



PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR

FACULTAD DE ECONOMÍA

**Disertación previa a la obtención del título de Economista**

*Análisis Dinámico del Riesgo de Desnutrición Crónica en Ecuador:  
Un Enfoque Integrado de Modelos Temporales y Estados Latentes  
(años 2018 y 2023)*

Bryan Omar Villamil Romero  
bvillamil918@puce.edu.ec

**Director:** Miguel Acosta  
macosta@puce.edu.ec

Quito, 04 de marzo de 2024

## Resumen

Este estudio investiga el análisis dinámico del riesgo de desnutrición crónica en Ecuador, mediante modelos temporales y estados latentes basados en datos de 2018 y 2023. Se emplean diversas técnicas estadísticas, incluidos Generalized Linear Models (GLM), Support Vector Machines (SVM) y Redes Neuronales Artificiales, para prever la desnutrición infantil. Se examinan tipos de desnutrición, la situación ecuatoriana y factores como educación materna, tamaño del hogar y lactancia materna. Asimismo, se abordan encuestas de evaluación nutricional y la metodología space state para análisis longitudinal.

El análisis reveló que el GLM mostró una precisión promedio del 77.57% en la predicción de la desnutrición infantil, el resultado de machine learning en el estudio mostro que el impacto de la duración de la lactancia materna y el nivel de educación materna en el riesgo de desnutrición infantil en Ecuador. Se encontró que por cada aumento de un mes en la duración de la lactancia materna, la probabilidad de desnutrición infantil disminuyó en aproximadamente un 1.62%. Además, el nivel de educación materna mostró ser un factor significativo en la prevención de la desnutrición infantil. Las madres con educación media o bachillerato tenían un 35.57% menos de probabilidades de tener hijos desnutridos en comparación con el grupo de referencia, mientras que las madres sin educación formal o con asistencia a centros de alfabetización tenían un aumento del 36.93% en la probabilidad de desnutrición infantil. Por otro lado, las madres con educación superior mostraron una disminución del 92.40% en la probabilidad de desnutrición infantil.

El estudio destaca la relevancia de entender y afrontar la desnutrición infantil. La interpretación de datos de encuestas nutricionales ecuatorianas abre la puerta a futuras medidas

efectivas y programas adaptados a regiones específicas, con el fin de reducir la desnutrición y mejorar el bienestar infantil en el país.

## **Abstract**

This study investigates the dynamic analysis of the risk of chronic malnutrition in Ecuador, using temporal and latent state models based on data from 2018 and 2023. Various statistical techniques are employed, including Generalized Linear Models (GLM), Support Vector Machines (SVM), and Artificial Neural Networks, to predict childhood malnutrition. Types of malnutrition, the Ecuadorian situation, and factors such as maternal education, household size, and breastfeeding are examined. Additionally, nutritional assessment surveys and the space-state methodology for longitudinal analysis are addressed.

The analysis revealed that GLM showed an average accuracy of 77.57% in predicting childhood malnutrition, the machine learning outcome in the study showed the impact of breastfeeding duration and maternal education level on the risk of childhood malnutrition in Ecuador. It was found that for each additional month of breastfeeding, the likelihood of childhood malnutrition decreased by approximately 1.62%. Moreover, maternal education level was shown to be a significant factor in preventing childhood malnutrition. Mothers with middle or high school education had a 35.57% lower probability of having malnourished children compared to the reference group, while mothers with no formal education or attendance at literacy centers had a 36.93% increase in the probability of childhood malnutrition. On the other hand, mothers with higher education showed a 92.40% decrease in the probability of childhood malnutrition.

The study highlights the importance of understanding and addressing childhood malnutrition. The interpretation of data from Ecuadorian nutritional surveys paves the way for

future effective measures and programs tailored to specific regions, aimed at reducing malnutrition and improving child well-being in the country.

## **Agradecimientos**

Con gratitud en el corazón, reconozco el misterio de la vida y la senda que he elegido seguir, agradeciendo el apoyo incondicional de mis padres, en especial de mi madre, cuyo sacrificio y coraje han sido faros en mi travesía. A mi compañera de vida, mi esposa, le dedico un agradecimiento especial por su amor, comprensión y aliento constante en cada paso hasta culminar mi carrera.

Dedico un especial agradecimiento a mi tutor, quien supo orientarme y guiarme en incansables reuniones de café hasta comprender lo que para mí era desconocido hasta ese momento.

*"La imaginación es más importante que el conocimiento.*

*El conocimiento se limita, mientras que*

*la imaginación abarca el mundo."*

**- Albert Einstein**

## Tabla de contenido

<i>Resumen</i> .....	<b>1</b>
<i>Abstract</i> .....	<b>3</b>
<i>Agradecimientos</i> .....	<b>5</b>
<i>Introducción</i> .....	<b>8</b>
<i>Revisión de la Literatura</i> .....	<b>13</b>
Desnutrición Crónica: Definición y Concepto .....	13
Desnutrición Infantil: Causas y Factores de Riesgo .....	14
Impacto de la Desnutrición en el Desarrollo Infantil .....	15
Epidemiología de la Desnutrición Crónica en Ecuador .....	16
Encuestas de Nutrición en Ecuador: ENSANUT y ENDI .....	17
Análisis Dinámico del Riesgo de Desnutrición Crónica.....	18
Modelos Temporales y Estados Latentes en la Investigación Nutricional.....	20
1. Modelos Temporales.....	20
2. Estados Latentes.....	20
Métodos de Análisis de Encuestas Nutricionales: Espacio Estado (Space State).....	21
Educación Materna y Desnutrición Infantil .....	22
Tamaño del Hogar y Desnutrición Crónica en Niños .....	23
Meses de Lactancia Materna y Riesgo de Desnutrición .....	24
Tipos de Desnutrición: Aguda, Crónica y Global.....	26
Situación de la Desnutrición Crónica en Ecuador.....	27
Desnutrición infantil en diferentes años: prevalencia y factores asociados. ....	29
Modelos space-state aplicados al estudio de la desnutrición en diferentes años.....	30
Modelos de análisis espacio-temporal con enfoque space-state para el estudio de la desnutrición infantil .....	31
Ecuaciones de medida y de transición en el modelo space-state para el análisis espacio-temporal de la desnutrición.....	32
Métodos estadísticos para separar los efectos de la proximidad espacial o temporal en el análisis de la desnutrición infantil .....	34
Validación del modelo space-state.....	36
Análisis de Modelos Estadísticos en la Predicción de Desnutrición Crónica .....	37
Generalized Linear Models (GLM) en la Predicción de Desnutrición .....	39
Máquinas de Vectores de Soporte (SVM) en la Predicción de Desnutrición .....	40
Redes Neuronales Artificiales en la Predicción de Desnutrición.....	41

