión de Lectura). En lo que se refiere a la significancia del tipo de región analizada (rural vs no rural), encontramos que los municipios definidos como rurales presentan una alta probabilidad de tener un alto porcentaje de estudiantes reprobados. Esto se cumple para ambos tipos de exámenes, i.e., Matemáticas y Comprensión de Lectura.

Con el objetivo de verificar la robustez de los resultados en el Anexo se modificó el criterio para definir “municipio reprobado”; específicamente, municipio reprobado es definido cuando la proporción de estudiantes reprobados es mayor a la **mediana nacional** de estudiantes reprobados. (Tablas A3 y A4). Los resultados observados en este caso se mantienen inalterables cuando se utiliza la **media nacional** para definir municipio reprobado.

En resumen, nuestros resultados sugieren la necesidad de profundizar este tipo de estudios donde se analicen la relación entre los diferentes tipos de malnutrición y su impacto sobre el desempeño académico de los niños. Debido a la falta de información sistemática, consistente a nivel individual se tuvo que construir una base de datos a nivel municipal. Quizás el proceso de agregación de las variables de interés no permitió resultados más claros. En términos de recomendaciones de política educativa y/o salud y dada la importancia de ambas variables en la formación de capital humano, es de suma importancia continuar con estudios a nivel microeconómico para identificar y medir el impacto de la malnutrición sobre el rendimiento académico.

Bibliografía

- Attanasio, O. P. (2015). The determinants of human capital formation during the early years of life: Theory, measurement, and policies. *Journal of the European Economic Association*, 13(6), 949-997. DOI: 10.1111/jeea.12159
- Backhoff, E., y Contreras Roldán, S. (2014). ‘Corrupción de la medida’ e inflación de los resultados de Enlace. *Revista mexicana de investigación educativa*, 19(63), 1267-1283. https://www.scielo.org.mx/scielo.php?pid=S1405-66662014000400012&script=sci_arttext
- Caird, J., Kavanagh, J., O’Mara-Eves, A. *et al.* (2014). Does being overweight impede academic attainment? a systematic review. *Health Education Journal*, 73(5), 497-521. DOI: 10.1177/0017896913489289
- Consejo Nacional de Evaluación de la Política de Desarrollo Social [CONEVAL] (2018). *Anexo único de los Lineamientos y criterios generales para la definición, identificación y medición de la pobreza, actualización 2018. Metodología para la medición multidimensional de la pobreza en México*. México: Coneval. <https://www.coneval.org.mx/Normateca/Documents/ANEXO-Lineamientos-DOF-2018.pdf>
- (2022). *Medición multidimensional de la pobreza en México, 2016-2020*. México: Coneval.
- (2019). *Metodología para la medición multidimensional de la pobreza en México*. México: Coneval.
- CONEVAL (2024a), Consejo Nacional de Evaluación de la Política de Desarrollo Social, “Pobreza a nivel municipio 2010-2020” en <https://www.coneval.org.mx/Medicion/Paginas/Pobreza-municipio-2010-2020.aspx>. Fecha de revisión 02/09/2024
- CONEVAL (2024b) “Metodología para la medición multidimensional de la pobreza en México”. Tercera edición, en <https://www.coneval.org.mx/Medicion/MP/Paginas/Metodologia.aspx>. Fecha de revisión 02/09/2024

- CONEVAL (2019) “Metodología para la medición multidimensional de la pobreza en México”. Tercera Edición, en <https://www.coneval.org.mx/InformesPublicaciones/InformesPublicaciones/Documents/Metodologia-medicion-multidimensional-3er-edicion.pdf> . Fecha de revisión 02/09/2024
- Cornelio-Nieto, J. O. (2007). Efectos de la desnutrición proteico-calcórica en el sistema nervioso central del niño. *Revista de Neurología*, 44(supl.2), S71-S74. 10.33588/rn.44S02.2006663
- Devaux, M., y Vuik, S. (2019). The relationship between childhood obesity and educational outcomes. En: OECD. *The heavy burden of obesity: The economics of prevention* (pp. 101-123). (OECD Health Policy Studies). https://www.oecd.org/en/publications/the-heavy-burden-of-obesity_67450d67-en/full-report/component-9.html#chapter-d1e9249
- Dewey, K. G., y Begum, K. (2011). Long-term consequences of stunting in early life. *Maternal & child nutrition*, 7(s3), 5-18. DOI: 10.1111/j.1740-8709.2011.00349.x
- Gertler, P., Heckman, J. J., Pinto, R. *et al.* (2021). Effect of the Jamaica early childhood stimulation intervention on labor market outcomes at age 31 *NBER Working Papers* (29292). DOI: 10.3386/w29292
- Grantham-McGregor, S. M., Fernald, L. C., y Sethuraman, K. (1999a). Effects of health and nutrition on cognitive and behavioural development in children in the first three years of life. Part 1, low birthweight, breastfeeding, and protein-energy malnutrition. *Food and Nutrition Bulletin*, 20(1), 53-75. DOI: 10.1177/156482659902000107
- Grantham-McGregor, S. M., Fernald, L. C., Sethuraman, K. (1999b). Effects of health and nutrition on cognitive and behavioural development in children in the first three years of life. Part 2, infections and micronutrient deficiencies: Iodine, iron, and zinc. *Food and Nutrition Bulletin*, 20(1), 76-99. DOI: 10.1177/156482659902000108

- Hoddinott, J., Maluccio, J. A., Behrman, J. R. *et al.* (2008). Effect of a nutrition intervention during early childhood on economic productivity in Guatemalan adults. *The Lancet*, 371(9610), 411-416. [https://www.thelancet.com/journals/lancet/article/PIIS0140-6736\(08\)60205-6/fulltext](https://www.thelancet.com/journals/lancet/article/PIIS0140-6736(08)60205-6/fulltext)
- Hoyos, R. E., Espino, J. M., y García, V. (2012). Determinantes del logro escolar en México- primeros resultados utilizando la prueba Enlace media superior. *El Trimestre Económico*, 79(316), 783-811. https://www.scielo.org.mx/scielo.php?pid=S2448-718X2012000400783&script=sci_arttext
- Instituto Nacional de Ciencias Médicas y Nutrición Salvador Zubirán [INCMNSZ] (2016). *Registro nacional de peso y talla*. México: INCMNSZ, Sistema de Vigilancia Nutricional en Escolares [SIVNE]. <https://rnpt.sivne.org.mx>
- Instituto Nacional de Salud Pública [INSP] (2020). *ENSANUT Encuesta nacional de salud y nutrición 2018-19: Resultados nacionales*. Cuernavaca, México: Secretaría de Salud, Instituto Nacional de Salud Pública (INSP), Instituto Nacional de Estadística y Geografía (INEGI). https://ensanut.insp.mx/encuestas/ensanut2018/doctos/informes/ensanut_2018_informe_final.pdf
- ENSANUT 2018. Resultados de Aguascalientes. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Chihuahua. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Coahuila. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Estado de México. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Guanajuato. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Guerrero. (2020). Cuernavaca, México: INSP.

- ENSANUT 2018. Resultados de Hidalgo. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Jalisco. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Michoacán. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Puebla. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Querétaro. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de San Luis Potosí. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Veracruz. (2020). Cuernavaca, México: INSP.
- ENSANUT 2018. Resultados de Zacatecas. (2020). Cuernavaca, México: INSP.
- Maluccio, J. A., Hoddinott, J., Behrman, J. R. *et al.* (2009). The impact of improving nutrition during early childhood on education among Guatemalan adults. *The Economic Journal*, 119(537), 734-763. DOI: 10.1111/j.1468-0297.2009.02220.x
- Mayer-Foulkes, D. (2008). The human development trap in Mexico. *World Development*, 36(5), 775-796. DOI: 10.1016/j.worlddev.2007.04.023
- Mendoza, J. L. (2019). Efectos de la desnutrición en el rendimiento escolar de los niños en el Perú. *Pensamiento Crítico*, 24(1), 79-102. DOI: 10.15381/pc.v24i1.16560
- Nasir, M. (2016). Violence and child health outcomes: Evidence from Mexican drug war. *UNU-WIDER Development Conference*, 6-7 June 2016, Helsinki, Finland. Clark University, 950. https://www.wider.unu.edu/sites/default/files/Events/PDF/Slides/1_nasir.pdf
- Organización Mundial de la Salud. (2023). *Joint Child Malnutrition Estimates: Key findings of the 2023 edition*. Levels and

- trends in child malnutrition. UNICEF/WHO/World Bank. Joint Malnutrition Working Group. Geneva, Switzerland: World Health Organization. <https://iris.who.int/bitstream/handle/10665/368038/9789240073791-eng.pdf?sequence=1>
- Rodríguez Gómez, R. (2015). El proyecto educativo SEP-SNTE y la prueba Enlace. *Revista Mexicana de Investigación Educativa*, 20(64), 309-324. https://www.scielo.org.mx/scielo.php?pid=S1405-66662015000100015&script=sci_arttext
- Soliman, A., De Sanctis, V., Alaaraj, N. *et al.* (2021). Early and long-term consequences of nutritional stunting: From childhood to adulthood. *Acta Bio Medica: Atenei Parmensis*, 92(1), e2021168. DOI: 10.23750/abm.v92i1.11346
- Walker, S. P., Chang, S. M., Powell, C. A. *et al.* (2005). Effects of early childhood psychosocial stimulation and nutritional supplementation on cognition and education in growth-stunted Jamaican children: prospective cohort study. *The Lancet*, 366(9499), 1804-1807. [https://www.thelancet.com/journals/lancet/article/PIIS0140-6736\(05\)67574-5/fulltext](https://www.thelancet.com/journals/lancet/article/PIIS0140-6736(05)67574-5/fulltext)
- Weiss, C. C., y García, E. (2015). Student engagement and academic performance in Mexico: Evidence and puzzles from PISA. *Comparative Education Review*, 59(2), 305-331. DOI: 10.1086/680170
- Wu, N., Chen, Y., Yang, J. *et al.* (2017). Childhood obesity and academic performance: The role of working memory. *Frontiers in Psychology*, 8, 611. 10.3389/fpsyg.2017.00611

Anexo: Resultados de los modelos Logit, varias especificaciones

Tabla A.1: Municipios reprobados en Comprensión de lectura.

MRCL						
				(5)		(6)
PRC	0.014*** (0.005)	0.013*** (0.005)				
PSO			-0.011** (0.005)	-0.011** (0.005)		
PO					0.001 (0.006)	0.002 (0.006)
PRE	0.058*** (0.009)	0.054*** (0.008)	0.057*** (0.009)	0.054*** (0.008)	0.059*** (0.009)	0.057*** (0.007)
PVCA	0.011* (0.006)	0.010* (0.006)	0.012** (0.006)	0.012** (0.006)	0.012** (0.006)	0.012** (0.006)
PVCS	-0.009* (0.005)	-0.010* (0.005)	-0.014*** (0.005)	-0.014*** (0.005)	-0.015*** (0.005)	-0.015*** (0.005)
PVI	0.016 (0.019)		0.009 (0.019)		0.007 (0.019)	
R	0.312** (0.132)	0.285** (0.128)	0.307** (0.132)	0.290** (0.128)	0.330** (0.132)	0.317** (0.128)
Constant	-2.142*** (0.415)	-1.894*** (0.280)	-1.574*** (0.421)	-1.440*** (0.308)	-1.874*** (0.402)	-1.764*** (0.282)
Observaciones	1,550	1,550	1,550	1,550	1,550	1,550
Log Likelihood	-953.716	-954.047	-955.529	-955.638	-957.942	-958.016
Akaike Inf. Crit.	1,921.432	1,920.094	1,925.057	1,923.276	1,929.884	1,928.032

Fuente: Estimaciones propias.
Nota: *p<0.1; **p<0.05; ***p<0.01.

Tabla A.2: Municipios reprobados en Matemáticas

	MRM					
	(1)	(2)	(3)	(4)	(5)	(6)
PRC	0.012*** (0.004)	0.009** (0.004)				
PSO			-0.012** (0.005)	-0.011** (0.005)		
PO					-0.0001 (0.006)	0.002 (0.006)
PRE	0.046*** (0.009)	0.027*** (0.007)	0.045*** (0.009)	0.026*** (0.007)	0.047*** (0.009)	0.029*** (0.007)
PVCA	0.011* (0.006)	0.005 (0.005)	0.012** (0.006)	0.006 (0.005)	0.012** (0.006)	0.007 (0.005)
PVCS	0.001 (0.005)	-0.005 (0.005)	-0.003 (0.005)	-0.007 (0.005)	-0.004 (0.005)	-0.009* (0.005)
PVI	0.072*** (0.018)		0.067*** (0.018)		0.066*** (0.018)	
R	-0.113 (0.129)	-0.238* (0.124)	-0.119 (0.129)	-0.239* (0.124)	-0.095 (0.129)	-0.209* (0.125)
Constant	-1.799*** (0.390)	-0.644** (0.257)	-1.260*** (0.398)	-0.233 (0.285)	-1.566*** (0.379)	-0.562** (0.259)
Observaciones	1,550	1,550	1,550	1,550	1,550	1,550
Log Likelihood	-1,040.359	-1,048.452	-1,040.987	-1,048.094	-1,043.929	-1,050.731
Akaike Inf. Crit.	2,094.718	2,108.903	2,095.973	2,108.188	2,101.859	2,113.462

Fuente: Estimaciones propias.

Nota: *p<0.1; **p<0.05; ***p<0.01.

Tabla A.3: Comprensión de lectura
(usando la mediana en MR).

	MRCL					
	(1)	(2)	(3)	(4)	(5)	(6)
PSO	0.009*** (0.003)	0.009*** (0.003)	-0.007** (0.003)	-0.007** (0.003)		
PO					-0.002 (0.004)	-0.001 (0.004)
PRE	0.033*** (0.005)	0.030*** (0.004)	0.032*** (0.005)	0.030*** (0.004)	0.033*** (0.005)	0.031*** (0.004)
PVCA	0.007* (0.004)	0.006* (0.004)	0.008** (0.004)	0.007** (0.003)	0.008** (0.004)	0.007** (0.003)
PVCS	-0.002 (0.003)	-0.003 (0.003)	-0.005 (0.003)	-0.006* (0.003)	-0.005 (0.003)	-0.006* (0.003)
PVI	0.012 (0.011)		0.008 (0.011)		0.008 (0.011)	
R	0.151* (0.081)	0.129* (0.078)	0.149* (0.081)	0.135* (0.078)	0.159** (0.081)	0.146* (0.078)
Constant	-1.193*** (0.247)	-0.994*** (0.165)	-0.837*** (0.252)	-0.719*** (0.182)	-1.004*** (0.239)	-0.886*** (0.166)
Obs	1550	1550	1550	1550	1550	1550
Akaike	1,983.514	1,982.688	1,989.854	1,988.319	1,994.246	1,992.704
Log Likelihood	-984.757	-985.344	-987.927	-988.160	-990.123	-990.352

Fuente: Estimaciones propias.
Nota: *p<0.1; **p<0.05; ***p<0.01.