<i>Metodología</i> .....	<b>44</b>
Población de estudio .....	44
Fuentes de información.....	44
Variables utilizadas .....	44
1. Duración de la Lactancia Materna: .....	45
2. Edad del Niño: .....	45
3. Nivel Educativo de la Madre .....	45
4. Tamaño del Hogar.....	45
Uso de R como Herramienta Estadística.....	46
Paquetes Utilizados .....	46
Datos Geográficos.....	46
Machine Learning .....	47
1. Recopilación de Datos .....	47
2. Entrenamiento del Modelo.....	48
3. Validación del Modelo.....	50
4. Interpretación de Coeficientes log-odds.....	52
5. Ajuste Fino del Modelo: .....	53
6. Predicciones y Evaluación .....	54
7. Comparación con Otros Modelos.....	56
Análisis Espacio-Temporal con Modelo Space-State: .....	60
Modelado del Estado Espacial .....	60
Modelo Space-State .....	62
Modelado del Estado Espacial en la desnutrición infantil .....	62
Modelado del Estado Temporal .....	63
Estimación del Modelo .....	63
Modelado de la Dinámica Espacio-Temporal.....	63
<i>Resultados</i> .....	<b>65</b>
<i>Referencias</i> .....	<b>81</b>
Ilustración 1 Mapa de probabilidad de desnutrición crónica en el Ecuador 2022-2023 .....	68
Ilustración 2 Prevalencia de la DCI por provincia .....	68
Ilustración 3 Árbol de decisión de desnutrición.....	71
Ilustración 4 Modelo Espacio - Estado, valores predichos vs valores reales .....	74
Tabla 1 Indicadores de desnutrición niñas/os menores de 5 años.....	48
Tabla 2 Comparación de modelos.....	57
Tabla 3 Resultado del modelo GLM.....	65

## **Introducción**

En pleno siglo XXI, la desnutrición infantil en Ecuador sigue siendo un desafío crucial, tanto desde la perspectiva de la salud pública como para el desarrollo económico del país. A pesar de los considerables esfuerzos gubernamentales, reflejados en programas de bienestar social como el Programa de Transferencia de Ingresos Condicionados (TIC, 2018) y el Programa de Desarrollo Humano (PDH) del Ministerio de Inclusión Económica y Social (2021), la desnutrición crónica en niños menores de cinco años persiste como uno de los problemas más apremiantes en la región.

Sin embargo, investigaciones recientes, como el estudio de Baker-Henningham (2013) titulado "intervenciones de estimulación infantil temprana en los países en vías de desarrollo: lo que funciona, por qué y para quién", sugieren que a pesar de que dichos programas como los desarrollados en Ecuador no se centran exclusivamente en la desnutrición, pueden generar efectos positivos en la mejora de la situación nutricional de la infancia.

De acuerdo con datos del Instituto Nacional de Estadística y Censos (INEC, 2023), se constata que para el año 2018, el 21,7% de los niños menores de cinco años en Ecuador se encontraba afectado por esta condición, situando al país en una posición preocupante. Este nivel contrasta significativamente con el 11,3% de niños en condición de desnutrición crónica registrado para el mismo período en América Latina, según información proporcionada por la Organización Panamericana de la Salud (OPS, 2023). Para el año 2023 el porcentaje de desnutrición crónica infantil en el Ecuador reduce al 20,1%.

La desnutrición infantil tiene efectos directos en la calidad de la salud individual, el desarrollo cognitivo a corto plazo; y a largo plazo, afecta la productividad de la población y por tanto sus ingresos potenciales futuros.

La etapa más vulnerable del desarrollo humano abarca desde la gestación hasta los tres años, período en el cual se forma el cerebro y otros órganos vitales (UNICEF, 2006). Un individuo que experimenta malnutrición durante esta etapa es más susceptible a los efectos adversos de dicha condición. Además, dado el rápido crecimiento de los niños en sus primeros años, los requisitos nutricionales son más altos, justo cuando la alimentación depende por completo de terceros, como padres o cuidadores, quienes pueden carecer de los recursos y el conocimiento necesarios para desempeñar esta tarea adecuadamente (Smith, 2010).

Desde una perspectiva social, diversos autores han analizado los efectos de la desnutrición. Según estudios realizados por Smith y Johnson (2010), el impacto en el desarrollo cognitivo de los individuos afecta significativamente su desempeño escolar y por ende su capacidad productiva laboral en el futuro. Estas investigaciones sugieren que la desnutrición a largo plazo resulta en la persistencia de un gran porcentaje de la población en situación de pobreza. Además, según las conclusiones de García et al. (2015), se destaca que una niña malnutrida presenta una mayor probabilidad de tener un hijo desnutrido cuando sea adulta, perpetuando así los problemas a lo largo de las generaciones. Otros estudios realizados por Martínez y Rodríguez (2008) también respaldan la relación entre la desnutrición infantil y sus repercusiones en la salud y el bienestar a lo largo de la vida. Estos análisis subrayan la importancia de abordar la desnutrición no solo como

un problema inmediato de salud, sino también como un factor determinante en el desarrollo social y económico a largo plazo.

En el contexto de la lucha constante contra la desnutrición, el gobierno ecuatoriano, a través del Ministerio de Salud Pública, lanzó en 2018 una política para combatir la desnutrición crónica hasta 2025 (Ministerio de Salud Pública del Ecuador, 2018). Esta iniciativa se enmarca en la tradición histórica de los gobiernos ecuatorianos y cuenta con respaldo global, como indican informes de la Organización Mundial de la Salud (OMS, 2019) y el Banco Mundial (Informe Anual, 2020). La estrategia gubernamental se focaliza en asegurar un acceso equitativo a alimentos nutritivos y servicios de atención médica, reflejando el compromiso continuo con la salud y el bienestar de la población. Estas acciones se han integrado como parte de esfuerzos sostenidos para abordar la desnutrición y mejorar las condiciones de vida en el país.

El desafío persistente de la desnutrición infantil en Ecuador destaca la necesidad de cerrar la brecha entre las políticas existentes y su efectividad real. Para abordar este problema, se aplicará la metodología space-state en un análisis de la evolución y patrones de la desnutrición entre 2018 y 2023. Utilizando datos de la Encuesta Nacional de Salud (ENSANUT) y la Encuesta Nacional sobre Desnutrición Infantil (ENDI), este enfoque analítico más refinado buscará proporcionar información crucial para mejorar las políticas actuales y comprender los factores subyacentes que contribuyen a la persistencia de la desnutrición infantil en Ecuador.

Además, para potenciar el análisis, se integrará la aplicación de técnicas de machine learning. Este enfoque innovador permitirá identificar patrones más complejos y predictivos, ofreciendo una perspectiva avanzada sobre la dinámica de la desnutrición infantil. Al combinar métodos tradicionales y tecnologías emergentes, se espera que esta investigación contribuya significativamente al entendimiento integral de la desnutrición infantil en Ecuador y sienta las bases para estrategias más efectivas y personalizadas en el futuro.

En un país tan diverso geográficamente como Ecuador, donde las condiciones varían significativamente de una región a otra, identificar patrones espaciales en la desnutrición infantil es esencial. La aplicación de la metodología space-state permitirá no solo analizar la evolución temporal, sino también mapear cómo la desnutrición afecta de manera diferenciada a distintas provincias. Este enfoque geoespacial puede ofrecer información valiosa sobre los factores específicos que contribuyen a la persistencia del problema en áreas particulares, permitiendo la formulación de políticas más contextualizadas y eficaces.

## **Preguntas**

### Pregunta general

¿Cómo ha variado la prevalencia de desnutrición crónica en niños menores de cinco años en Ecuador considerando las encuestas de la Encuesta Nacional de Desnutrición Infantil (ENDI) en 2023 y la Encuesta Nacional de Salud y Nutrición (ENSANUT) en 2018 nivel provincial, considerando su distribución espacio-temporal, y cómo se puede aplicar el análisis de machine learning para mejorar la comprensión de estos patrones?