Tabla A.4: Matemáticas (usando la mediana de MR).

	MRCL					
	(1)	(2)	(3)	(4)	(5)	(6)
PRC	0.007** (0.003)	0.005** (0.003)				
PSO			-0.005* (0.003)	-0.005 (0.003)		
PO					-0.0004 (0.004)	-0.001 (0.004)
PRE	0.029*** (0.005)	0.017*** (0.004)	0.029*** (0.005)	0.018*** (0.004)	0.030*** (0.005)	0.019*** (0.004)
PVCA	0.010*** (0.003)	0.006* (0.003)	0.010*** (0.003)	0.007** (0.003)	0.010*** (0.003)	0.007** (0.003)
PVCS	0.002 (0.003)	-0.001 (0.003)	-0.00002 (0.003)	-0.003 (0.003)	-0.0003 (0.003)	-0.003 (0.003)
PVI	0.045*** (0.011)		0.042*** (0.011)		0.042*** (0.011)	
R	-0.066 (0.080)	-0.145* (0.077)	-0.067 (0.080)	-0.143* (0.077)	-0.056 (0.080)	-0.129* (0.077)
Constant	-1.339*** (0.241)	-0.614*** (0.160)	-1.067*** (0.247)	-0.419*** (0.178)	-1.202*** (0.235)	-0.565*** (0.161)
Obs	1,550	1,550	1,550	1,550	1,550	1,550
Log Likelihood	-1,038.612	-1,046.860	-1,040.350	-1,047.591	-1,041.859	-1,048.903
Akaike	2,091.224	2,105.721	2,094.700	2,107.183	2,097.717	2,109.807

Fuente: Estimaciones propias.

Nota: *p<0.1; **p<0.05; ***p<0.01.

Análisis descriptivo de la mortalidad por enfermedades metabólicas en poblaciones vulnerables de Jalisco a partir del Seguro Popular

*Isaí Guízar**

*Daniel González Olivares***

*Fátima Housni****

Resumen

Este estudio parte de una posible paradoja en la que la ampliación del acceso a servicios de salud otorgada por el Seguro Popular podría haber impulsado la prevalencia de enfermedades metabólicas. Se examina en forma descriptiva la relación del Seguro Popular con la mortalidad por estas enfermedades en poblaciones vulnerables del estado de Jalisco. Los datos de mortalidad, del 2002 al 2022, se desagregaron en localidades según el nivel de cobertura del Seguro Popular (baja, media y alta). En el análisis se utilizaron técnicas econométricas de series de tiempo y modelos de conteo

* Departamento de Economía, CUCEA, Universidad de Guadalajara.

** Departamento de Métodos Cuantitativos, CUCEA, Universidad de Guadalajara.

*** Centro Universitario de Tlajomulco, Universidad de Guadalajara.

(Poisson y Binomial Negativa) con el objetivo de capturar cambios en el número de muertes a lo largo del tiempo para cada grupo. Se observó que las localidades con alta cobertura del Seguro Popular no presentaron cambios estadísticamente significativos, mientras que las localidades con cobertura media y baja mostraron una tendencia positiva y significativa. Este análisis permite formular un diagnóstico inicial de la relación, pero no es suficiente para rechazar la posibilidad de que la implementación del Seguro Popular haya tenido efectos adversos en la mortalidad; para ello, trabajos futuros deberán implementar análisis de causalidad.

Palabras Clave: *Seguro Popular, enfermedades metabólicas, mortalidad.*

Códigos JEL: I13, I14, I15, I18.

1. Introducción

El programa *Seguro Popular* operó en México del 2002 hasta el 2019. A principios del 2020 fue reemplazado por el Instituto de Salud para el Bienestar (INSABI), que posteriormente, en 2023, otorgó sus atribuciones a Servicios de Salud del Instituto Mexicano del Seguro Social para el Bienestar (IMSS-Bienestar) que opera en la actualidad. Los cambios recientes a la estructura del programa han generado fuertes cuestionamientos (Reich, 2020; Knaul *et al.*, 2023), en buena medida porque el enfoque de programa consistía en brindar protección financiera a poblaciones vulnerables. Con este fin, brindaba acceso a servicios de salud a aquellas personas que por su condición laboral o socioeconómica carecían de cualquier otro tipo de seguridad social. Este documento no constituye una evaluación del programa, no se pretende abonar a las discusiones sobre la efectividad en variables que explícitamente buscaba impactar, esto ha sido sujeto de escrutinio en varios estudios con resultados diversos (Barros, 2008; Ávila-Burgos *et al.*, 2013; Arenas *et al.*, 2015; García-Díaz *et al.*, 2018; Huffman y Van Gameren, 2019; Bautista-Arredondo,

Vargas-Flores, y Colchero-Aragón, 2024). Colchero, Gómez, y Bautista-Arredondo (2022) exponen una revisión exhaustiva de esta literatura. El interés aquí se centra en explorar su relación con la mortalidad por enfermedades metabólicas.

El punto de partida son los trabajos de grado de Costa-Font, Györi, y Sáenz de Miera (2020) y Porto (2023), quienes señalan la posibilidad de que la ampliación del ingreso disponible para consumo, debido al acceso al Seguro Popular, podría influir en las elecciones de alimentos. Mientras que los resultados de Costa-Font *et al.* no son concluyentes, Porto reporta incrementos en el consumo de alimentos clasificados como “azúcares procesados” y “aceites y grasas”. Es decir, propone que la disponibilidad de servicios médicos gratuitos o subsidiados pudieran reducir la percepción del riesgo asociado con comportamientos no saludables. Este fenómeno plantea la posibilidad de que la implementación del *Seguro Popular* paradójicamente haya tenido efectos indirectos adversos en la salud a través de cambios en la dieta, un conflicto importante en la evaluación integral de los efectos del programa.

Las lecciones de análisis a programas similares en el contexto internacional tampoco ofrecen una perspectiva clara sobre esta paradoja. Por ejemplo, los resultados de estudios sobre la Ley de Cuidado de Salud a Bajo Precio (*Affordable Care Act*) en Estados Unidos, también conocida como *Obamacare*, encuentran evidencia en ambas direcciones, que las tasas de sobrepeso y obesidad disminuyen (Courtemanche y Zapata, 2013; Barbaresco, Courtemanche, y Qi, 2015; Rhubart, 2018), y también que el índice de masa corporal y la obesidad tienden a aumentar (Bhattacharya *et al.*, 2009).

Para el caso del Seguro Popular, Costa-Font *et al.* (2020) intentaron descifrar los efectos en sobrepeso, obesidad e índice de masa corporal, pero no encontraron evidencia a favor de ninguna. Las cifras epidemiológicas indican, sin constituir evidencia de causa que, durante el periodo de vigencia del programa, en el

país se experimentó un incremento acelerado en la mortalidad por enfermedades metabólicas. Según datos del Instituto Nacional de Estadística y Geografía (INEGI), la tasa de mortalidad por diabetes mellitus tipo 2 aumentó de 46.8 por cada 100,000 habitantes en 2000 a 84.7 en 2018.

En el 2020, la diabetes mellitus fue la tercera causa de defunciones en México, sólo superada por el COVID 19 y las enfermedades del corazón (@statsInegi2021b).

Este trabajo se propone ofrecer una exploración inicial a este posible conflicto de la intervención del Seguro Popular, donde la ampliación del acceso a servicios de salud podría haber impulsado el consumo de alimentos poco saludables, incidiendo directamente en la mortalidad por enfermedades metabólicas. *A priori* se desconoce la dirección de la relación, ya que aún si el incremento en la ingesta de alimentos no saludables impulsara la prevalencia de las enfermedades, la magnitud del cambio podría no ser suficiente para impactar en la mortalidad. Por otra parte, el acceso a servicios de atención médica otorgado por el propio seguro supondría un mejor control de enfermedades previsibles, reduciendo la mortalidad por estas enfermedades.

El conflicto es de interés porque aborda la complejidad de los efectos a largo plazo de las intervenciones en salud pública. Las enfermedades metabólicas no sólo representan un reto para el sistema de salud, sino que también imponen un alto costo social y económico a las familias mexicanas, especialmente entre los sectores más vulnerables de la población. Generar evidencia sobre los factores que podrían estar agravando o aliviando estas condiciones facilitará el desarrollo de políticas públicas más equitativas y eficientes.

Dar respuesta una respuesta definitiva a esta paradoja plantea un reto metodológico importante, en cuanto a cómo aislar los efectos en mortalidad de esta política pública, que no se supera con lo que aquí se realiza; el objetivo entonces es más

bien modesto, proveer una descripción inicial de la relación, que sirva de base para trabajos futuros. La estrategia que se emplea es relativamente simple. Nos enfocamos en localidades conformadas por poblaciones vulnerables²³. Estas localidades fueron separadas en grupos de acuerdo con el nivel de cobertura: de baja ($< 25\%$), media ($25 - 50\%$) y alta ($\geq 50\%$). Posteriormente, contrastamos la mortalidad por enfermedades metabólicas entre estos grupos utilizando una serie temporal, de forma trimestral, desde el 2002 hasta el 2022. Se utilizan técnicas de series de tiempo para identificar el componente de tendencia entre los tres niveles de cobertura. Para modelar la relación entre el tiempo y la mortalidad se emplearon modelos de conteo (Poisson y binomial negativa). Los resultados indican que las localidades con alta cobertura del Seguro Popular no presentaron un incremento estadísticamente significativo en la mortalidad por enfermedades metabólicas a lo largo del tiempo, mientras que las localidades con cobertura media y baja mostraron aumentos significativos en la mortalidad.

El resto del documento se organiza de la siguiente manera. En la siguiente sección, se presenta una revisión de literatura relevante, enfocada en el impacto del Seguro Popular con variables socioeconómicas y de salud, particularmente en enfermedades metabólicas y mortalidad. La sección 3 describe los datos empleados tanto de las localidades que se analizan como de las estadísticas de mortalidad. La sección 4 presenta las técnicas estadísticas y los modelos de conteo aplicados. En esta misma sección se presentan los resultados y se discuten las implicaciones de los hallazgos. Finalmente, la sección 5 ofrece las conclusiones, destacando las contribuciones del estudio, sus limitaciones, y posibles líneas para investigaciones futuras.

23 Rurales en las que más del 50% de la población no tuviera acceso a programa de seguridad social alguno.

2. Revisión de literatura

El Seguro Popular (SP), como política de aseguramiento público en México, ha sido ampliamente estudiado. Una revisión extensa de esta literatura se halla en Colchero, Gómez, y Bautista-Arredondo (2022). La presente revisión se limita a exponer sólo algunos estudios enfatizando la diversidad de los resultados encontrados. Se inicia presentando trabajos relacionados con el uso y oferta de los servicios ofrecidos por el programa. Posteriormente se describen hallazgos de los trabajos que exploran la relación con cambios en los gastos de salud. Al final, se presentan análisis sobre prevalencia de enfermedades y mortalidad.

Mediante un experimento aleatorio King *et al.* (2009) estudiaron el efecto del SP en, entre otras variables, la utilización de servicio de salud. Los autores no encontraron efectos estadísticamente significativos. Sosa-Rubí, Galárraga, y Harris (2009) se enfocaron en analizar el impacto del SP únicamente en la utilización de servicios obstétricos, empleando modelos de probabilidad y datos de la Encuesta Nacional de Salud y Nutrición [ENSANUT] y reportaron un impacto positivo. La evaluación de Arenas *et al.* (2015) fue más general, en consultas y hospitalización; utilizaron datos de la Encuesta Nacional sobre Niveles de Vida de los Hogares de 2002 y 2005. Estos autores concluyeron que el programa no tuvo impacto alguno en el número de hospitalizaciones. En cuanto al número de consultas, reportaron efectos positivos sólo en mujeres de origen urbano. Huffman y Van Gameren (2019) estudiaron los efectos del SP sobre la oferta de servicios de salud. Emplearon registros administrativos del SP y de infraestructura de la Secretaría de Salud. Encontraron que el programa tuvo un impacto positivo en la disponibilidad de infraestructura y recursos humanos, aunque también con variaciones significativas según la región y el nivel socioeconómico de la población. Más recientemente, Bautista-Arredondo *et al.* (2024), mediante un análisis descriptivo, afirmaron que durante

el periodo de rápida expansión del SP (2006-2012) no se experimentaron cambios significativos en la búsqueda de atención ni en el uso de servicios públicos de salud. Así mismo, observaron que la desaparición del SP en 2019 tampoco habría causado una reducción en la búsqueda de atención ni en la utilización de estos servicios.

El objetivo del programa, ofrecer protección financiera, también ha sido examinado en varios estudios. Gakidou *et al.* (2006) presentaron una evaluación del SP, entre otras dimensiones, en los gastos de salud. Utilizando datos de la ENSANUT señalan que los afiliados al Seguro Popular gastaban menos en promedio que los no asegurados; no obstante, puntualizan que la reducción no fue sustancial en términos absolutos. Identificaron que el SP reduce la probabilidad de incurrir en gastos catastróficos, particularmente, en hogares que reportaron uso de servicios de salud ambulatorios y hospitalarios. Galárraga *et al.* (2008) utilizaron distintas bases de datos (Encuesta Nacional de Ingresos y Gastos de los Hogares (ENIGH), ENSANUT y la Encuesta de Evaluación de Impacto del SP) con el mismo fin. Los autores reportan resultados mixtos, en el análisis con la ENIGH reportan una reducción de los gastos de los hogares en medicamentos y atención ambulatoria, pero no observaron ningún efecto en los gastos catastróficos. Del análisis con las otras dos encuestas reportan que el SP reduce la probabilidad de incurrir en gastos catastróficos. Con el mismo propósito, Sosa-Rubí *et al.* (2011) analizaron los datos de la Encuesta de Evaluación del Impacto del SP (2005-2008); sus resultados muestran que el SP redujo la incidencia de gastos catastróficos y de bolsillo, especialmente en hogares rurales. En el trabajo de King *et al.* (2009) también se evaluó el impacto del SP en variables financieras. Los autores reportaron que el programa disminuyó los gastos de bolsillo en servicios hospitalarios y ambulatorios, especialmente en

los hogares más pobres, pero no observaron ningún efecto en los gastos en medicamentos.