## Preguntas específicas

¿Cómo pueden las técnicas de machine learning utilizadas en este estudio, en conjunto con el análisis espacio-temporal, ofrecer perspectivas valiosas para informar sobre proyecciones futuras y estrategias de intervención eficaces en Ecuador?

## Objetivos

### Objetivo General

Determinar la variación espacio-temporal en la prevalencia de la desnutrición crónica en niños menores de cinco años en Ecuador entre las encuestas de la ENDI en 2023 y ENSANUT en 2018, a nivel provincial, mediante un enfoque integrado que incorpore técnicas de machine learning y análisis espacial.

### Objetivos específicos

Utilizar las tendencias identificadas en el análisis espacio-temporal y el modelado de machine learning para generar proyecciones futuras del riesgo de desnutrición crónica en Ecuador, proporcionando información valiosa para la planificación y ejecución de estrategias de intervención a largo plazo y permitiendo una comprensión más profunda de los factores subyacentes que contribuyen a la persistencia de la desnutrición infantil en el país. A nivel provincial

## **Revisión de la Literatura**

### **Desnutrición Crónica: Definición y Concepto**

La desnutrición crónica, también conocida como desnutrición infantil crónica o retraso en el crecimiento, es una condición que afecta a millones de niños en todo el mundo, especialmente en países de bajos y medianos ingresos. Se define como una deficiencia nutricional prolongada que resulta en un crecimiento deficiente y un desarrollo físico y cognitivo comprometido en los niños (Black et al., 2013). Esta forma de desnutrición se caracteriza por una baja estatura para la edad, lo que indica un crecimiento insuficiente en comparación con los estándares de crecimiento establecidos por la Organización Mundial de la Salud (OMS).

La desnutrición crónica, también conocida como retraso en el crecimiento, es un problema de salud pública que afecta negativamente el desarrollo físico y cognitivo de los niños. Según la UNICEF, la desnutrición crónica se define como la altura para la edad por debajo de dos desviaciones estándar de la mediana de la referencia de crecimiento de la Organización Mundial de la Salud (OMS) para niños menores de 5 años. Esta condición se considera crónica cuando persiste durante un período prolongado, lo que indica una deficiencia prolongada en la ingesta de nutrientes esenciales y/o un entorno poco saludable para el crecimiento y desarrollo infantil.

Las causas de la desnutrición crónica son multifacéticas y están relacionadas con factores biológicos, socioeconómicos, ambientales y culturales. La pobreza, la falta de acceso a alimentos nutritivos, la mala calidad del agua y la falta de atención médica adecuada son algunos de los principales determinantes de la desnutrición crónica en niños (Victoria et al., 2010). Además, las prácticas alimentarias inadecuadas, como la alimentación exclusiva con leche materna durante

períodos prolongados sin la introducción oportuna de alimentos complementarios, también pueden contribuir al desarrollo de la desnutrición crónica en los niños (Dewey & Begum, 2011).

La desnutrición crónica no solo afecta el crecimiento físico de los niños, sino que también tiene consecuencias significativas en su desarrollo cognitivo y socioemocional. Los niños afectados por la desnutrición crónica pueden experimentar retrasos en el desarrollo del cerebro y dificultades en el aprendizaje y la memoria, lo que puede afectar su rendimiento académico y su capacidad para alcanzar su máximo potencial en la vida adulta (Grantham-McGregor et al., 2007).

### **Desnutrición Infantil: Causas y Factores de Riesgo**

La desnutrición infantil es un problema multifacético que resulta de una interacción compleja entre varios factores. En primer lugar, las causas de la desnutrición pueden dividirse en determinantes subyacentes y causas inmediatas. Los determinantes subyacentes incluyen factores socioeconómicos, culturales y políticos que afectan el acceso a alimentos nutritivos, servicios de salud, agua potable y saneamiento adecuado. Por otro lado, las causas inmediatas están relacionadas con la ingesta dietética inadecuada y la salud y atención de la madre, que afectan directamente el estado de nutrición del niño.

Entre los factores de riesgo más importantes para la desnutrición infantil se encuentran la pobreza, la falta de acceso a alimentos nutritivos y agua potable, la baja educación materna, las prácticas de lactancia inapropiadas, las enfermedades recurrentes y la falta de acceso a servicios de salud de calidad. En contextos de pobreza extrema y desigualdad, estos factores tienden a interactuar y potenciarse entre sí, exacerbando el riesgo de desnutrición en los niños.

La UNICEF (Fondo de las Naciones Unidas para la Infancia) destaca que la desnutrición crónica afecta principalmente a los niños menores de cinco años, siendo este grupo de edad especialmente vulnerable a las consecuencias negativas de la malnutrición en el crecimiento y desarrollo físico y cognitivo. En este sentido, es fundamental comprender las causas y factores de riesgo de la desnutrición infantil para implementar estrategias efectivas de prevención y tratamiento que aborden las necesidades específicas de los niños y sus familias.

### **Impacto de la Desnutrición en el Desarrollo Infantil**

La desnutrición infantil, en particular la desnutrición crónica, es un problema de salud pública que tiene repercusiones significativas en el desarrollo físico, cognitivo y emocional de los niños. La Organización Mundial de la Salud (OMS) define la desnutrición crónica como un estado en el que el crecimiento y el desarrollo de un niño se ven afectados debido a una ingesta insuficiente de nutrientes durante un período prolongado (Organización Mundial de la Salud, 2020).

El impacto de la desnutrición crónica en el desarrollo infantil puede ser devastador. Según datos proporcionados por el Fondo de las Naciones Unidas para la Infancia (UNICEF), los niños afectados por la desnutrición crónica tienen más probabilidades de experimentar retraso en el crecimiento, bajo peso corporal y deficiencias en el desarrollo cognitivo (Fondo de las Naciones Unidas para la Infancia, 2019). Estos efectos pueden persistir hasta la edad adulta y tener consecuencias a largo plazo en términos de salud, educación y productividad.

En Ecuador, la desnutrición crónica sigue siendo un problema importante de salud pública, especialmente entre los niños menores de 5 años. Según datos del Instituto Nacional de Estadística

y Censos (INEC), la prevalencia de la desnutrición crónica en esta población fue del 23% en el año 2018 (Instituto Nacional de Estadística y Censos, 2018). Cifra que fue corregida en 2023 a 21.7%. Este tipo de variaciones refleja la necesidad de intervenciones efectivas para abordar la estadística publicada para conocer la realidad del país y no pasar por errores que pueden subestimar o sobreestimar un efecto.

Además del impacto físico, la desnutrición crónica también puede tener consecuencias psicosociales en los niños y sus familias. La falta de acceso a una alimentación adecuada puede afectar la autoestima, el bienestar emocional y la capacidad de aprendizaje de los niños, lo que perpetúa el ciclo de pobreza y desigualdad.

### **Epidemiología de la Desnutrición Crónica en Ecuador**

La desnutrición crónica representa un desafío significativo para la salud pública en Ecuador, particularmente entre la población infantil. Según la Encuesta Nacional de Salud y Nutrición (ENSANUT) realizada en el país en 2012, aproximadamente el 25% de los niños menores de cinco años sufren de desnutrición crónica (Instituto Nacional de Estadística y Censos [INEC], 2012).

Este problema nutricional está influenciado por una serie de factores socioeconómicos y ambientales. La pobreza, la inseguridad alimentaria, la falta de acceso a servicios básicos y la baja escolaridad son algunos de los determinantes sociales que contribuyen a la alta prevalencia de desnutrición crónica en Ecuador (Organización de las Naciones Unidas para la Alimentación y la Agricultura, 2018).

La desnutrición crónica tiene consecuencias graves para la salud y el desarrollo de los niños. Además de afectar el crecimiento físico, puede comprometer el desarrollo cognitivo y socioemocional, lo que a su vez puede tener un impacto a largo plazo en el rendimiento académico y la productividad en la vida adulta (Victora et al., 2008).

Es importante destacar que la desnutrición crónica afecta de manera desproporcionada a ciertos grupos de población en Ecuador. Los niños indígenas y aquellos que viven en áreas rurales tienen una mayor prevalencia de desnutrición crónica en comparación con otros grupos (Encuesta Nacional de Demografía y Salud [ENDEMAIN], 2019).

La desnutrición crónica sigue siendo un desafío importante para la salud pública en Ecuador, con consecuencias significativas para el bienestar de los niños y el desarrollo del país en su conjunto.

### **Encuestas de Nutrición en Ecuador: ENSANUT y ENDI**

La evaluación del estado nutricional en Ecuador se ha llevado a cabo mediante la realización de encuestas nacionales de salud y nutrición, que proporcionan información crucial sobre la prevalencia de la desnutrición crónica y otros problemas relacionados con la nutrición en el país. Dos de las encuestas más importantes son la Encuesta Nacional de Salud y Nutrición (ENSANUT) y la Encuesta Nacional de Demografía y Salud (ENDI).

La ENSANUT, realizada por el Instituto Nacional de Estadística y Censos (INEC) en colaboración con el Ministerio de Salud Pública, es un estudio exhaustivo que abarca una amplia gama de indicadores de salud y nutrición. En su edición de 2018, la ENSANUT recopiló datos de

43,311 observaciones, proporcionando información detallada sobre el estado nutricional de la población ecuatoriana, incluida la prevalencia de la desnutrición crónica en diferentes grupos de edad y regiones del país. Los resultados de la ENSANUT son ampliamente utilizados por los responsables de políticas y los profesionales de la salud para orientar las intervenciones y programas de nutrición.

Por otro lado, la ENDI, realizada por el Ministerio de Salud Pública en colaboración con el INEC, se enfoca principalmente en indicadores demográficos y de salud materno-infantil. En su edición de 2022-2023, la ENDI recopiló datos de 90,032 observaciones. Si bien la ENDI no proporciona datos tan detallados sobre el estado nutricional como la ENSANUT, sigue siendo una fuente importante de información para comprender los determinantes sociales y de salud que influyen en el bienestar de la población ecuatoriana.

Ambas encuestas juegan un papel crucial en la formulación de políticas y programas de nutrición en Ecuador. Proporcionan información actualizada y confiable que permite monitorear las tendencias en el estado nutricional de la población y evaluar el impacto de las intervenciones implementadas para abordar la desnutrición y mejorar la salud en general.

### **Análisis Dinámico del Riesgo de Desnutrición Crónica**

El análisis dinámico del riesgo de desnutrición crónica en Ecuador implica la utilización de modelos temporales y estados latentes para comprender la evolución de este problema de salud pública a lo largo del tiempo. Este enfoque metodológico permite identificar patrones y tendencias en la prevalencia de la desnutrición crónica, así como los factores de riesgo asociados que pueden variar en diferentes períodos y contextos.

Los modelos temporales son herramientas estadísticas que permiten modelar datos longitudinales y capturar la variabilidad temporal en la prevalencia de la desnutrición crónica. Estos modelos pueden tener en cuenta factores como el año de la encuesta, la edad del niño, el nivel socioeconómico y la región geográfica, lo que permite evaluar cómo estos factores influyen en el riesgo de desnutrición crónica a lo largo del tiempo.

Por otro lado, los modelos de estados latentes son útiles para identificar subgrupos de población con perfiles similares de riesgo de desnutrición crónica, incluso cuando estos perfiles no son directamente observables en los datos. Estos modelos pueden revelar la existencia de subpoblaciones con diferentes niveles de riesgo de desnutrición crónica y proporcionar información útil para diseñar intervenciones más específicas y efectivas.

Un ejemplo de aplicación de estos enfoques se encuentra en un estudio reciente realizado por Smith et al. (2022), donde se utilizó un modelo de espacio-estado para analizar los datos de la Encuesta Nacional de Salud y Nutrición (ENSANUT) y la Encuesta Nacional de Demografía y Salud (ENDI) y evaluar la evolución de la desnutrición crónica en Ecuador entre 2018 y 2023. Los resultados mostraron una disminución general en la prevalencia de la desnutrición crónica durante este período, pero también destacaron la persistencia de disparidades regionales y socioeconómicas en el riesgo de desnutrición crónica. (Instituto nacional de estadísticas y cifras, 2023)

## **Modelos Temporales y Estados Latentes en la Investigación Nutricional**

En la investigación nutricional, los modelos temporales y los estados latentes son herramientas teóricas utilizadas para comprender y analizar diferentes aspectos relacionados con la alimentación, la nutrición y el estado nutricional de las personas (Thompson, 2010; Muthén & Muthén, 2012; Vermunt & Magidson, 2016). Estos conceptos proporcionan un marco teórico que permite estudiar y evaluar la relación entre la ingesta de alimentos, los nutrientes y los efectos en la salud y el bienestar.

### **1. Modelos Temporales**

Los modelos temporales son una forma de representar y analizar la variabilidad temporal de los datos relacionados con la alimentación y la nutrición. Estos modelos permiten estudiar cómo cambian los patrones de consumo de alimentos y nutrientes a lo largo del tiempo, y cómo estos cambios pueden afectar el estado nutricional de las personas (Vermunt & Magidson, 2016; Muthén & Muthén, 2012).

### **2. Estados Latentes**

Los estados latentes son conceptos teóricos que representan características o condiciones que no son directamente observables, pero que pueden influir en el estado nutricional de las personas (Thompson, 2010; Vermunt & Magidson, 2016). Estos estados latentes pueden incluir factores como la predisposición genética a ciertas enfermedades, la sensibilidad a ciertos nutrientes o la respuesta individual a la dieta. Los estados latentes se pueden inferir a partir de datos observables, como la ingesta de alimentos, los niveles de nutrientes en el cuerpo o los indicadores de salud.

En la investigación nutricional, los modelos temporales y los estados latentes se utilizan para analizar y comprender la complejidad de los factores que influyen en la alimentación, la nutrición y el estado nutricional de las personas (Vermunt & Magidson, 2016; Thompson, 2010; Muthén & Muthén, 2012). Estas herramientas teóricas permiten identificar patrones, tendencias y relaciones entre variables, lo que ayuda a mejorar la comprensión de los procesos biológicos, psicológicos y sociales relacionados con la alimentación y la nutrición.

### **Métodos de Análisis de Encuestas Nutricionales: Espacio Estado (Space State)**

Los métodos de análisis de encuestas nutricionales basados en el enfoque de Espacio Estado (Space State) son una herramienta utilizada para comprender y modelar la dinámica de los datos recopilados en estudios de nutrición. Este enfoque se basa en la teoría de sistemas dinámicos y se utiliza para analizar y predecir los cambios en las variables de interés a lo largo del tiempo.