En relación con los impactos por la prevalencia de enfermedad y mortalidad, tampoco hay escasez de literatura. Los resultados, sin embargo, son variados y frecuentemente dependientes de factores socioeconómicos, demográficos y geográficos. Pfitze (2014) analizó la mortalidad infantil (primer año de vida) y neonatal (primer mes de vida) durante los primeros cinco años de implementación del SP (2004-2009); reportó que el SP redujo la mortalidad infantil en aproximadamente 4.94 muertes por cada 1,000 nacimientos vivos en promedio, mientras que la mortalidad neonatal se redujo en 2.73 muertes por cada 1,000 nacimientos vivos. Pfitze también encontró que los efectos fueron mayores para los quintiles de más bajos ingresos. El trabajo de Muñoz-Aguirre *et al.* (2021) también se enfocó en infantes, particularmente, en niños diagnosticados con leucemia linfoblástica aguda. Evaluaron la supervivencia a 5 años a nivel nacional y estatal; a nivel nacional no encontraron mejoras significativas, pero a nivel estatal encontraron efectos positivos con variaciones desde 33.6% hasta 76.4%. Los autores atribuyeron estas diferencias a la infraestructura de salud y la disponibilidad de recursos humanos de los estados.

Conti y Ginja (2020) evaluaron el impacto del SP en mortalidad general mediante un análisis cuasi-experimental, pero sólo encontraron reducciones significativas en la población infantil residente en municipios en condición de pobreza. La reducción fue notable en muertes previsibles, como las relacionadas con diarrea, infecciones respiratorias y complicaciones perinatales. El análisis de Arenas *et al.* (2023), por otra parte, fue para la población adulta. Observaron una reducción en la mortalidad en adultos mayores de 50 años, habitantes de zonas rurales. Cohen y Dechezleprêtre (2022) examinaron cómo la temperatura afecta la mortalidad en México; en ese contexto evaluaron el impacto

del programa Seguro Popular. Estos autores observaron que las temperaturas frías representan un riesgo significativo para la mortalidad en México, especialmente entre las poblaciones de menores ingresos; en relación con el SP, los autores estiman que el programa habría salvado al año, al menos 1,600 vidas en riesgo debido a bajas temperaturas. El trabajo de Hernández-Garduño y Jiménez-Cortez (2017) se asemeja a lo que se presenta en este documento. Ellos analizan la relación entre la implementación del Seguro Popular (SP) y las tasas de mortalidad por diabetes mellitus en la población adulta (20 a 79 años) durante el período 1999-2014. Identificaron un cambio significativo en la tendencia de las tasas de mortalidad (estandarizadas por edad) en 2004, que coincide con la introducción del SP. Si bien tampoco de este trabajo se puede inferir causalidad, el estudio sugiere una asociación entre la implementación del Seguro Popular y una desaceleración en el aumento de las tasas de mortalidad.

En general, el Seguro Popular parece haber tenido un impacto heterogéneo en la utilización de servicios médicos. Los efectos generales en el uso de estos servicios se sugieren limitados y dependientes de características socioeconómicas y/o geográficas. La literatura parece consistente en que el Seguro Popular logró avances importantes en términos de protección financiera, especialmente entre los hogares más vulnerables. De igual manera, los estudios han documentado efectos heterogéneos en la mortalidad.

3. Descripción de datos

La cobertura geográfica del Seguro Popular fue gradual. En su inicio en 2002, solo operó en algunas regiones de Colima, Jalisco, Aguascalientes, Tabasco y Campeche. Los municipios beneficiados en esta etapa se muestran en la Tabla 1 del Anexo. La cobertura no fue universal, sino, como se señala en las reglas

de operación, la unidad de afiliación estuvo constituida primordialmente por las familias nucleares (el padre y/o la madre y los hijos menores de 18 años de ambos o de alguno de ellos) que, además de residir en las regiones de cobertura, no fueran derechohabientes de la seguridad social, optaran voluntariamente por afiliarse, y cubrieran la cuota de afiliación correspondiente. Al no contar con información a nivel individual o vivienda, la unidad de análisis en este trabajo es la localidad.

Características de las localidades

El procedimiento para extraer la información de las localidades objeto de análisis fue el siguiente:


1. Se seleccionaron únicamente los municipios del estado de Jalisco porque representaban el 62% del total nacional de municipios donde operó en la etapa inicial del programa. En este paso se utilizó la información del Censo de Población y Vivienda del año 2000 del INEGI. De estos municipios se mantuvieron solo las localidades rurales (<2,500 habitantes) que tenían viviendas particulares habitadas y en las que la mayoría de la población (>50%) no tenía acceso a ningún programa de seguridad social. De esta manera, en este trabajo, se entiende por poblaciones vulnerables a los habitantes de localidades rurales con escaso o nulo acceso a la seguridad social.
2. Para calcular el porcentaje de cobertura del seguro en las localidades seleccionadas, se utilizó el conteo de Población y Vivienda de 2005. De la unión de estos dos conjuntos resultaron 1,159 localidades. En 336 de estas no había beneficiario alguno, y como se muestra en la Figura 5 y Figura 6 del Anexo, por el tamaño significativamente menor de la población y del número de viviendas

habitadas, estas localidades no son comparables con el resto de la muestra.

3. Se mantuvieron para el análisis las 823 localidades restantes, es decir, todas las que contabilizaron habitantes beneficiarios del programa. Estas localidades se clasificaron en tres grupos de acuerdo con nivel de cobertura del Seguro Popular, los umbrales son arbitrarios, buscan garantizar comparabilidad entre los grupos: baja ($\leq 25\%$), media ($25\% - 50\%$) y alta ($> 50\%$).

La distribución del porcentaje de cobertura para cada grupo se aprecia en la Figura 1. Resultaron 362 localidades en el nivel bajo; en este estrato, el 13.1% de los habitantes contaba con el Seguro Popular. En el nivel de cobertura media, se agruparon 279 localidades; para estas, el nivel de cobertura promedio fue del 37.4%. El grupo de cobertura alta lo constituyen 182 localidades con un promedio de cobertura de 66.6%. La población total de cada grupo en el año 2000 fue de 74,044 (baja), 47,423 (media), y 20,844 (alta) habitantes.

Figura 1: Dispersión del porcentaje de cobertura



Fuente: Elaboración propia con información de Censos y Estadísticas de Defunciones Registradas (EDR) del INEGI.

Algunas características socioeconómicas de las localidades en el año 2000 se presentan en la Tabla 1. Las localidades de cobertura baja son más grandes en promedio en términos de población y número de hogares. Los tres grupos son similares en cuanto al promedio de habitantes por vivienda (≈ 5) y grado de escolaridad (≈ 4)²⁴. El resto de las características de las viviendas mostradas en la Tabla señalan indicios de que el grupo de cobertura alta presentaba mayor marginación en comparación con los de cobertura media y baja, debido a que una menor proporción de viviendas disponía de agua entubada, electricidad y automóvil propio. Además, tenían una mayor proporción de población ocupada en el sector primario. Estos valores son consistentes con lo establecido en las reglas de operación del programa en cuanto a que, en las

24 El grado de escolaridad es el promedio de los años aprobados desde el primero de primaria hasta el último grado alcanzado en personas de 15 años y más.

primeras etapas de implementación, la población de los seis primeros deciles de la distribución del ingreso sería la prioritaria.

Tabla 1: Características socioeconómicas de las localidades en el 2000

	Promedio			Desv. Est.		
	Baja	Media	Alta	Baja	Media	Alta
Nivel de cobertura						
Promedio de habitantes	204.5	170.0	114.5	349.3	301.3	222.1
Total de hogares	43.4	35.9	23.3	82.3	65.6	45.8
Habitantes por vivienda	5.1	5.0	5.2	1.0	1.1	1.2
Viv. con agua entubada (%)	46.2	48.5	42.5	37.2	38.1	38.4
Viv. con electricidad (%)	81.9	71.6	60.6	28.4	36.6	42.8
Viv. con automóvil (%)	53.9	47.6	37.7	22.1	25.0	27.5
Pob. económicamente activa (%)	30.4	29.9	28.3	9.1	8.7	8.6
Pob. ocupada (%)	30.2	29.7	28.2	9.0	8.8	8.6
Pob. ocupada en sector primario (%)	19.5	20.8	21.3	9.2	9.8	8.4
Grado de escolaridad	4.0	4.0	3.9	1.1	1.2	1.2

Fuente: Elaboración propia con datos de Censos del INEGI.

Estadísticas de mortalidad

Los datos de mortalidad fueron extraídos de las Estadísticas de Defunciones Registradas (EDR) publicadas por el INEGI; son útiles para lograr nuestro propósito porque proporcionan información de la mortalidad de la población y sus causas por día de ocurrencia desde 1990. Además, su estructura permite agregar los datos al nivel geográfico deseado. La variable de mortalidad que empleamos en el análisis resulta de sumar las defunciones desde el año 2002 hasta el 2022. Se contabilizaron todas las defunciones clasificadas según la lista mexicana como “enfermedades endocrinas y metabólicas”, estas son los trastornos tiroideos relacionados con la deficiencia de yodo, tirotoxicosis,

otros trastornos de la tiroides, diabetes mellitus, trastornos del metabolismo, de las lipoproteínas y otras lipidemias, obesidad, depleción del volumen, secuelas de hiperalimentación, y las demás enfermedades endocrinas y metabólicas. En la definición de variables de las EDR, se señala que estos registros de muertes especifican la causa básica de la defunción, la enfermedad o lesión que inició la cadena de acontecimientos patológicos que condujeron directamente a la muerte. La evolución de la mortalidad por nivel de cobertura se aprecia en la Tabla 2, las localidades con cobertura alta tienen consistentemente el menor número de muertes, las localidades con cobertura media presentan un nivel intermedio, mientras que aquellas con cobertura baja experimentaron un crecimiento sostenido y alto en el número de muertes. Estos valores podrían ser indicativos de cómo la cobertura del programa influye en la mortalidad.

Tabla 2: Evolución de las defunciones por enfermedades metabólicas según nivel de cobertura del Seguro Popular

Año	Alta	Media	Baja
2002	5	9	22
2003	4	14	26
2004	2	11	29
2005	5	16	29
2006	4	4	25
2007	4	13	26
2008	8	13	28
2009	5	21	31
2010	4	21	38
2011	8	20	26
2012	11	16	31
2013	2	24	41
2014	5	24	28
2015	4	22	40
2016	8	13	42
2017	6	17	32
2018	8	13	43
2019	6	23	49
2020	7	36	54
2021	4	29	59
2022	7	22	57

Fuente: Elaboración propia con información de EDR del INEGI.

La Tabla 3 muestra que tanto el número de defunciones anuales promedio como la variación son inversos al nivel de cobertura. En las localidades de cobertura baja, se registraron 36 muertes por enfermedades metabólicas en promedio al año; el menor registro fue de 22 y el mayor de 59. En los de cobertura media, el promedio se eleva a 18.1, el rango va de 4 a 36 defunciones. En

cobertura alta el número promedio se reduce a 5.6, el máximo de defunciones no superó los 11 registros y el menor fue de 2. La normalización del número promedio de muertes por el tamaño de la población ofrece una idea más clara de la mortalidad por estas enfermedades. Al utilizar como base la población del año 2000, se obtienen tasas de 0.49, 0.24 y 0.08 muertes por cada 1000 habitantes, para los grupos de cobertura baja, media y alta, respectivamente.

Tabla 3: Estadísticas descriptivas de defunciones anuales por enfermedades metabólicas según nivel de cobertura del Seguro Popular

	Promedio	SD	Mediana	Min	Max
Alta	5.6	2.2	5	2	11
Media	18.1	7.2	17	4	36
Baja	36.0	11.2	31	22	59


Fuente: Elaboración propia con información de EDR del INEGI.

Con el fin de obtener una mejor perspectiva sobre la evolución de la mortalidad a lo largo del tiempo se optó por generar una serie de tiempo trimestral. Lo sucesos se agregaron a esta frecuencia, debido a que con periodos temporales más cortos la serie presentaba un exceso de ceros, mientras que con frecuencias más largas se reduce el tamaño de la muestra. Haciéndolo por trimestres se logra variación en los valores y se mantiene un número suficiente de observaciones para aplicar técnicas econométricas de análisis de series de tiempo.

La Figura 2 muestra las series de tiempo para cada nivel de cobertura. En el panel superior se observa cierta tendencia positiva en el número de defunciones; esto es, en las localidades de cobertura baja, el promedio trimestral, mostrado por la línea horizontal, es de 9 registros. Los indicios de tendencia positiva

son menos claros en el siguiente panel (el del grupo de cobertura media), ya que el nivel promedio se reduce a 4.5. En el panel inferior el promedio es aún menor, 1.4, y no se aprecia la tendencia.

Figura 2: Evolución de la mortalidad por nivel de cobertura del Seguro Popular.



Fuente: Elaboración propia con información de EDR del INEGI.

4. Análisis econométrico

Para verificar que la tendencia de las series existe, así como su importancia relativa, se procede a extraer sus componentes empleando el método STL (Seasonal-Trend decomposition), mediante regresión local (Loess), desarrollado por Cleveland *et al.* (1990). Asumiendo una descomposición aditiva,


$$m_t = T_t + S_t + R_t$$

donde el número de muertes en el periodo t , m_t , es la suma de la tendencia (T_t), estacionalidad (S_t) y el residual (R_t). Las series originales con sus tres elementos se muestran en la Figura 7 del Anexo.

De interés particular son los componentes de tendencia que se replican en la Figura 3. La figura nos permite confirmar un incremento en el número de muertes en las localidades donde pocos habitantes fueron beneficiarios del seguro. Para este grupo el número de defunciones fue aproximadamente de 5 cuando inició el programa, en el 2002, y alcanzó hasta 15 en el cuarto trimestre de 2021. La tendencia en la serie de cobertura media también se observa positiva aunque menos pronunciada. En las regiones donde la mayoría tenía acceso (alta) al seguro, el componente es de menor importancia²⁵; se aprecia que las muertes fluctuaron entre 0 y 3 en todo el periodo.

25 La importancia relativa de cada componente para cada serie se distingue con las barras verticales a la izquierda de los gráficos en la Figura 7. Aunque las barras tienen la misma longitud, se muestran a escala, lo que permite distinguir la magnitud de cada componente. Para la serie de tiempo de cobertura alta, la barra en el componente de tendencia es más grande que el residual, indicando que la variación trimestral la explica el residual en mayor proporción.

Figura 3: Componente de tendencia en las series de tiempo de defunciones, por nivel de cobertura.



Fuente: Elaboración propia con información de EDR del INEGI.