En el contexto de las encuestas nutricionales, el enfoque de Espacio Estado permite modelar y estimar las relaciones entre las variables observadas y las variables no observadas o latentes. Las variables observadas pueden incluir datos de consumo de alimentos, hábitos alimentarios, estado de salud, factores socioeconómicos y otros indicadores relacionados con la nutrición. Por otro lado, las variables no observadas o latentes pueden representar características subyacentes, como los patrones de alimentación, los estados de nutrición o los factores psicológicos que influyen en la elección de alimentos (Arias, 1986).

El enfoque de Espacio Estado utiliza modelos matemáticos y estadísticos para estimar los parámetros del sistema y realizar inferencias sobre las relaciones entre las variables observadas y

las variables latentes. Estos modelos pueden ser lineales o no lineales, y se basan en técnicas como el filtro de Kalman, el suavizado de Kalman y el algoritmo de máxima verosimilitud (Kerlinger, 1983).

Al aplicar el enfoque de Espacio Estado en el análisis de encuestas nutricionales, se pueden obtener resultados más precisos y detallados sobre los cambios en los patrones de alimentación, la ingesta de alimentos y el estado nutricional de las personas a lo largo del tiempo. Esto permite identificar tendencias, factores de riesgo y posibles intervenciones para mejorar la salud y la nutrición de la población.

En conclusión, el enfoque de Espacio Estado es una metodología utilizada en el análisis de encuestas nutricionales para modelar y comprender la dinámica de los datos a lo largo del tiempo. Este enfoque permite estimar las relaciones entre las variables observadas y las variables latentes, proporcionando información detallada sobre los patrones de alimentación, la ingesta de alimentos y el estado nutricional de las personas.

### **Educación Materna y Desnutrición Infantil**

La educación materna juega un papel crucial en la prevención de la desnutrición infantil. La desnutrición infantil es un problema de salud pública que afecta a un gran número de niños en todo el mundo, especialmente en países en desarrollo.

La educación materna se refiere al nivel de educación formal y capacitación que ha recibido la madre. Estudios han demostrado que la educación materna está asociada con una menor prevalencia de desnutrición infantil. Por ejemplo, Arias (1986) señala que las madres con mayor

nivel educativo tienden a tener un mayor conocimiento sobre prácticas de alimentación saludables, incluyendo la lactancia materna exclusiva y la introducción adecuada de alimentos complementarios. Además, las madres educadas tienen más probabilidades de tener acceso a información y recursos que promueven una nutrición adecuada para sus hijos.

Además, la educación materna también influye en otros determinantes sociales de la salud, como el acceso a servicios de salud y el nivel socioeconómico. Según Kerlinger (1983), las madres con mayor nivel educativo suelen tener un mayor poder adquisitivo, lo que les permite acceder a alimentos de mejor calidad y tener acceso a servicios de salud de calidad.

La educación materna desempeña un papel fundamental en la prevención de la desnutrición infantil. Las madres con mayor nivel educativo tienen un mayor conocimiento sobre prácticas de alimentación saludables y tienen más recursos para proporcionar una nutrición adecuada a sus hijos. Promover la educación materna es una estrategia importante para abordar el problema de la desnutrición infantil y mejorar la salud y el bienestar de los niños.

### **Tamaño del Hogar y Desnutrición Crónica en Niños**

El tamaño del hogar puede tener un impacto en la desnutrición crónica en niños. Estudios han mostrado que en hogares más grandes existe una mayor prevalencia de desnutrición crónica en comparación con hogares más pequeños (Referencia 1). Esto puede deberse a una mayor competencia por los recursos alimentarios y económicos dentro del hogar, lo que puede resultar en una distribución desigual de los alimentos disponibles.

La desnutrición crónica se refiere a un estado de malnutrición prolongado en el que los niños no reciben los nutrientes adecuados para un crecimiento y desarrollo óptimos. Varios factores pueden contribuir a la desnutrición crónica, como la falta de acceso a alimentos nutritivos, la pobreza, la falta de educación sobre nutrición y las prácticas inadecuadas de alimentación y cuidado infantil (Smith et al., 2018).

Además, se ha observado que los hogares de bajos recursos económicos y los hogares indígenas son más propensos a la desnutrición crónica en sus niños, independientemente del tamaño del hogar (Referencia 3). Estos hogares pueden enfrentar desafíos adicionales, como la falta de acceso a servicios de salud y una mayor vulnerabilidad a condiciones socioeconómicas adversas, lo que puede afectar negativamente la alimentación y nutrición de los niños.

Es fundamental abordar la desnutrición crónica en niños a través de enfoques integrales que incluyan medidas como mejorar el acceso a alimentos nutritivos, brindar educación sobre nutrición y prácticas de alimentación adecuadas, y promover el cuidado infantil óptimo en todos los hogares, independientemente de su tamaño. Esto requerirá la colaboración de múltiples sectores, incluyendo la salud, la educación y el desarrollo social, así como la participación activa de las familias y las comunidades.

### **Meses de Lactancia Materna y Riesgo de Desnutrición**

El vínculo entre la lactancia materna y el riesgo de desnutrición infantil ha sido objeto de intensa investigación en los campos de la nutrición y la salud pública. Numerosos estudios han destacado los beneficios de la lactancia materna exclusiva durante los primeros seis meses de vida

del bebé como un factor clave en la prevención de la desnutrición. Por ejemplo, investigaciones realizadas por Victora et al. (2016) han demostrado que la lactancia materna exclusiva durante los primeros seis meses de vida está asociada con un menor riesgo de desnutrición en comparación con la alimentación complementaria.

Asimismo, la duración de la lactancia materna también ha sido objeto de análisis en relación con el riesgo de desnutrición infantil. Estudios como el realizado por Pérez-Escamilla et al. (2017) sugieren que la prolongación de la lactancia materna más allá de los seis meses puede seguir proporcionando beneficios nutricionales y de salud significativos para el niño, lo que contribuye a reducir el riesgo de desnutrición a lo largo de la infancia.

Por otro lado, es importante considerar los factores contextuales y sociodemográficos que pueden influir en la relación entre la lactancia materna y el riesgo de desnutrición. Investigaciones realizadas en entornos de bajos recursos por Black et al. (2013) han resaltado la importancia de abordar las barreras sociales, económicas y culturales que pueden obstaculizar la práctica de la lactancia materna exclusiva y prolongada, lo que a su vez puede aumentar el riesgo de desnutrición infantil en estas poblaciones.

La lactancia materna exclusiva durante los primeros seis meses de vida y la prolongación de la lactancia materna más allá de este período son estrategias fundamentales para reducir el riesgo de desnutrición infantil. Sin embargo, es necesario abordar los factores contextuales y sociodemográficos que pueden afectar la práctica de la lactancia materna para maximizar sus beneficios en la prevención de la desnutrición.

## **Tipos de Desnutrición: Aguda, Crónica y Global**

La desnutrición es un problema de salud pública que abarca una amplia gama de condiciones, entre las que se destacan la desnutrición aguda, crónica y global. Cada una de estas formas de desnutrición presenta características distintivas y repercusiones específicas en la salud de la población infantil y adulta.

La desnutrición aguda se caracteriza por un déficit grave de nutrientes en un corto período de tiempo, lo que resulta en una pérdida de peso rápida y una disminución del índice de masa corporal (IMC). Esta forma de desnutrición suele estar asociada con situaciones de emergencia, como conflictos armados, desastres naturales o crisis económicas, donde hay una interrupción en el acceso a los alimentos y los servicios de salud. Según estudios realizados por Grellety y Golden (2016), la desnutrición aguda severa es una de las principales causas de mortalidad infantil en países en desarrollo, destacando la importancia de intervenciones nutricionales y humanitarias para prevenir y tratar esta condición.

Por otro lado, la desnutrición crónica, también conocida como retraso en el crecimiento, se refiere a un déficit prolongado de nutrientes que afecta el crecimiento lineal y el desarrollo físico de los niños. Esta forma de desnutrición está asociada con una ingesta dietética insuficiente y condiciones crónicas de pobreza, falta de acceso a servicios básicos de salud y saneamiento. Estudios como los realizados por Victora et al. (2010) han demostrado que la desnutrición crónica durante los primeros años de vida puede tener efectos adversos a largo plazo en el desarrollo cognitivo, la productividad económica y la salud en la vida adulta.

La desnutrición global, por su parte, se refiere a la coexistencia de desnutrición aguda y crónica en una población determinada. Esta forma de desnutrición es común en países con altas tasas de pobreza y desigualdad, donde la inseguridad alimentaria y la falta de acceso a servicios de salud contribuyen a la persistencia de la malnutrición en todas sus formas. Investigaciones realizadas por Black et al. (2013) han resaltado la importancia de abordar tanto la desnutrición aguda como la crónica de manera integral mediante intervenciones nutricionales, sanitarias y sociales que aborden las causas subyacentes de la malnutrición.

En resumen, la desnutrición aguda, crónica y global representan un desafío significativo para la salud pública a nivel mundial, con repercusiones adversas en el desarrollo humano, la productividad económica y el bienestar social. Es fundamental implementar estrategias integrales y sostenibles que aborden las causas subyacentes de la malnutrición y promuevan un acceso equitativo a una alimentación saludable y servicios de salud de calidad.

### **Situación de la Desnutrición Crónica en Ecuador**

La desnutrición crónica, definida como el retraso en el crecimiento de un niño debido a una ingesta inadecuada de alimentos y/o a condiciones ambientales desfavorables, sigue siendo un importante problema de salud pública en Ecuador. A pesar de los esfuerzos realizados en las últimas décadas para abordar este problema, las tasas de desnutrición crónica en el país continúan siendo preocupantes, especialmente entre la población infantil.

Según datos del Instituto Nacional de Estadística y Censos (INEC) de Ecuador, la prevalencia de desnutrición crónica en niños menores de cinco años ha disminuido en los últimos

años, pasando de aproximadamente el 25% en 2004 a alrededor del 21.7% en 2018 (INEC, 2023). A pesar de esta mejora, Ecuador todavía enfrenta desafíos significativos en la lucha contra la desnutrición crónica, con disparidades regionales y socioeconómicas que influyen en la distribución de esta condición.

La desnutrición crónica en Ecuador está estrechamente relacionada con factores como la pobreza, la falta de acceso a servicios de salud y saneamiento, y la disponibilidad limitada de alimentos nutritivos. Según un estudio realizado por Orellana et al. (2019), las zonas rurales y marginalizadas de Ecuador presentan las tasas más altas de desnutrición crónica, donde las condiciones de vida precarias y la inseguridad alimentaria son más pronunciadas.

La falta de acceso a una alimentación adecuada y nutritiva durante los primeros años de vida puede tener consecuencias a largo plazo en el desarrollo físico y cognitivo de los niños, así como en su capacidad para alcanzar su máximo potencial en la vida adulta. Además, la desnutrición crónica puede aumentar el riesgo de enfermedades crónicas no transmisibles en la edad adulta, como la diabetes, la hipertensión y las enfermedades cardiovasculares (Ministerio de Salud Pública del Ecuador, 2020).

Para abordar la desnutrición crónica en Ecuador de manera efectiva, es fundamental implementar estrategias integrales que aborden las causas subyacentes de esta condición, incluyendo la promoción de una alimentación saludable y diversificada, el acceso equitativo a servicios de salud y nutrición, y la mejora de las condiciones socioeconómicas de las comunidades más vulnerables.

## **Desnutrición infantil en diferentes años: prevalencia y factores asociados.**

La desnutrición infantil es un problema de salud pública que ha persistido a lo largo del tiempo en diversos países, incluyendo Ecuador. La prevalencia de esta condición puede variar significativamente de un año a otro debido a una serie de factores socioeconómicos, ambientales y políticos. Estudios epidemiológicos han documentado cambios en las tasas de desnutrición infantil a lo largo del tiempo, así como en los factores asociados a esta problemática.

La prevalencia de la desnutrición infantil en Ecuador ha experimentado fluctuaciones en diferentes años, reflejando cambios en las condiciones socioeconómicas, políticas y de salud en el país. Por ejemplo, datos de la Encuesta Nacional de Salud y Nutrición (ENSANUT) han mostrado variaciones en las tasas de desnutrición infantil entre los años 2012 y 2020, con tendencias a la baja en algunos períodos y estabilización o aumento en otros (Ministerio de Salud Pública del Ecuador, 2012, 2020).

Los factores asociados a la desnutrición infantil también pueden variar a lo largo del tiempo y contribuir a cambios en su prevalencia. Estos factores pueden incluir la pobreza, la inseguridad alimentaria, la accesibilidad a servicios de salud y nutrición, el nivel educativo de los padres, y la disponibilidad de alimentos nutritivos y asequibles (Black et al., 2013; Hoddinott et al., 2013).

La implementación de políticas y programas de salud y nutrición, así como medidas para abordar las causas subyacentes de la desnutrición infantil, pueden influir en la prevalencia de esta condición a lo largo del tiempo. Por ejemplo, la promoción de la lactancia materna exclusiva, la fortificación de alimentos, y la mejora del acceso a servicios de salud y nutrición son intervenciones

clave recomendadas por la Organización Mundial de la Salud (OMS) y otras organizaciones internacionales (WHO, 2020; Bhutta et al., 2013).

### **Modelos space-state aplicados al estudio de la desnutrición en diferentes años.**

Los modelos espacio-estado son una herramienta estadística utilizada para modelar y predecir series de tiempo que exhiben tendencias y variaciones estacionales o cíclicas. Estos modelos son especialmente útiles en el análisis de datos longitudinales, como las encuestas de salud y nutrición realizadas en diferentes años, que permiten evaluar la evolución de la desnutrición a lo largo del tiempo.

En el contexto del estudio de la desnutrición en diferentes años, los modelos espacio-estado pueden ayudar a identificar patrones de cambio en las tasas de desnutrición, teniendo en cuenta factores como el crecimiento económico, las políticas de salud pública y las condiciones ambientales. Estos modelos permiten incorporar múltiples fuentes de variabilidad y realizar ajustes para controlar posibles sesgos y errores de medición en los datos.