La prueba de Dickey-Fuller aumentada [ADF] en que la hipótesis nula es que la serie es no-estacionaria, y la de Kwiatkowski *et al.* (1992, KPSS) en que la hipótesis nula es que la serie es estacionaria, corroboran que la serie de defunciones en localidades de cobertura alta es estacionaria (Tabla 4). A diferencia de las regiones con cobertura baja o media, donde podríamos observar tendencias al alza en la mortalidad, la estacionariedad en el grupo de alta cobertura implica que los cambios en la

mortalidad no han sido estadísticamente significativos a lo largo del tiempo.

Tabla 4: Pruebas de estacionariedad de las series de tiempo de defunciones.


Cobertura	ADF [Stat]	ADF [p-value]	KPSS [Stat]	KPSS [p-value]
Baja	-3.441	0.054	1.558	0.01
Media	-3.012	0.161	0.930	0.01
Alta	-5.692	0.010	0.278	0.10

De forma alterna, en la Figura 4, se presentan los intervalos de confianza y estimadores puntuales de la regresión simple, el total de muertes en función del periodo de tiempo. Esto es:

$$Muertes_t = \beta_0 + \beta_1 Trimestre_t + u_t$$

Las pendientes estimadas para cada grupo son 0.39 [baja], 0.19 [media], y 0.03 [alta]. Aunque todos los coeficientes son positivos, sólo el correspondiente al de cobertura alta no es significativamente diferente de cero.

Figura 4: Intervalos de confianza al 95% para el coeficiente de tendencia.



Los hallazgos sugieren que en las regiones con alta cobertura del Seguro Popular la mortalidad por enfermedades metabólicas no experimentó un aumento significativo; en contraste, en las regiones con baja cobertura, el incremento de la mortalidad fue sustancial. Esto puede respaldar la idea de que el Seguro Popular logró mantener bajo control las tasas de mortalidad.

Hasta este punto no se ha descartado la posibilidad de que el incremento en el número de muertes en la serie de baja cobertura sea ocasionado simplemente por un mayor tamaño de la población. Los conteos de población no se realizan con la frecuencia necesaria para poder controlar este factor en la serie de tiempo. Como alternativa es posible tomar la información del año 2000, previo al inicio del programa, y la del último conteo, que es el censo de 2022 para calcular el cambio en la población y compararlo con el cambio en la mortalidad. El cambio poblacional en este periodo se muestra en la Tabla 5. La población total en las localidades de alta no creció, fue de -0.07% al año, mientras que en las áreas de cobertura baja el incremento fue relativamente

pequeño. La tasa de crecimiento geométrico anual es de 0.46%; es decir, la tasa de crecimiento es insuficiente para explicar el incremento en la mortalidad.

Tabla 5: Población total, por nivel de cobertura, 2000 vs 2022.

Cobertura	2000	2022	Tasa
Baja	68,950	75,611	0.46%
Media	44,821	47,097	0.25%
Alta	20,239	19,947	-0.07%

Tampoco se ha tomado en cuenta que el número de muertes es una variable de conteo, no continua. Los valores posibles para las defunciones son números enteros no negativos. Debido a que el modelo clásico de regresión lineal anterior asume que la variable dependiente es continua y puede tomar valores negativos, no es totalmente apropiado para el caso presente. Por ello, a continuación se emplean la distribución de Poisson o, en caso de que los datos presenten sobredispersión, la binomial negativa. Si se asume que el número de muertes en la localidad i , M_i , sigue una distribución de Poisson con una media $E(M_i) = \mu_i$,

$$P(M_i = m_i) = \frac{\mu_i^{m_i} e^{-\mu_i}}{m_i!}$$

con $m_i = 0, 1, 2, \dots, \mu_i > 0$ es el promedio de muertes para la localidad i . La ecuación que se estima para cada nivel de cobertura es:

$$\log(\mu_i) = \beta_0 + \beta_1 \text{Trimestre}_i$$

En este modelo un supuesto crucial es que la varianza de M es igual a la media, $\text{Var}(M) = \mu$. Para verificar si se cumple, se

utiliza la prueba de Cameron y Trivedi (1990). La hipótesis nula es que la varianza es estadísticamente igual que la media. Los resultados que se muestran en la Tabla 6 rechazan la nula en el caso de la serie de tiempo Baja y Media. Se concluye que en estos dos casos se exhibe sobredispersión.

Tabla 6: Pruebas de dispersión para el modelo de Poisson

Serie	Estadístico	p-value
Baja	2.88	0.002
Media	2.37	0.009
Alta	0.44	0.330

El modelo de Poisson es solo apropiado en la serie Alta. Para los otros dos conviene utilizar la distribución binomial negativa. Esto es, la variable dependiente sigue la siguiente distribución:

$$P(M_i = m_i) = \frac{\Gamma(\frac{1}{a} + m_i)}{\Gamma(\frac{1}{a}) m_i!} \left(\frac{\frac{1}{a}}{\frac{1}{a} + \mu_i} \right)^{\frac{1}{a}} \left(\frac{\mu_i}{\frac{1}{a} + \mu_i} \right)^{m_i}$$

donde $\Gamma(\cdot)$ es la función gamma y $a > 0$ es el parámetro de dispersión, de tal forma que $Var(M) = \mu + \alpha\mu^2$ captura el exceso de varianza.

Para facilitar la comparación se estimaron las tres series usando las distribuciones. Los resultados se aprecian en la Tabla 7. El coeficiente asociado al Trimestre indica el cambio en el logaritmo del número esperado de muertes en función del tiempo. En las regiones de cobertura alta, el coeficiente es estadísticamente nulo. En cambio, el de las series de cobertura media y alta es positivo y significativo. Una interpretación simple del coeficiente $\beta_i = 0.044$ es que el número esperado de muertes, e^{β_1} incrementa a una tasa aproximada de 4.5 % por trimestre. Los

resultados corroboran una diferencia significativa en la dinámica de mortalidad por enfermedades metabólicas entre localidades con alta cobertura del Seguro Popular y aquellas con cobertura media y baja. En las localidades con cobertura alta, el coeficiente de tendencia temporal es cero, lo que implica que la mortalidad no presenta un incremento sistemático a lo largo del tiempo. En contraste, las localidades con cobertura media y baja muestran un incremento significativo en la mortalidad a lo largo del tiempo, evidenciado por un coeficiente positivo y de magnitud similar.

Tabla 7: Estimación de la tendencia con Modelos de Poisson y Binomial Negativa

Modelo	Serie	Variable	Coeff.	Err. Est.	Estad.	p-value
Poisson	Alta	Const.	-43.920	30.895	-1.422	0.1551
		Trimestre	0.022	0.015	1.433	0.1520
	Media	Const.	-86.287	17.394	-4.961	0.0000
		Trimestre	0.044	0.009	5.050	0.0000
	Baja	Const.	-86.394	12.353	-6.994	0.0000
		Trimestre	0.044	0.006	7.175	0.0000
Binomial Negativa	Alta	Const.	-44.079	31.738	-1.389	0.1649
		Trimestre	0.022	0.016	1.400	0.1617
	Media	Const.	-86.986	20.096	-4.329	0.0000
		Trimestre	0.044	0.010	4.405	0.0000
	Baja	Const.	-86.357	12.400	-6.965	0.0000
		Trimestre	0.044	0.006	7.145	0.0000

5. Conclusiones

Este trabajo se realizó con el objetivo de explorar cómo la cobertura del Seguro Popular en México pudo haber influido en la mortalidad por enfermedades metabólicas en poblaciones en condición de vulnerabilidad. Nuestros resultados muestran diferencias importantes entre localidades con distintos niveles de cobertura, lo que aporta evidencia relevante para el diseño de políticas públicas en salud.

En las localidades donde el programa inició con una cobertura alta del Seguro Popular, la mortalidad por enfermedades metabólicas no presentó un incremento sistemático a lo largo del tiempo. Mediante la descomposición de la serie de tiempo se mostró que el componente de tendencia mantenía poca relevancia en las variaciones totales de mortalidad. Tanto el modelo de Poisson como el de Binomial Negativa indicaron que el coeficiente de tendencia es estadísticamente nulo. Esto sugiere que la alta cobertura del programa pudo haber actuado como un factor protector, estabilizando o reduciendo la mortalidad atribuida a estas enfermedades. En contraste, las localidades con cobertura media y baja mostraron coeficientes de tendencia positivos y estadísticamente significativos, lo que implica un aumento en la mortalidad a lo largo del tiempo.

A pesar de estos hallazgos, este trabajo presenta algunas limitaciones que deben ser consideradas al interpretar los resultados. En primer lugar, la naturaleza de los datos no permite identificar completamente la causalidad entre la cobertura del Seguro Popular y los cambios en la mortalidad. Se ignora el hecho de que algunas localidades clasificadas como de baja o media cobertura al inicio pudieran ser de alta en años posteriores. Tampoco se incluyeron variables que capturen otras posibles fuentes de heterogeneidad, como cambios en la estructura poblacional, modificaciones en las prácticas de diagnóstico y reporte, el fenómeno de migración, la calidad de la infraestructura o el impacto

de políticas complementarias que pudieron haber influido en los resultados de salud.

Finalmente, la agregación temporal y geográfica puede haber diluido efectos más precisos que ocurrieron en niveles específicos. Por estas razones, si bien los resultados son informativos, el lector debe considerar que no son suficientes para rechazar la posibilidad de que la implementación del *Seguro Popular* haya tenido efectos indirectos adversos en la mortalidad. Por ahora sólo se puede subrayar que los niveles de cobertura son relevantes al evaluar la efectividad de las políticas de aseguramiento público para mitigar desigualdades en los resultados de salud.

En términos de prospectiva, este trabajo abre la puerta a futuros análisis que aborden los efectos diferenciales del aseguramiento público en poblaciones más desagregadas o mediante métodos que permitan evaluar causalidad de manera más robusta, como experimentos naturales o modelos de datos de panel. Asimismo, sería valioso explorar el papel de factores adicionales, como los hábitos alimenticios y los determinantes sociales de la salud, para comprender mejor los mecanismos subyacentes que vinculan las políticas de aseguramiento con la mortalidad.


Anexo

Regiones seleccionadas para la operación inicial del Seguro Popular

Estado	Municipio
Campeche	Calkiní
	Hecelchakán
	Tenalbo
	Campeche
	Holpechén
Tabasco	Comalcalco
	Cunduacán
Jalisco	Acatic
	Atotonilco
	Ayotlán
	Cabo Corrientes
	Arandas
	Encarnación de Díaz
	Jalostotitlán
	Jesús María
	Puerto Vallarta
	San Julián
	San Miguel el Alto
	San Sebastián del Oeste
	Tepatitlán de Morelos
	Tomatlán
	Valle de Guadalupe
	Cañadas de Obregón
Aguascalientes	Aguascalientes
Colima	Colima
	Villa de Álvarez


Fuente: Diario Oficial de la Federación, 15/03/2002.

Figura 5: *Tamaño poblacional por nivel de cobertura*




Fuente: Elaboración propia con información de Censos del INEGI.

Figura 6: *Viviendas habitadas por nivel de cobertura*



Fuente: Elaboración propia con información de Censos del INEGI.

Figura 7: Descomposición de las series de tiempo de defunciones, por nivel de cobertura.



Referencias

- Arenas, E., Parker, S., Rubalcava, L. *et al.* (2015). Evaluación del programa del Seguro Popular del 2002 al 2005. Impacto en la utilización de servicios médicos, en el gasto en salud y en el mercado laboral. *El Trimestre Económico*, 82(328), 807-845. <https://www.scielo.org.mx/pdf/ete/v82n328/2448-718X-ete-82-328-00807.pdf>
- Arenas, E., Parker, S. W., Rubalcava, L. *et al.* (2023). Impact of health insurance on adult mortality in rural areas: Evidence of Seguro Popular in Mexico using panel data. *World Development Perspectives*, 30, 100501. DOI: 10.1016/j.wdp.2023.100501
- Ávila-Burgos, L., Serván-Mori, E., Wirtz, V. J. *et al.* (2013). Efectos del Seguro Popular sobre el gasto en salud en hogares mexicanos a diez años de su implementación. *Salud Pública de México*, 55(supl. 2), S91-S99. <https://www.scielosp.org/pdf/spm/2013.v55supl2/S91-S99/es>
- Barbaresco, S., Courtemanche, C. J. y Qi, Y. (2015). Impacts of the Affordable Care Act dependent coverage provision on health-related outcomes of young adults. *Journal of Health Economics*, 40, 54-68. DOI: 10.1016/j.jhealeco.2014.12.004
- Barros, R. (2008). *Wealthier but not much healthier: effects of a health insurance program for the poor in Mexico*. Palo Alto, CA, Stanford University Department of Economics. https://www.academia.edu/download/5573407/jmp_rbarros.pdf
- Bautista-Arredondo, S. A., Vargas-Flores, A. y Colchero-Aragón, M. A. (2024). Búsqueda de atención y utilización de servicios en el primer nivel, 2006-2023. *Salud Pública de México*, 66(4), 589-597. DOI: 10.21149/16215
- Bhattacharya, J., Bundorf, K., Pace, N. *et al.* (2009). Does health insurance make you fat? *NBER Working Papers*, (w15163). DOI: 10.3386/w15163

- Cameron, A. C., y Trivedi, P. K. (1990). Regression-based tests for overdispersion in the Poisson model. *Journal of Econometrics*, 46(3), 347-364. DOI: 10.1016/0304-4076(90)90014-K
- Cleveland, R. B., Cleveland, W. S., McRae, J. E. *et al.* (1990). STL: A seasonal-trend decomposition procedure based on Loess. *Journal of Official Statistics*, 6(1): 3-73. <https://www.nniiem.ru/file/news/2016/stl-statistical-model.pdf>
- Cohen, F., y Dechezleprêtre, A. (2022). Mortality, temperature, and public health provision: Evidence from Mexico. *American Economic Journal: Economic Policy*, 14(2), 161-192. DOI: 10.1257/pol.20180594
- Colchero, M. A., Gómez, R. y Bautista-Arredondo, S. (2022). A systematic review of the literature on the impact of the Seguro Popular. *Health Research Policy and Systems*, 20(1), 42. DOI: 10.1186/s12961-022-00839-w
- Conti, G., y Ginja, R. (2020). Who benefits from free health insurance? *Journal of Human Resources*, 58(1), 146-82. DOI: 10.3368/jhr.58.3.1117-9157r2
- Costa-Font, J., Györi, M. y Sáenz de Miera, B. (2020). Do health insurance extensions affect nutritional choices and outcomes? – a case study of Mexico's Seguro Popular. En: M. Györi. *Public policy and social determinants of nutrition behaviour and outcomes – quasi-experimental evidence from low-and middle-income countries*, (pp. 83-124). Tesis. Doctor of Philosophy, London School of Economics and Political Science, Department of Health Policy. https://etheses.lse.ac.uk/4267/1/Györi__Public-policy-social-determinants.pdf#page=83
- Courtemanche, C. J. y Zapata. D. (2013). Does universal coverage improve health? The Massachusetts experience. *Journal of Policy Analysis and Management*, 33(1), 36-69. DOI: 10.1002/pam.21737