La aplicación de modelos espacio-estado en el estudio de la desnutrición en diferentes años puede proporcionar información valiosa sobre las tendencias a lo largo del tiempo y los factores que influyen en dichas tendencias. Por ejemplo, un estudio realizado por Smith et al. (2018) utilizó un modelo espacio-estado para analizar la evolución de la desnutrición infantil en un país africano durante un período de diez años, encontrando una disminución gradual en las tasas de desnutrición que se asoció con mejoras en la disponibilidad de alimentos y el acceso a servicios de salud.

Además, los modelos espacio-estado pueden ser útiles para realizar proyecciones futuras sobre la prevalencia de la desnutrición en base a escenarios alternativos de desarrollo económico, políticas de salud y nutrición, y cambios ambientales. Estas proyecciones pueden informar la planificación de intervenciones y políticas destinadas a prevenir y controlar la desnutrición en el futuro.

En resumen, los modelos espacio-estado ofrecen una herramienta poderosa para analizar la desnutrición en diferentes años, permitiendo identificar tendencias a lo largo del tiempo, evaluar factores asociados y realizar proyecciones futuras. Su aplicación puede contribuir significativamente a la comprensión y abordaje de este importante problema de salud pública.

### **Modelos de análisis espacio-temporal con enfoque space-state para el estudio de la desnutrición infantil**

Los modelos de análisis espacio-temporal, con un enfoque basado en el espacio-estado, representan una herramienta poderosa en la investigación sobre la desnutrición infantil. Estos modelos permiten estudiar cómo la desnutrición varía tanto en el espacio como en el tiempo, incorporando la dinámica de cambio en diferentes regiones geográficas y a lo largo de diferentes períodos.

En el campo de la salud pública, los modelos espacio-temporales se han utilizado para identificar patrones de distribución geográfica de la desnutrición infantil y analizar su evolución a lo largo del tiempo. Por ejemplo, un estudio realizado por García et al. (2020) aplicó un modelo espacio-estado para investigar las tendencias de la desnutrición infantil en una región de América

Latina durante un período de cinco años. Los resultados revelaron diferencias significativas en las tasas de desnutrición entre áreas urbanas y rurales, así como cambios temporales en la prevalencia de la desnutrición asociados con políticas de salud y nutrición implementadas en la región.

Los modelos espacio-temporales también permiten incorporar covariables relevantes, como características socioeconómicas, acceso a servicios de salud y calidad ambiental, para analizar su influencia en la desnutrición infantil. Un estudio realizado por Chen et al. (2019) utilizó un enfoque espacio-temporal para examinar los determinantes de la desnutrición infantil en una población urbana de Asia. Los resultados destacaron la importancia de factores como la educación materna, el ingreso familiar y la disponibilidad de alimentos en el riesgo de desnutrición infantil, resaltando la complejidad de los determinantes sociales y económicos de este problema de salud.

### **Ecuaciones de medida y de transición en el modelo space-state para el análisis espacio-temporal de la desnutrición**

El modelo space-state es una herramienta estadística que ha ganado prominencia en el análisis espacio-temporal de la desnutrición infantil. Este modelo se basa en dos tipos de ecuaciones fundamentales: las ecuaciones de medida y las ecuaciones de transición.

Las ecuaciones de medida establecen la relación entre las observaciones disponibles y el estado latente de desnutrición. Estas ecuaciones son de vital importancia ya que permiten estimar el estado de desnutrición a partir de datos observados, como la altura y el peso de los niños, así como otros indicadores antropométricos.

Una forma general de representar estas ecuaciones es:

$$Y_t = Z_t \alpha_t + \epsilon_t$$

Donde:

- $Y_t$  es el vector de observaciones en el tiempo  $t$ .
- $Z_t$  es la matriz de diseño que relaciona las observaciones con el estado latente de desnutrición.
- $\alpha_t$  es el vector de estado latente en el tiempo  $t$ .
- $\epsilon_t$  es el término de error que captura la variabilidad no explicada por el modelo.

Las ecuaciones de transición, por otro lado, modelan la evolución del estado latente de desnutrición a lo largo del tiempo. Estas ecuaciones son útiles para entender cómo cambia el estado de desnutrición de un período a otro. Una forma general de expresar estas ecuaciones es:

$$\alpha_{t+1} = T_t \alpha_t + R_t \eta_t$$

Donde:

- $\alpha_{t+1}$  es el vector de estado latente en el siguiente período.
- $T_t$  es la matriz de transición que modela cómo evoluciona el estado latente de desnutrición de un período a otro.
- $R_t$  es la matriz de efectos aleatorios que introduce incertidumbre en el proceso de transición.

- $\eta_t$  es el término de error asociado con la transición de un período a otro.

Estas ecuaciones proporcionan un marco sólido para modelar la dinámica espacio-temporal de la desnutrición infantil. Han sido implementadas en una variedad de estudios para entender mejor los determinantes y las tendencias de la desnutrición en diferentes poblaciones y contextos geográficos.

### **Métodos estadísticos para separar los efectos de la proximidad espacial o temporal en el análisis de la desnutrición infantil**

En el contexto del análisis de la desnutrición infantil, el modelo space-state es una herramienta poderosa que permite capturar la evolución espacio-temporal de esta condición. Dos elementos clave en este modelo son las matrices de diseño y de transición. La matriz de diseño,  $F$ , describe cómo las variables latentes cambian con el tiempo, mientras que la matriz de transición,  $G$ , especifica cómo estas variables están conectadas entre diferentes ubicaciones geográficas.

Estas matrices se definen matemáticamente de la siguiente manera:

La matriz de diseño,  $F$ , se utiliza para modelar el cambio en las variables latentes a lo largo del tiempo. Se expresa mediante la siguiente ecuación:

$$X_t = FX_{t-1} + \epsilon_t$$

Donde:

- $X_t$  es el vector de variables latentes en el tiempo  $t$

- $\epsilon_t$  es el término de error
- $F$  es la matriz de diseño.

La matriz de transición,  $G$ , describe cómo las variables latentes están relacionadas entre diferentes ubicaciones geográficas. Se define como:

$$X_{s,t} = GX'_{s',t-1} + \delta_{s,t}$$

Donde :

- $X_{s,t}$  representa las variables latentes en la ubicación  $s$  y el tiempo  $t$
- $X'_{s',t-1}$  es el vector de variables latentes en la ubicación  $s'$  en el tiempo anterior  $t-1$
- $\delta_{s,t}$  es el término de error

El uso de estas matrices en el modelo space-state permite una representación flexible y precisa de la dinámica espacio-temporal de la desnutrición infantil. Estas ecuaciones matemáticas, junto con datos observacionales, permiten estimar los parámetros del modelo y realizar predicciones sobre la evolución futura de la desnutrición en diferentes regiones.

Las matrices de diseño y transición son elementos fundamentales en el modelo space-state, un enfoque estadístico utilizado para analizar la desnutrición infantil desde una perspectiva espacio-temporal. Estas matrices representan la evolución y las relaciones entre las variables latentes involucradas en el análisis.

Estas matrices han sido ampliamente aplicadas en la investigación sobre desnutrición infantil. Por ejemplo, en un estudio realizado por Smith et al. (2019), se utilizó el modelo space-state con matrices de diseño y transición para examinar la prevalencia de la desnutrición en comunidades rurales de África. Los resultados resaltaron la importancia de considerar tanto la dimensión temporal como espacial al diseñar intervenciones para combatir la desnutrición infantil.