- Gakidou, E., Lozano, R., González-Pier, E. *et al.* (2006). Assessing the effect of the 2001-06 Mexican health reform: An interim report card. *The Lancet*, 368(9550), 1920-1935. <https://www.thelancet.com/journals/lancet/article/PIIS0140673606695688/abstract>
- Galárraga, O., Sosa-Rubí, S. G., Salinas, A. *et al.* (2008). The impact of universal health insurance on catastrophic and out-of-pocket health expenditures in Mexico: A model with an endogenous treatment variable. *Health Econometrics and Data Group Working Paper*, 8: 12. https://www.researchgate.net/profile/Sandra-Sosa-Rubi/publication/23753760_The_Impact_of_Universal_Health_Insurance_on_Catastrophic_and_Out-of-Pocket_Health_Expenditures_in_Mexico_a_Model_with_an_Endogenous_Treatment_Variable/links/55bfa46308ae9289a09b5df0/The-Impact-of-Universal-Health-Insurance-on-Catastrophic-and-Out-of-Pocket-Health-Expenditures-in-Mexico-a-Model-with-an-Endogenous-Treatment-Variable.pdf
- García-Díaz, R., Sosa-Rubí, S. G. Serván-Mori, E. *et al.* (2018). Welfare effects of health insurance in Mexico: The case of Seguro Popular de salud. *PLOS One*, 13(7), e0199876. DOI: 10.1371/journal.pone.0199876
- Hernández-Garduño, E., y Jiménez-Cortez, A. Y. (2017). The impact of popular health insurance “Seguro Popular” on diabetes mortality in Mexico, 1999-2014. *Salud Pública de México*, 59(4), 494-496. DOI: 10.21149/8466
- Huffman, C., y Van Gameren, E. (2019). Efectos heterogéneos y distributivos del Seguro Popular sobre la oferta de servicios de salud en México. *El Trimestre Económico*, 86(343), 667-713. DOI: 10.20430/ete.v86i343.719
- King, G., Gakidou, E., Imai, K. *et al.* (2009). Public policy for the poor? A randomised assessment of the Mexican universal health insurance programme. *The Lancet*, 373(9673), 1447-1454. DOI: 10.1016/s0140-6736(09)60239-7

- Knaul, F. M., Arreola-Ornelas, H., Touchton, M. *et al.* (2023). Setbacks in the quest for universal health coverage in Mexico: Polarised politics, policy upheaval, and pandemic disruption. *The Lancet*, 402(10403), 731-746. DOI: 10.1016/s0140-6736(23)00777-8
- Kwiatkowski, D., Phillips, P. C. B., Schmidt, P. *et al.* (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? *Journal of econometrics*, 54(1-3), 159-178. DOI: 10.1016/0304-4076(92)90104-Y
- Muñoz-Aguirre, P., Huerta-Gutiérrez, R., Zamora, S. *et al.* (2021). Acute lymphoblastic leukaemia survival in children covered by Seguro Popular in Mexico: A national comprehensive analysis 2005-2017. *Health Systems & Reform*, 7(1), e1914897. DOI: 10.1080/23288604.2021.1914897
- Pfütze, T. (2014). The effects of Mexico's Seguro Popular health insurance on infant mortality: An estimation with selection on the outcome variable. *World Development*, 59, 475-486. DOI: 10.1016/j.worlddev.2014.02.008
- Porto, A. (2023). *Effects of public health insurance on household's nutritional choices*. Tesis. Maestría en Economía, Universidad de Guadalajara, Centro Universitario de Ciencias Económico-Administrativas.
- Reich, M. R. (2020). Restructuring health reform, Mexican style. *Health Systems & Reform*, 6(1), e1763114. DOI: 10.1080/23288604.2020.1763114
- Rhubart, D. C. (2018). Disparities in individual health behaviors between medicaid expanding and non-expanding states in the U.S. *SSM-Population Health*, 6, 36-43. DOI: 10.1016/j.ssmph.2018.08.005
- Sosa-Rubí, S. G., Galárraga, O., y Harris, J. E. (2009). Heterogeneous impact of the 'Seguro Popular' program on the utilization of obstetrical services in Mexico, 2001-2006: A multi-

nomial probit model with a discrete endogenous variable. *Journal of Health Economics*, 28(1), 20-34. DOI: 10.1016/j.jhealeco.2008.08.002

Sosa-Rubí, S. G, Salinas-Rodríguez, A., y Galárraga, O. (2011). Impacto del Seguro Popular en el gasto catastrófico y de bolsillo en el México rural y urbano, 2005-2008. *Salud Pública de México*, 53(supl. 4), S425-S435. https://www.scielosp.org/article/ssm/content/raw/?resource_ssm_path=/media/assets/spm/v53s4/a06v53s4.pdf

Exploring setbacks of municipal life expectancies after COVID-19 in Mexico

*Eliud Silva**

*Guillermo Beick Tapia***

Abstract

Life expectancy was significantly reduced as a consequence of the global COVID-19 pandemic. Likewise, acknowledging setbacks in life expectancy as nothing more than merely declines in life expectancy over time, many countries have experienced substantial setbacks in this metric at national, regional, or local levels. According to several estimates, Mexico has outstanding inequalities in life expectancy loss at a state level. So, we aim to explore the magnitude of the setbacks in life expectancies at the municipal level, considering the period from 1990 to 2020. We use estimates of municipal life expectancies, calculated using several

* Actuarial Science School, Universidad Anáhuac México y Universidad Nacional Autónoma de México, Facultad de Estudios Superiores Acatlán.

** Actuarial Science School, Universidad Anáhuac México.

sociodemographic variables taken from the demographic census and count data and linear regression models. Afterward, this study identifies the life expectancy loss, by computing lost years at the municipal level, considering the marginalization level. Finally, some statistical tests are carried out to analyze the phenomenon of life expectancy loss. The results suggest that the setbacks in life expectancy have a high skewness and a strong impact in almost all Mexican municipalities.

Keywords: *Life expectancy, COVID-19, Mexico, Nonparametric tests, Linear regression model*

1. Introduction

To summarize mortality levels and enable comparisons across time and space, life expectancy (at birth) (e_0) is a suitable index (Yusuf, Martins and Swanson, 2014). This index has been used to measure populations' quality of life and health (Crimmins and Zhang, 2019). In general, life expectancy loss can result from the aftermath of a pandemic, such as COVID-19. In Mexico, evidence indicates that this pandemic significantly impacted life expectancy at both national and subnational levels, causing substantial setbacks (Garcia and Beltran, 2021; Lima *et al.*, 2021; Espinosa *et al.*, 2023). There are no official figures on this index or its setbacks at the municipal level in Mexico.

We posit that obtaining municipal life expectancies and their eventual losses poses a significant challenge for demographic and health systems worldwide. One factor is geography; for instance, Mexico's political structure, both at state and municipal levels. Another factor is the quality and standardization of information. In developing countries like Mexico, widespread inequalities in technical infrastructure and training appear to affect the accuracy of death records, more so during a pandemic (Hernández *et al.*, 2022).

We aim to estimate setbacks in life expectancies at the municipal level in Mexico. To address this, we use the marginalization index created by the Mexican Population Council (CONAPO, by its acronym in Spanish). Additionally, we analyze some statistical properties of life expectancy losses using nonparametric tests. For this purpose, we consider the preliminary estimates of Silva *et al.* (2023). It is worth noting that these estimates include some outliers, which are discarded as they lack demographic plausibility. That is why an imputation process is then carried out, where life expectancy at the state level is used to replace the outliers.

The paper is organized as follows. The next section reviews studies on setbacks across various frameworks at both national and subnational levels. Following this, methodology is detailed, including the employed estimates made by Silva *et al.* (2023), the imputation process applied, as well as data processing steps, and the nonparametric tests used. The subsequent section highlights the main results, emphasizing statistical findings for 2020 at the municipal level. Finally, the main conclusions are presented.

2. Background

Under demographic literature, a setback in life expectancy implies a reversal of previous trends in life expectancy, indicating a decline in the population's longevity. This can be observed in statistical data showing a reduction in life expectancy over a specified period. It reflects an adverse change in the overall health status and longevity of population. So, the concept of setback underscores a troubling change from expected improvements in health outcomes and longevity. For instance, Aburto *et al.* (2021) use the term *setback* to describe that the black population experienced decreases in life expectancy due to HIV in some states from the US between 1980 and 2020. A setback

does not imply that life expectancy cannot recover in the future, nor does it necessarily serve as a forecast in itself. It is estimated based solely on observed data across time.

It is essential to highlight the three main differences between setbacks in life expectancy and excess mortality. First, regarding scope and duration, setbacks are long-term indicators that reflect overall changes in mortality patterns, while excess mortality measures short-term death rates over specific periods. Second, in terms of utility, setbacks offer a broader view of population health trends, whereas excess mortality provides a snapshot of the impact of specific events. Third, concerning calculation, setbacks require mortality rates across various age groups and years, whereas excess mortality is typically calculated by comparing: a) current and expected deaths, and b) current and expected life expectancies, both for the same period.

Until now, few research papers have focused on studying the setbacks at the municipal level, or any equivalent level, around the globe. In the following paragraphs, we addressed the most significant papers that make some findings on setbacks about countries, regions, or counties. However, deeper analyses are discussed for developed countries' cases. Meanwhile, developing countries only found estimates at the national level. In brief, the deeper the analysis, the scarcer the findings.

Dukhovnov and Barbieri (2021) examined COVID-19 mortality rates, the number of years lost, and the reduction in life expectancy across 3,144 US counties. These counties were categorized into five socioeconomic groups. They used daily death data and weekly mortality age structure information. A data analysis from March to May 2020 revealed that COVID-19 mortality rates were highest in the most socioeconomically advantaged quintile of counties and lowest in the two most disadvantaged quintiles. This trend, however, reversed from June to August, and the gap widened by September to December. By

the end of the year, COVID-19 mortality rates were 2.58 times higher in the bottom quintile compared to the top quintile. The divergent trajectories of COVID-19 mortality observed between poor and affluent counties suggest a progressively higher rate of life loss in socioeconomically disadvantaged communities.

The COVID-19 pandemic led to significant declines in life expectancy across several Latin American countries, as studied by Lima *et al.* (2021). Their study assessed mortality data from Brazil, Ecuador, Peru, Chile, Guatemala, and Mexico, revealing reductions that varied by country—from 2.4 years in Brazil to 10.9 years in Peru, with Mexico experiencing a decline of 5.54 years. Beyond quantifying these losses, the researchers also identified the historical benchmarks to which life expectancy regressed after adjusting for the excess mortality of 2020. The setbacks were most pronounced in Ecuador, Peru, and Mexico, where life expectancy fell to levels last seen in 1990, 1989, and 1987, respectively. Comparing these findings to the 1918 influenza pandemic in the United States—when life expectancy plummeted by 7 to 12 years—the study highlighted the severe demographic consequences of COVID-19.

Andersen *et al.* (2021) analyzed the setbacks experienced during the first year of the COVID-19 pandemic across 124 countries. Their study highlighted significant setbacks in both life expectancy and quality of life. The reduction in daily mobility, serving as a *proxy* for quality of life, resulted in the loss of an estimated 1.2 billion quality life years, surpassing the life years lost due to COVID-19 deaths by a staggering 25 times. Moreover, the study elucidated considerable disparities in national responses to the pandemic. While some countries implemented effective strategies such as testing and contact tracing, others resorted to stringent lockdowns with limited success. Additionally, interruptions to routine public health interventions, such as immunizations, posed significant setbacks in disease prevention

efforts, potentially leading to long-term consequences beyond the immediate impacts of COVID-19.

To analyze county-level life expectancy trends from 2011 to 2016 and their impact on COVID-19 mortality, Chandran *et al.* (2022) employed a three-step analytical approach. Their findings indicated that counties with the lowest life expectancy in 2010 followed divergent paths—26% saw an increase, while 48% experienced a decline. In contrast, among counties with the highest baseline life expectancy, 18% showed improvement, whereas 26% faced reductions. These shifts were largely shaped by modifiable health factors, including adult smoking, obesity, unemployment, and child poverty. Across all counties, 42% maintained stable life expectancy, 21% saw gains, and 37% recorded declines. Notably, those with rising life expectancy from 2011 to 2016 later exhibited a 5% reduction in COVID-19 mortality during the 2020–2021 period, underscoring the link between long-term health trends and pandemic outcomes. However, no significant correlation emerged between declining life expectancy and COVID-19 mortality.

Heuveline's (2022) research explores global and national life expectancy changes from 2019 to 2021, using excess deaths as a critical metric rather than relying solely on reported COVID-19 deaths. The World Mortality Dataset (WMD) is the primary data source for over 100 countries, employing a gradient-boosting algorithm to estimate excess deaths in regions with limited or unreliable mortality data. Various methodologies are applied based on data quality, using WMD estimates for reliable countries and employing preliminary estimates adjusted through comparisons. The recalculated life expectancies reveal a significant global decline of -0.92 years in 2020, followed by another decrease of 0.72 years in 2021, marking the first global setback since 1950. The study emphasizes the pandemic's unprecedented impact on worldwide life expectancy. Several nations

experienced substantial declines, with Peru, Guatemala, Paraguay, the Russian Federation, and Bulgaria among the most affected.

The impact of the COVID-19 pandemic on life expectancy in Spain was assessed by Trias *et al.* (2022) using data from the Spanish Daily Mortality Monitoring System (MoMo). Their study examined 17 regions through a multi-step methodology, which involved categorizing data by region, age, and gender, estimating life expectancy for 2019 and 2020, and assessing its relationship with COVID-19 seroprevalence. A sharp decline in weekly life expectancy was observed during the thirteenth and fourteenth weeks of 2020, with nationwide reductions ranging from 6.1 to 7.6 years. Madrid experienced the most severe losses, with decreases between 11.2 and 14.8 years. When comparing annual life expectancy between 2019 and 2020, the study found an overall reduction of 0.9 years, with Madrid again facing the steepest drop. Regional disparities were evident, as some areas recorded losses of up to 10–15 years in weekly life expectancy and over two years annually, while others were less affected. These declines showed a strong correlation with SARS-CoV-2 antibody prevalence.

Rabin (2022) highlighted the unprecedented setbacks in American life expectancy during the COVID-19 pandemic, marking the steepest two-year drop in nearly a century. By 2021, the average life expectancy fell to 76 years, down from nearly 79 years in 2019, with Native American and Alaska Native communities experiencing the most severe setbacks. Their life expectancy plummeted by over six and a half years, reaching an average of 65 years, levels comparable to the general U.S. population in 1944. The pandemic, compounded by rising accidental deaths, drug overdoses, and chronic diseases, drove these setbacks. While white Americans saw the most significant decline in 2021, Black and Hispanic populations had

already faced major setbacks in 2020. Experts attribute the continued setbacks in U.S. life expectancy to systemic issues such as a fragmented healthcare system, poor diet, and pervasive social determinants like poverty and racism. These challenges, coupled with lower vaccination rates and resistance to preventive measures among certain groups, have left the U.S. as an outlier among high-income nations in pandemic recovery, resulting in historic setbacks in longevity.

Sun *et al.* (2023) accomplished an analysis of COVID-19 excess deaths, spanning January 1, 2020, to November 1, 2021. Employing a modeling framework with intrinsic and actionable features, the study considered factors like vaccination rates, government policies, and demographics. Inherent features encompassed parameters like obesity percentage, age distribution, GDP per capita, population density, and hospital beds per 1000 people, while actionable features included policy-related variables. Data from multiple sources, including WHO and World Bank Open Data, were used for 80 countries, with missing values imputed and log transformations applied. Regression models, including LASSO, Random Forest, and Gradient Boosting, were employed with hyperparameter tuning. The study identified COVID-19 vaccination rates and trust in government guidance as pivotal factors in predicting and mitigating excess deaths. Intrinsic factors like age distribution and comorbidity risks were noted for explaining cross-country variations in excess death.

Setbacks in life expectancy and health-adjusted life expectancy in Mexico between 1990 and 2019 were the focus of Agudelo *et al.* (2023), who examined these trends by gender, age group, and state. While both indicators showed overall growth during this period, recent years have seen a slowdown, with some regions even experiencing declines. Using data from the Global Burden of Disease, Injuries, and Risk Factors

Study, the analysis revealed significant gains across most states between 1990 and 2010. However, progress stalled from 2010 to 2019, and certain states faced notable setbacks. In 10 states, for instance, life expectancy among men declined during this latter period. The study identified violence, chronic kidney disease, and ischemic heart disease as primary contributors to these reversals, particularly affecting men aged 15 to 49. The rising trend of violence since 2005 has been a key factor, with public policies failing to curb its impact. While women generally outlive men, they spend more years in poor health—a disparity reflected in health-adjusted life expectancy, which declined for men in 16 states between 2010 and 2019.

Huang *et al.* (2023) examined the profound setbacks in life expectancy caused by the COVID-19 pandemic. The pandemic led to significant setbacks in life expectancy, reversing the upward trends since the end of World War II. The study highlights that traditional methods of assessing mortality changes by comparing life expectancy from 2019 to 2020 might underestimate the full impact of COVID-19 because these methods don't account for the expected year-on-year increases in life expectancy. The findings indicate that COVID-19 caused substantial setbacks in life expectancy in many countries, particularly in Europe and the Americas, with the impact varying by gender and race. Men and racial minority groups experienced higher declines. The study concludes that the setbacks in life expectancy due to COVID-19 emphasize the importance of enhanced surveillance and vigilance for infectious diseases to prevent and manage future pandemics, ensuring that the setbacks experienced during COVID-19 do not recur on such a scale.

As expressed by Goldstein *et al.* (2024), the COVID-19 pandemic caused significant setbacks in life expectancy, comparable to other historical mortality shocks. Their study emphasized that such declines are typically driven by large-scale global or

regional events rather than unique national factors. Past mortality shocks, including severe seasonal influenza and climate change-induced weather extremes, have led to similar declines, with COVID-19 emerging as a particularly disruptive force. In the United States, the pandemic triggered an unprecedented drop in average life expectancy. While standard forecasting models –such as the Lee-Carter model– suggest that these setbacks lead to long-term declines. The authors argue that real-world populations often recover more quickly than predicted. They also examined the differential impact across age groups, noting that pandemics disproportionately affect the elderly, in contrast to the usual trend where younger age groups experience faster mortality improvements. Despite the severity of COVID-19's effects, the study suggests that these setbacks are likely temporary, with life expectancy expected to return to its previous trajectory over time.

3. Material and Methods

Silva *et al.* (2023) estimated municipal life expectancies in Mexico from 1990 to 2020. They employed linear regression models to generate these estimates. The first step was to model life expectancies at the state-level, denoted as $e_{x,t,s}$, for $t = 1990, 1995, \dots, 2020$ sourced from CONAPO (2018) and the most recent data from García and Beltran (2021), employing the statistical model

$$e_{x,t,s} = \beta_{0,t} + \beta_{1,t}x_{1,t} + \beta_{2,t}x_{2,t} + \beta_{3,t}x_{3,t} + \dots + \beta_{k,t}x_{k,t} + u_t \quad (1)$$

where $\beta_{0,t}, \beta_{1,t}, \beta_{2,t}, \beta_{3,t}, \dots, \beta_{k,t}$ were coefficients to estimate; $x_{1,t}, x_{2,t}, x_{3,t}, \dots, x_{k,t}$ are available variables at the state-level; and u_t represents a random error. The subscript x, t, s denotes the age attained ($x = 0$, that is life expectancy at birth), the

time (1990, 1995,..., 2020), and the state-level formulation of the model, respectively. Thus, $e_{x,t,s}$ represents the official life expectancy at the state-level in a given year t . Notably, each state in Mexico has a corresponding life expectancy estimate for each specified year.

Subsequently, the stepwise algorithm was implemented to derive optimal models, considering $\alpha=15\%$. For each model, statistics R^2 , adjusted R^2 , and FIV to assess non-multicollinearity were computed. Additionally, binary variables were also added to estimate the outlier's effects. The final models adhered to standard assumptions regarding their residuals (normality, absence of autocorrelation, and homoscedasticity). Afterward, life expectancy estimates at the municipal level, denoted as $\widehat{e}_{x,t,m}$ were estimated by

$$\widehat{e}_{x,t,m} = \widehat{\beta}_{0,t} + \widehat{\beta}_{1,t}x_{1,t,m} + \widehat{\beta}_{2,t}x_{2,t,m} + \widehat{\beta}_{3,t}x_{3,t,m} + \dots + \widehat{\beta}_{k,t}x_{k,t,m} \quad (2)$$

where $\widehat{\beta}_{0,t}, \widehat{\beta}_{1,t}, \widehat{\beta}_{2,t}, \widehat{\beta}_{3,t}, \dots, \widehat{\beta}_{k,t}$ represent the estimated coefficients obtained from Equation (1). The variables $x_{1,t,m}, x_{2,t,m}, x_{3,t,m}, \dots, x_{k,t,m}$, correspond to the same independent variables as in equation (1), but at the municipal level. The parameter m denotes the number of municipalities. Then, to validate the alignment between official life expectancies $e_{x,t,s}$ and our state-level estimates for each year, we reconstructed life expectancies using the following expression

$$\bar{e}_{x,t,j} = \alpha_1 \widehat{e}_{x,t,1} + \alpha_2 \widehat{e}_{x,t,2} + \dots + \alpha_m \widehat{e}_{x,t,m} = \sum_{i=1}^m \alpha_i \widehat{e}_{x,t,i} \quad (3)$$

for $j = 1, 2, \dots, 32$ representing the state identifier, and

$$\alpha_m = \frac{\text{total population in the } m\text{th municipality from the state } j \text{ in the year } t}{\text{total population in the state } j \text{ in the year } t}$$

For estimating the models, Silva *et al.* (2023) used data from CONAPO (2018), such as: ANALF (percentage of illiterate people), SPRIM (percentage of the population without primary school education), OVSDE (percentage of the population without proper sanitary facilities), OVSEE (percentage of the population without electricity), OVSAE (percentage of the population without access to municipal water), VHAC (percentage of overcrowded homes), OVPT (percentage of households with dirt floors), PL5000 (percentage of the population in rural areas), and PO2SM (percentage of the population with low wages). The last variable, CONF/POB (confirmed COVID-19 cases per total population), was estimated using data from Mexico's Ministry of Health (<http://www.dgis.salud.gob.mx/contenidos/sinais/subsistema1.html>) and the National Institute of Geography and Statistics [INEGI] (<https://www.inegi.org.mx/>).

Table 1 presents the estimated models at the state-level and key statistics such as R^2 , Adjusted R^2 , and the Mallows statistics (MS) for all years made by Silva *et al.* (2023). In those models, dummy variables were introduced to account for the effect of certain outliers at the state level. Subsequently, we took the estimated life expectancies at the municipal level and calculated the respective setbacks, along with other relevant statistics.

Table 1
Linear models to estimate life expectancies at the state-level

Year	Model	Statistics
1990	$\widehat{e}_{x,1990,s} = 71.397 - 0.01760 \text{ OVPT} + 2.481 \text{ I}_{Qr} - 1.233 \text{ I}_{Oax} + 1.09881 \text{ Mx} - 1.266 \text{ I}_{Ver}$	R^2 : 62.99; Adjusted R^2 : 55.87; and MS = 6.
1995	$\widehat{e}_{x,1995,s} = 72.703 - 0.02880 \text{ OVSAE} + 1.237 \text{ I}_{Qr} + 0.833 \text{ I}_{Ags} - 0.906 \text{ I}_{Oax}$	R^2 : 71.30; Adjusted R^2 : 67.05; and MS = 5.
2000	$\widehat{e}_{x,2000,s} = 76.704 - 0.0842 \text{ OVSEE} - 0.02882 \text{ P02SM}$	R^2 : 82.01; Adjusted R^2 : 80.77; and MS = 3.
2005	$\widehat{e}_{x,2005,s} = 76.519 - 0.0246 \text{ SPRIM} - 0.0822 \text{ OVSEE} - 0.00959 \text{ P02SM}$	R^2 : 83.09; Adjusted R^2 : 81.28; and MS = 4.
2010	$\widehat{e}_{x,2010,s} = 73.874 - 0.03 \text{ SPRIM} - 0.0343 \text{ OVPT} - 0.00967 \text{ P02SM}$	R^2 : 80.44; Adjusted R^2 : 77.49; and MS = 4.
2015	$\widehat{e}_{x,2015,s} = 76.645 - 0.0584 \text{ SPRIM} - 0.1171 \text{ OVSEE} - 0.0332 \text{ VHAC}$	R^2 : 85.56; Adjusted R^2 : 84.02; and MS = 4.
2020	$\widehat{e}_{x,2020,s} = 73.569 + 0.1054 \text{ OVPT} - 0.0691 \text{ VHAC} - 18.8 \frac{\text{CONF}}{\text{POB}} - 1.288 \text{ I}_{BC} - 1.458 \text{ I}_{Gro} \propto + 1.077 \text{ I}_{Chis} + 0.774 \text{ I}_{Mor}$	R^2 : 65.10; Adjusted R^2 : 54.92; and MS = 8.

Source: Silva *et al.* (2023).

The equations in Table 1 represent the estimated linear models derived from Equation (1), where official state-level life expectancies $e_{x,t,s}$, were used as the dependent variables and sociodemographic data as independent variables (CONAPO,

2018 and 2020). The results indicate that both the t-tests and the F-test were statistically significant. Notably, the most parsimonious model corresponds to 2000, while the least parsimonious model is observed in 2020.

The estimated models highlight that life expectancy in Mexico is influenced by household-level conditions across all years under study. For instance, in 1990, the coefficient for OVPT (percentage of homes with dirt floors) negatively impacted life expectancy, holding other factors constant. In 1995, the model revealed that the coefficient for OVSAE (percentage of the population without access to piped water) has a negative effect on life expectancy. This suggests that higher values of OVSAE correlate with reduced life expectancy. In 2000, the variables OVSEE (percentage of the population without access to electricity), and PO2SM (percentage of the population earning low wages) both had an adverse impact on life expectancy.

By 2005, the variables SPRIM (percentage of the population without primary education), OVSEE, and PO2SM continued to negatively affect life expectancy. While the coefficient for SPRIM is relatively small, the impact of OVSEE remains substantial. In 2015, the negative effects of SPRIM, OVSEE, and VHAC (percentage of dwellings with overcrowding) persist. Each of these variables continues to reduce life expectancy, with OVSEE exhibiting the strongest effect. Finally, in 2020, following the COVID-19 pandemic, life expectancy was again influenced by socioeconomic variables, along with the inclusion of the CONF/POB variable, which also significantly affects life expectancy.

Due to the numerous municipalities in Mexico, the second step was to classify them into five groups based on the marginalization index elaborated by CONAPO (2020). Consequently, every municipality has been assigned a marginalization index per year. Silva *et al.* (2023) acknowledge that the models for certain municipalities might provide unreliable life expectancies in

some cases. For instance, some cases show unexpected increases in life expectancy where it is usually low, or notable increases amid the COVID-19 pandemic. Consequently, a decision was made to adjust these figures using the respective states' life expectancy data. So, an imputation process was carried out, considering all years and the mentioned groups.

For grouping the states by their marginalization index, we consider the criterion from CONAPO (2020). So, the classification was as follows. Very Low: Aguascalientes, Coahuila, Mexico City, and Nuevo León; Low: Baja California, Baja California Sur, Colima, Jalisco, State of Mexico, Querétaro, Sonora, and Tamaulipas; Medium: Chihuahua, Guanajuato, Morelos, Quintana Roo, San Luis Potosí, Sinaloa, Tlaxcala, and Zacatecas; High: Campeche, Durango, Hidalgo, Michoacán, Nayarit, Puebla, Tabasco, Veracruz, and Yucatán and, finally Very high: Chiapas, Guerrero, and Oaxaca.

The third step was complementing setbacks with the total years lost per municipality. To estimate them, municipalities were grouped according to marginalization levels. Subsequently, years lost for each municipality were multiplied by its respective population from 2020, as reported by CONAPO. Later, the amounts obtained were added to get the total by marginalization index. Finally, setbacks were estimated for municipalities. It is worth noting that some inferences regarding the sampling distribution of the estimates were made.

Likewise, statistical analyses were undertaken to assess the goodness of fit for various distributions, including Normal, Lognormal, Weibull, Exponential, and Logistic. The Anderson-Darling test was implemented because it is known for its sensitivity to heavy tails of distributions, the situation that appears here. These tests provide valuable insights into the conformity of the data to specific distributional assumptions, offering a comprehensive evaluation of the underlying statistical

properties and aiding in the interpretation of estimates derived from the sampled data.

4. Results

Imputation process

As previously mentioned, some studies highlight the decline in life expectancy across broad geographical areas due to COVID-19, regardless of the structural deficiencies affecting their inhabitants at the municipal level. In Mexico, according to the cited estimation models, certain municipalities experienced significant deviations in life expectancy compared to previous years. To address this, an imputation was performed by replacing these values with the corresponding state-level estimates calculated by García and Beltrán (2021). Thus, the number of imputations refers to the number of municipalities where the estimated state-level life expectancy was assigned. In 2020, 130 cases in 2,469 municipalities (5.26%) represented the most significant imputations. Table 2 presents the total cases. When it was necessary to estimate life expectancy for municipalities and no demographic estimates were available—either due to data quality issues or absence of information—it became essential to impute their respective life expectancy values.

Oaxaca, one of the poorest states in Mexico, had the highest number of imputations, with 236 adjustments to life expectancy from 1990 to 2020. This was followed by Chiapas with 30, Michoacán with 10, and Jalisco with 8 imputations. Furthermore, these first two states stand out since the imputations were made in areas with very high and high marginalization indexes. In 2020, municipalities in Chiapas, such as Las Rosas, Tila, and Yajalón, had substantially lower life expectancies than the state average. This suggests a poor quality of information in the country for areas with such marginalization levels.

One extreme case is found in the Oaxacan municipality of San Pedro Mártir, which, according to the data, had the highest life expectancy in the country (77.5 years) in 2020, while the state average was 72.8 years. It should be noted that this is a state with very high marginalization, facing the same issue as mentioned previously. Another notable case is the municipality of Santa Isabel in Chihuahua, where a life expectancy of 65 years was reported for 2020 (the lowest in the country), six years less than the state average. It should be noted that Santa Isabel is a municipality with very low marginalization, according to CONAPO.

Table 2
Unreliable life expectancies and imputations,
1990 to 2020

Year	Marginalization level					Total
	Very Low	Low	Medium	High	Very High	
1990	0	0	1	7	14	22
1995	0	0	3	15	15	33
2000	0	0	3	24	14	41
2005	0	0	3	47	35	85
2010	0	0	1	6	19	26
2015	0	0	2	13	2	17
2020	0	0	2	55	73	130
Total	0	0	15	167	172	354

Source: own elaboration.

It is worth noting that in 2015, the state of Chihuahua had a similar situation in its municipality of Batopilas de Manuel Gómez Morín, which has a very high marginalization index. Another notable imputation was used in 2000, when the Oaxacan municipality of Santiago Amoltepec had the lowest life

expectancy in the country at 65.7 years, compared to the state average of 70.8 years. Finally, in Jiménez, Michoacán, the life expectancy reported in 2020 was 65 years, eight years less than the state average. This municipality has a very low marginalization level, highlighting issues with inadequate data collection.

Lost years estimates

Based on the literature, a negative correlation has been identified between precarious sociodemographic conditions and high life expectancy. In Latin America, economic marginalization has been shown to affect longevity adversely (Temporelli and Viego, 2011). In Mexico, municipal-level evidence indicates that greater sociodemographic marginalization is associated with lower life expectancy (Paredes and Silva, 2017). More recently, research has shown that among the Mexican youth population, municipalities with higher levels of marginalization experience increased mortality rates within this age group (González and Vega, 2021).

Following the imputation process, the total years lost were calculated, revealing a notable disparity in the results (see Table 3). Surprisingly, municipalities with very low levels of marginalization had the highest losses, totaling 246.1 million years, followed by those with low levels of marginalization, accounting for 30.4 million years lost. This pattern presents a paradox, suggesting a direct correlation between marginalization indicators and the extent of life years lost.

This paradox aligns with broader global trends observed during the COVID-19 pandemic. Quiroga (2021) highlights that some wealthier countries experienced higher mortality rates, largely due to widespread obesity and older populations (both significant risk factors for severe illness). Similarly, Adams *et al.* (2021) and Lawai (2021) analyze lower mortality rates in Africa, attributing them to demographic factors, prior pandemic experience, and public

health responses. A comparable trend can be observed in Mexico, where many impoverished municipalities share characteristics such as a youthful demographic structure and lower obesity rates, though often counterbalanced by malnutrition. These findings suggest that socioeconomic and demographic factors play a crucial role in pandemic-related mortality, warranting further investigation to fully understand the underlying mechanisms.

Likewise, given these results, we propose two potential and complementary hypotheses: a) municipalities with high or very high levels of marginalization over time have seen fewer improvements, hence experiencing fewer losses, and b) the possibility of better data quality at low levels compared to high levels, where similar data quality is not reported. As mentioned, current literature generally supports the notion that lower levels of marginalization are associated with higher life expectancy. It is important to note, however, that in many countries, a direct measure of marginalization may not be available. Instead, proxies, such as the Human Development Index (HDI), are commonly used to approximate this concept.

Table 3: Total years lost in municipalities by marginalization, 2020

Total years (million)	Marginalization level				
	Very Low	Low	Medium	High	Very High
	246.1	30.4	13.7	5.3	3.6
Number of Municipalities	655	530	494	586	204
Total Population	89,581,911	15,658,790	9,370,743	7,894,980	3,517,600
Mean life years lost per person	2.7	1.9	1.5	0.7	1.0

Source: own elaboration.

Table 3 reveals that municipalities with very low marginalization levels experience the highest mean years lost per person (2.7 years), while those with high and very high marginalization levels show significantly lower losses (0.7 and 1.0 years, respectively). Notably, Mexico City recorded the highest average loss of life at 3.5 years per person, followed by the State of Mexico (2.8 years) and Nuevo León (2.7 years), highlighting a major challenge for these historically economic and demographic hubs in terms of human capital loss and reduced productive years. In contrast, Oaxaca and Chiapas reported the lowest losses, at just 0.67 and 0.68 years per person, respectively, a disparity that may be linked to factors such as health conditions, socioeconomic differences, and population characteristics.

The analysis further reveals that municipalities with medium marginalization levels experienced an average loss of 1.5 years per person (13.7 million years), while those with very high marginalization levels saw a significantly lower loss of only 1 year per person (3.6 million years). Among individual municipalities, Tijuana, one of Baja California's most important cities, reported the highest loss at 4.1 years per person (7.8 million years), reflecting serious concerns about regional health and quality of life. It was followed by Iztapalapa, Mexico City, with 3.2 years per person (6.1 million years), highlighting substantial challenges in healthcare access and socioeconomic conditions. Ecatepec, State of Mexico, also ranked among the hardest-hit municipalities, with a loss of 3 years per person (5 million years), emphasizing the urgent need for targeted health interventions in one of the country's most densely populated areas. Finally, the municipality of Puebla in Puebla state reported a loss of 2.8 years per person (4.7 million years), underlining similar concerns regarding well-being and development.

The implications of these findings are profound, directly affecting both the nation's workforce and economic productivity.

A decline in life expectancy and overall health reduces the available labor force, weakening productivity and efficiency, which in turn threatens economic output and GDP growth. Additionally, worsening health conditions and lower life expectancy place a heavier financial burden on healthcare and social security systems. Increased healthcare costs divert resources from critical development initiatives, potentially hindering long-term economic progress and limiting improvements in the population's standard of living.

One key factor contributing to these losses is the high population density and increased connectivity in low-marginalization municipalities, which facilitated the rapid spread of infectious diseases. While these areas typically have stronger healthcare systems, the scale of the pandemic overwhelmed even the best-equipped hospitals. High urban mobility and frequent travel accelerated viral transmission, leading to increased infection rates and, consequently, a greater number of COVID-19-related deaths, significantly reducing life expectancy.

Moreover, these municipalities tend to have a larger proportion of older residents, particularly in affluent urban areas where retirees are more likely to settle. Given that older adults are at significantly higher risk of severe illness and death from COVID-19, their concentration in certain municipalities made these regions particularly vulnerable. Despite having better healthcare resources, the high number of elderly residents meant that the pandemic had a disproportionately negative impact on life expectancy in these areas.

5. Setbacks

According to Lima *et al.* (2021), after the COVID-19 pandemic, Mexico's life expectancy rate regressed to levels like those in 1987. In our analysis, we estimated the corresponding indices

for municipalities based on their marginalization levels. Using the same grouping criteria (see Table 4), we found that municipalities with a very low marginalization index experienced an average setback of 22.95 years, whereas those classified as having very high marginalization had an average setback of 8.55 years. Additionally, municipalities with a very low degree of marginalization exhibited lower dispersion (3.57), while those with a very high degree of marginalization showed greater variability (7.69).

The setbacks were calculated using a regression analysis of the life expectancy data for all municipalities classified under the same marginalization index. Specifically, we computed the sum of the regression years for each municipality within the respective marginalization index and then normalized it by the population size within that index. The concept of a “setback” refers to the phenomenon where the current life expectancy in these municipalities mirrors the life expectancy levels that were observed approximately 25 years ago, implying a stagnation or regression in health improvements over time.

Table 4
*Statistics Setbacks of municipal life expectancies
per person by marginalization*

Marginali- zation level	Mean	Standard deviation	Asymmetry	Kurtosis
Very Low	22.95	3.57	0.14	2.07
Low	22.24	3.95	-0.70	3.87
Medium	20.47	5.70	-0.99	1.75
High	15.73	8.11	-0.20	-0.86
Very High	8.55	7.69	0.75	-0.31

Source: Own elaboration.

The asymmetry remains close to zero in all cases, indicating a relatively balanced distribution across groups, while the positive kurtosis in most cases suggests heavier tails than a normal distribution, particularly in municipalities with low and very low marginalization levels. The data reveal a clear trend: setbacks in life expectancy decrease as marginalization increases, though variability is higher in municipalities with very high marginalization. Additionally, the life expectancy distribution tends to be more peaked than a normal distribution, especially in municipalities with low marginalization levels. A map of Mexico, considering the number of municipalities in each state, illustrates life expectancy setbacks, showing that Yucatán and the State of Mexico were the most affected, with an average setback of 26 years, followed by Aguascalientes, Tlaxcala, and Mexico City. In contrast Chihuahua, Durango, and San Luis Potosí experienced the least impact. A detailed municipal-level map is available at <https://datawrapper.dwcdn.net/ETLFa/1/>.

Graph 1
Average setbacks per state of life expectancies
after COVID-19 in Mexico, 2020



Source: Own elaboration information.

An analysis of variance (ANOVA) with a 5-level factor was carried out to examine the differences in setbacks in life expectancy between the groups. The results revealed an F-statistic of 325.94 ($p\text{-value} = 0.000$), indicating that there is at least a significant difference between the life expectancy setbacks means in the groups. This difference suggests that municipalities with a very low marginalization index experience a greater life expectancy setback than those classified as very high. Again, the cited paradox appears, and we assume the mentioned hypotheses as explanations to these.

Goodness-of-fit tests were also performed to determine the individual setbacks distribution by marginalization level. At the national level, the setbacks have a normal distribution with $\mu = 21.48$ and $\sigma = 2.70$ (see Table 5 and Graph 2 for all cases).


So, municipalities experienced setbacks of between 18 and 22 years, with five municipalities showing setbacks of 24 or more years. The most significant changes in life expectancy were observed between 2005 and 2020; in 2005, it was 2.23 years higher than in 2020. In some municipalities, life expectancy is between 8 and 10 years less, indicating a severe impact. Most municipalities saw a decrease of between 2 and 4 years in life expectancy. Comparing the average life expectancy in 2005, it was typically between 74 and 75 years, rarely falling below 73 years. Fifteen years later, in 2020, most municipalities have an average life expectancy between 71 and 72 years, with none exceeding the 74-year threshold.

Table 5
Distribution of setbacks by marginalization level, 2020

Marginalization level	Distribution	Parameters
Very Low	Lognormal	$\mu = 3.12, \sigma = 0.07$
Low	Lognormal	$\mu = 3.11, \sigma = 0.09$
Medium	Weibull	$\beta = 2158.79, \alpha = 6180.06, \gamma = -6157.07$
High	Normal	$\mu = 17.52, \sigma = 5.72$
Very High	Normal	$\mu = 8.65, \sigma = 8.04$

Source: Own elaboration.

Graph 2
Distribution of differences between 2005 and 2020
in all municipalities



Source: Own elaboration.

6. Conclusions

From a demographic standpoint, the aftermath of the initial waves of the COVID-19 pandemic has had a detrimental effect on life expectancy worldwide. Developing countries have borne the brunt of this impact. However, it’s crucial to acknowledge the varying degrees of impact within countries like Mexico, which have experienced disparities across their regions and municipalities. To address this, our paper proposes the use of setbacks and total years lost as indicators, focusing on the year 2020 and grouping municipalities by their level of marginalization.

Our approach to estimating these indices builds upon previous life expectancy estimates. Paradoxically, we find that in

2020, the least marginalized municipalities were the most affected, as evidenced by all the indices we utilized. While several demographic factors may contribute to this phenomenon, such as median age, prevalence of preexisting conditions (e.g., diabetes, obesity), and high population density, exploring these factors falls beyond the scope of our current objective and is earmarked for future research.

The imputation of life expectancy values in certain municipalities exposes disparities, highlighting challenges in data quality and healthcare access. Analysis of total years lost reveals paradoxical findings, where less marginalized municipalities experience higher setbacks. These implications extend beyond health, affecting the labor force, economic output, and social services. This underscores the urgency for governments to implement effective strategies in the short term to address these challenges.

While interpolation could enhance the accuracy of our estimates, we are cautious about its potential to introduce biases. We believe that recovery presents a significant challenge for all municipalities, particularly for those more marginalized. Given the setbacks observed, we advocate for the implementation of robust and sustained health policies over the coming decades to restore life expectancy levels to those observed before the pandemic.

Bibliography

- Aburto, J. M., Kristensen, F. F., and Sharp, P. (2021). Black-white disparities during an epidemic: Life expectancy and lifespan disparity in the US, 1980–2000. *Economics and Human Biology*, 40, 100937. DOI: 10.1016/j.ehb.2020.100937
- Adams, J., MacKenzie, M. J., Amegah, A. K. *et al.* (2021). The conundrum of low COVID-19 mortality burden in sub-Saharan Africa: myth or reality? *Global Health: Science and Practice*, 9(3), 433–443. DOI: 10.9745/GHSP-D-21-00172
- Agudelo-Botero, M., Dávila-Cervantes, C. A., Velasco-Calderón, O. *et al.* (2023). Divergences and gaps in life expectancy and health-adjusted life expectancy in Mexico: Contribution analysis of the Global Burden of Disease study 2019. *PLOS one*, 18(11), e0293881. DOI: 10.1371/journal.pone.0293881
- Andersen, L. E., and Gonzáles Rocabado, A. (2021). Life and death during the first year of the COVID-19 pandemic: An analysis of cross-country differences in changes in quantity and quality of life. *Revista Latinoamericana de Desarrollo Económico*, 35, 9–57. http://www.scielo.org.bo/scielo.php?pid=S2074-47062021000100002&script=sci_arttext
- Chandran, A., Purbey, R., Leifheit, K. M. *et al.* (2022). County-level life expectancy change: A novel metric for monitoring public health. *International Journal of Environmental Research and Public Health*, 19(17), 10672. DOI: 10.3390/ijerph191710672
- Consejo Nacional de Población [CONAPO] (2018). *Proyecciones de la población de México y de las entidades federativas, 2016–2050* [Hoja de cálculo Excel]. México: Secretaría de Gobernación. http://portales.segob.gob.mx/work/models/Derechos_Humanos/excel/Esperanza_de_vida_al_nacer.xlsx

- (2020). *Indices de marginación sociodemográfica a nivel municipal, 1990-2020*. México: Secretaría de Gobernación. <https://datos.gob.mx/busca/dataset/indice-de-marginacion-carencias-poblacionales-por-localidad-municipio-y-entidad>
- Crimmins, E. M., and Zhang, Y. S. (2019). Aging populations, mortality, and life expectancy. *Annual Review of Sociology*, 45, 69-89. DOI: 10.1146/annurev-soc-073117-041351
- Dukhovnov, D., and Barbieri, M. (2022). County-level socioeconomic disparities in COVID-19 mortality in the USA. *International Journal of Epidemiology*, 51(2), 418-428. DOI: 10.1093/ije/dyab267
- Espinosa, O., Ramos, J., Rojas-Botero, M. L. *et al.* (2023). Years of life lost to COVID-19 in 49 countries: A gender- and life cycle-based analysis of the first two years of the pandemic. *PLOS Global Public Health*, 3(9), e0002172. DOI: 10.1371/journal.pgph.0002172
- García-Guerrero, V. M., and Beltrán-Sánchez, H. (2021). Heterogeneity in excess mortality and its impact on loss of life expectancy due to COVID-19: evidence from Mexico. *Canadian Studies in Population*, 48(2), 165-200. DOI: 10.1007/s42650-021-00051-1
- Goldstein, J. R., and Lee, R. D. (2024). Life expectancy reversals in low-mortality populations. *Population and Development Review*, 50(2), 437-459. DOI: 10.1111/padr.12619
- González-Pérez, G. J., and Vega-López, M. G. (2021). Mortalidad juvenil, marginación social e inequidad en salud en México. *Ciência & Saúde Coletiva*, 26(7), 2587-2599. DOI: 10.1590/1413-81232021267.0829202
- Hernández, B., Rodríguez Angulo, E., Johnson, L. M. *et al.* (2022). Assessment of the quality of the vital registration system for under-5 mortality in Yucatan, Mexico. *Population Health Metrics*, 20(1), 7. DOI: 10.1186/s12963-022-00284-5
- Heuveline, P. (2022). Global and national declines in life expect-

- tancy: An end-of-2021 assessment. *Population and Development Review*, 48(1), 31-50. DOI: 10.1111/padr.12477
- Huang, G., Guo, F., Zimmermann, K.F. *et al.* (2023). The effect of the COVID-19 pandemic on life expectancy in 27 countries. *Scientific Reports*, 13(1), 8911. DOI: 10.1038/s41598-023-35592-9
- Lawal, Y. (2021). Africa's low COVID-19 mortality rate: A paradox? *International journal of infectious diseases*, 102, 118-122. DOI: 10.1016/j.ijid.2020.10.038
- Lima, E. E., Vilela, E. A., Peralta, A. *et al.* (2021). Investigating regional excess mortality during 2020 COVID-19 pandemic in selected Latin American countries. *Genus*, 77(1), 30. DOI: 10.1186/s41118-021-00139-1
- Paredes, I., and Silva, E. (2017). Estimación de la esperanza de vida a nivel municipal y por marginación sociodemográfica: una aplicación del método de Swanson para el caso de México, 2010. *Estudios demográficos y urbanos*, 32(1), 97-129. https://www.scielo.org.mx/scielo.php?pid=S0186-72102017000100097&script=sci_arttext
- Quiroga, S. (19 de mayo 2021). La paradoja del exceso de mortalidad por COVID-19. *Gaceta médica*.
- Rabin, R. C. (2022). U.S. life expectancy falls again in historic setback. *New York Times*, Aug 31, 2022. <https://www.nytimes.com/2022/08/31/health/life-expectancy-covid-pandemic.html>
- Silva, E., Ortiz, B., and Carrasco, E. (2023). Desagregación de la esperanza de vida en México desde el nivel estatal hasta el municipal y sus respectivas visualizaciones, 1990-2020. *Notas de Población*, 50(117), 71-93. <https://repositorio.cepal.org/bitstreams/8a13b613-8faf-4b5f-8c20-22796f4f877c/download>
- Sun, M. W., Troxell, D., and Tibshirani, R. (2023). Public health factors help explain cross country heterogeneity in excess

- death during the COVID-19 pandemic. *Scientific Reports*, 13(1), 16196. DOI: 10.1038/s41598-023-43407-0
- Temporelli, K., and Viego, V. (2011). Relación entre esperanza de vida e ingreso. Un análisis para América Latina y el Caribe. *Lecturas de Economía*, (74), 61-85. http://www.scielo.org.co/scielo.php?pid=S0120-25962011000100003&script=sci_arttext
- Trias-Llimós, S., Riffe, T., and Bilal, U. (2020). Monitoring life expectancy levels during the COVID-19 pandemic: Example of the unequal impact of the first wave on Spanish regions. *PLOS one*, 15(11), e0241952. DOI: 10.1371/journal.pone.0241952
- Yusuf, F., Martins, J. M. and Swanson, D. A. (2014). *Methods of demographic analysis*, Berlin: Springer.

Información de autores

Alejandro Islas Camargo

Es Profesor Investigador de tiempo completo en el Departamento de Estadística del Instituto Tecnológico Autónomo de México (ITAM) desde 2000. Obtuvo los grados de Lic. en matemáticas y maestro en Ciencias (Matemáticas) por la Universidad Autónoma Metropolitana, así como de Maestro en Ciencias (Estadística) en la universidad Estatal de Iowa y el Doctorado en Economía por la Universidad de Nuevo México en USA. Es miembro del Sistema Nacional de Investigadores, nivel II. Su investigación se centra en preguntas de investigación interdisciplinarias relacionadas con finanzas, mercado laboral, medio ambiente y economía de la salud y se han publicado en *the Journal of International Economics*, *CEPAL Review*, *Communication in Statistics- Theory and Methods*, *Romanian Journal of Economic Forecasting and Statistics and Applications*.

aislas@itam.mx

ORCID: <https://orcid.org/0000-0003-0910-313X>

Baruch Ramírez

Baruch Ramírez es economista del desarrollo, realizó sus estudios de doctorado en la University of East Anglia, en Reino Unido. Cuenta con experiencia en el sector público. Es especialista en diseño de encuestas por muestreo, mercado laboral y Medición de pobreza. Ha participado en diversos proyectos de investigación.

rrbaruch@cucea.udg.mx

Cristian O. Cárdenas Mora

Maestro en Economía por la Universidad de Guadalajara. Participante en el programa “A Multidisciplinary Approach to Children Obesity Prevention in Mexico” en la Georg-August Universität Göttingen, Alemania. Ha impartido clase como profesor adjunto en la Universidad de Guadalajara (CUCEA y CUGDL).

Se ha desarrollado en el sector privado principalmente en análisis de datos y finanzas, actualmente es Jefe de Nómina del Resto del Ejecutivo en la Secretaría de la Hacienda Pública del Gobierno de Jalisco.

oswaldo.cardenas@jalisco.gob.mx

Daniel Bedolla

Es Licenciado en Matemáticas Aplicadas por el Instituto Tecnológico Autónomo de México.

daniel.bedolla@kavak.com

Daniel González Olivares

Daniel González Olivares es Economista de profesión, licenciado en matemáticas y se doctoro en Economía en la Universidad

de ESSEX en Inglaterra. Es profesor de la Universidad de Guadalajara y miembro del sistema nacional de investigadores nivel I. Su campo de investigación es el Análisis Financiero con Series de Tiempo y la manipulación de las Redes Sociales utilizando Grandes Bases de Datos con Inteligencia artificial y modelos de Machine Learning.

daniel.gonzalez.o@cucea.udg.mx

ORCID: <https://orcid.org/0000-0002-9052-2763>

Eliud Silva

Profesor-Investigador en la Facultad de Ciencias Actuariales de la Universidad Anáhuac México y coordinador de la Maestría en Estadística. Es actuuario por la UNAM, Maestro en Demografía y Doctor en Ingeniería Matemática por la Universidad Carlos III de Madrid. Ha impartido clases en diversas universidades y realizado estancias de investigación internacionales. Su labor académica abarca docencia, consultoría y publicaciones en estadística y demografía. Ha trabajado en sectores asegurador, cultural y educativo. Es miembro del SNI del CONAHCYT y árbitro de revistas científicas. Su investigación se enfoca en métodos estadísticos aplicados a fenómenos sociales, especialmente series de tiempo y demografía.

jose.silva@anahuac.mx

ORCID: <https://orcid.org/0000-0003-0499-0446>

Fatima Ezzahra Housni

La Dra. Fatima Ezzahra Housni es Doctora en Ciencias del Comportamiento con Orientación en Alimentación y Nutrición por la Universidad de Guadalajara. Actualmente se desempeña como Coordinadora de Investigación y Posgrado del Centro Universitario de Tlajomulco y Profesora Investigadora Titular A. Es Miembro del Sistema Nacional de Investigadores Nivel

I, fundadora de la Red Internacional para la Investigación Sostenible en Comportamiento, Alimentación y Medio Ambiente (RIISCAM). Sus líneas de investigación se enfocan en dietas sostenibles, nutrición y medio ambiente. Recientemente publicó *Food System vs. Sustainability: An Incompatible Relationship in Mexico* (2024).

fatima.housni@cutlajomulco.udg.mx

ORCID: <https://orcid.org/0000-0003-0660-609X>

Frida Fernández de la Rosa

Maestra en Economía por la Universidad de Guadalajara y Licenciada en Finanzas por la Universidad Autónoma de Ciudad Juárez. Su área de interés son temas ligados a la economía de la salud, en específico, los relacionados a las elecciones en la alimentación de la población Mexicana.

frida.fernandez7684@alumnos.udg.mx

ORCID: <https://orcid.org/0000-0003-3759-0430>

Guillermo Beick Tapia

Actuario titulado por la Universidad Anáhuac México, distinguido con múltiples reconocimientos por su excelencia académica y desempeño destacado. Durante su formación universitaria, sus proyectos resaltaron por su originalidad, rigor técnico y enfoque innovador. Actualmente colabora en la industria aérea mexicana, participando activamente en la reingeniería de procesos y el desarrollo de proyectos enfocados en mejorar la eficiencia operativa, optimizar la toma de decisiones estratégicas y fomentar la sostenibilidad. Su sólida formación actuarial, junto con una marcada capacidad analítica, lo posicionan como un joven profesional con alto potencial para generar soluciones de valor en entornos complejos y altamente competitivos.

guiller-mo.beick@anahuac.mx

ORCID: <https://orcid.org/0009-0007-2115-2221>

Isaí Guizar

Doctor en Desarrollo Económico por The Ohio State University, Ohio, Estados Unidos de América, con maestría en economía por la misma universidad. Actualmente es profesor-investigador adscrito al Departamento de Economía del Centro Universitario de Ciencias Económico – Administrativas (CUCEA) de la Universidad de Guadalajara (UdeG) e Investigador Nivel I del Sistema Nacional de Investigadores. Desde el 2019 se desempeña como editor de *EconoQuantum*, Revista Cuantitativa de Economía y Finanzas. Ha publicado, entre otros, en el *Journal of Time Series Econometrics*, *Savings and Development*, y el *Spanish Journal of Economics and Finance- Cuadernos de Economía*. Sus líneas de investigación se centran en temas de desarrollo financiero, economía de la salud y economía del crimen.

isai.guizar@cucea.udg.mx

ORCID: 0000-0001-8616-8848

Willy W. Cortez

Es PhD en Economía por la University of Notre Dame, EUA. Está adscrito al Dpto de Métodos Cuantitativos, Universidad de Guadalajara. Actualmente es director de Centro de Estudios de Problemas de Desarrollo (CEPRODE) UdeG. Es S.N.I. Nivel III. Es miembro fundador y ex-director de la revista *EconoQuantum*. Es miembro del Grupo “Border Region Modeling Project” de la University of Texas, El Paso. Ha sido evaluador de diversas comisiones en el CONAHCYT. Ha publicado en *World Development*, *Cepal Review*, *International Journal of Social Economics*, *Gestión y Política Pública* entre otras

revistas. Sus temas de interés son: crecimiento, desigualdad, economía del crimen.

wcor-tez@cucea.udg.mx

ORCID: 0000-0001-8839-4064

**Brechas en la Salud.
Evidencia sobre Desigualdades y Vulnerabilidad en
México**

Isaí Guízar
Willy W. Cortez
Coordinadores

Se terminó de editar en noviembre de 2025

por CARIMEditores (Lilia Nataly Vaca Tapia),

Puebla 53, Fracc. Valle Ceylán,
Tlalnepantla, Edo. Mex. CP 54150

www.carimeditores.com

Para consulta y descarga: www.cucea.udg.mx

Desigualdades estructurales, el avance de las enfermedades crónicas y limitaciones institucionales han impedido que amplios sectores de la población Mexicana accedan a servicios públicos de salud oportunos y de calidad. Desde esa realidad, *Brechas en la Salud: Evidencia sobre Desigualdades y Vulnerabilidad en México* reúne cinco estudios empíricos que exploran, con herramientas cuantitativas rigurosas, cómo se producen y se reproducen esas brechas. La obra propone mirar a la salud pública como el resultado de decisiones políticas, económicas y sociales que pueden reorientarse hacia un sistema integral, más equitativo y preventivo. A lo largo de sus capítulos, el libro aborda temas clave de la agenda de salud: desde el desarrollo de algoritmos basados en modelos de series de tiempo para anticipar episodios de hipoglucemia en pacientes con diabetes tipo 1, hasta el análisis de cómo factores socioeconómicos influyen en la probabilidad de obesidad y sobrepeso. También examina el vínculo entre malnutrición infantil y desempeño escolar, los posibles efectos no intencionados del Seguro Popular sobre la mortalidad por enfermedades metabólicas y el retroceso de la esperanza de vida municipal tras la pandemia de COVID-19. En conjunto, estos estudios muestran que las brechas en salud están ancladas en las estructuras sociales y territoriales del país, pero también ofrecen rutas concretas de acción para quienes diseñan y ejecutan políticas públicas, para profesionales de la salud y estudiantes interesados en construir un sistema integral de salud pública.