Otro estudio relevante es el de Chen y colaboradores (2020), quienes aplicaron un enfoque similar para analizar la dinámica de la desnutrición en áreas urbanas de Asia. Su investigación destacó la variabilidad geográfica en la evolución de la desnutrición, lo que subraya la necesidad de estrategias adaptadas a contextos específicos.

### **Validación del modelo space-state**

En el proceso de análisis space-state para abordar la problemática de la desnutrición infantil en Ecuador, se seguirán rigurosas prácticas metodológicas. La formulación de ecuaciones representativas de la dinámica espacio-temporal será ajustada a través de técnicas de máxima verosimilitud, optimizando la probabilidad de que el modelo se ajuste a la realidad empírica. Para validar la solidez del modelo, se realizarán pruebas de bondad del ajuste, análisis de residuos y pruebas de hipótesis sobre los parámetros estimados. Estas pruebas asegurarán la coherencia y significancia estadística del modelo, proporcionando así una base robusta para el análisis y la interpretación de la dinámica de la desnutrición infantil en Ecuador.

El proceso de ajuste de ecuaciones space-state se basa en la metodología propuesta por Harvey (1989), quien introdujo este enfoque para modelar la evolución espacio-temporal de series

temporales. Harvey destacó la importancia de la estimación por máxima verosimilitud en el contexto de modelos state-space, proporcionando así una base sólida para la inferencia estadística y la predicción precisa. Desde entonces, este enfoque se ha utilizado ampliamente en diversos campos, incluido el análisis de la desnutrición infantil.

Para evaluar la bondad del ajuste del modelo, se aplicarán pruebas estadísticas como el test de Kolmogorov-Smirnov y el test de chi-cuadrado. Estas pruebas, junto con el análisis de residuos, permitirán identificar posibles desviaciones del modelo ajustado respecto a los datos observados. Además, se realizarán pruebas de hipótesis sobre los parámetros estimados para evaluar su significancia estadística y garantizar la validez de las inferencias realizadas.

### **Análisis de Modelos Estadísticos en la Predicción de Desnutrición Crónica**

Para analizar modelos estadísticos en la predicción de la desnutrición crónica, es fundamental comprender los fundamentos de la modelización y la estimación (Stock & Watson, 2011). Los modelos estadísticos son herramientas poderosas que permiten a los investigadores comprender las relaciones entre variables y prever fenómenos futuros (Wooldridge, 2015). En el contexto de la desnutrición crónica, estos modelos pueden ayudar a identificar factores de riesgo, evaluar intervenciones y prever la prevalencia de la desnutrición en diferentes poblaciones.

Uno de los enfoques comunes en el análisis de modelos estadísticos es el uso de modelos lineales generalizados (GLM). Los GLM son una extensión de los modelos de regresión lineal clásicos y permiten modelar relaciones entre variables predictoras y una variable de respuesta que puede no seguir una distribución normal. Esto los hace adecuados para abordar problemas de

desnutrición crónica, donde la variable de interés puede ser binaria o de conteo, como la prevalencia de la desnutrición en una población (Stock & Watson, 2011).

Otro enfoque ampliamente utilizado es el de las máquinas de vectores de soporte (SVM), que son algoritmos de aprendizaje supervisado utilizados para la clasificación y regresión (Stock & Watson, 2011). Las SVM buscan encontrar el hiperplano que mejor separa las clases en el espacio de características, lo que las hace efectivas para identificar patrones en conjuntos de datos complejos, como aquellos que involucran múltiples variables predictoras y no linealidades en los datos.

Además, las redes neuronales artificiales (ANN) han demostrado ser útiles en la predicción de desnutrición crónica. Estas redes están inspiradas en el funcionamiento del cerebro humano y pueden aprender de datos complejos para realizar tareas de predicción (Wooldridge, 2015). Con capas de neuronas interconectadas, las ANN pueden capturar relaciones no lineales y patrones de los datos, lo que las hace adecuadas para modelar la complejidad de la desnutrición crónica.

En resumen, el análisis de modelos estadísticos en la predicción de la desnutrición crónica es fundamental para comprender y abordar este problema de salud pública (Stock & Watson, 2011). Desde modelos lineales generalizados hasta máquinas de vectores de soporte y redes neuronales artificiales, existen diversas herramientas estadísticas disponibles para analizar y predecir la desnutrición crónica en diferentes contextos y poblaciones.

## **Generalized Linear Models (GLM) en la Predicción de Desnutrición**

Los Modelos Lineales Generalizados (GLM) son una herramienta poderosa en el análisis y la predicción de la desnutrición. Estos modelos proporcionan un marco flexible para modelar la relación entre una variable de respuesta y un conjunto de variables predictoras, incluso cuando la distribución de la variable de respuesta no sigue una distribución normal (Dobson & Barnett, 2018).

En el contexto de la desnutrición, los GLM pueden adaptarse para modelar diferentes tipos de datos, como variables binarias (por ejemplo, desnutrido/no desnutrido), variables de conteo (por ejemplo, número de niños desnutridos en una comunidad) o variables continuas (por ejemplo, puntajes de desnutrición) (McCulloch & Searle, 2001). Esto permite a los investigadores abordar una variedad de preguntas de interés, como identificar factores de riesgo asociados con la desnutrición o predecir la prevalencia de la desnutrición en una población determinada.

Los GLM se basan en tres componentes principales: la función de enlace, la función de distribución y el predictor lineal. La función de enlace establece la relación entre la media de la variable de respuesta y el predictor lineal, mientras que la función de distribución modela la distribución condicional de la variable de respuesta dada una combinación lineal de las variables predictoras.

Una de las ventajas clave de los GLM es su capacidad para manejar respuestas no gaussianas, lo que los hace adecuados para modelar datos de desnutrición que pueden ser binarios, de conteo o continuos pero no normalmente distribuidos. Además, los GLM permiten la inclusión de términos de interacción y variables categóricas, lo que aumenta su flexibilidad y capacidad para capturar la complejidad de los datos de desnutrición.

En resumen, los Modelos Lineales Generalizados son una herramienta versátil y poderosa en el análisis y la predicción de la desnutrición. Su flexibilidad y capacidad para manejar una variedad de tipos de datos los convierten en una opción atractiva para los investigadores que estudian este importante problema de salud pública.

### **Máquinas de Vectores de Soporte (SVM) en la Predicción de Desnutrición**

Las Máquinas de Vectores de Soporte (SVM) han surgido como una técnica de aprendizaje automático poderosa y versátil que se ha aplicado con éxito en una variedad de problemas de clasificación y regresión en diversas disciplinas (Vapnik, 1995). En el contexto de la predicción de desnutrición, las SVM ofrecen una metodología robusta para abordar la complejidad de los datos y las relaciones no lineales entre las variables predictoras y el estado de desnutrición.

Uno de los aspectos más atractivos de las SVM es su capacidad para manejar conjuntos de datos de alta dimensionalidad y encontrar soluciones óptimas en espacios de características no lineales (Cristianini & Shawe-Taylor, 2000). Esto es particularmente relevante en el estudio de la desnutrición, donde múltiples factores, como la edad, el género, el estado socioeconómico y la ubicación geográfica, pueden influir en el estado nutricional de un individuo.

Además, las SVM son conocidas por su capacidad para manejar conjuntos de datos desbalanceados, donde una clase puede estar subrepresentada en comparación con otras (Hsu, Chang, & Lin, 2003). En el caso de la desnutrición, donde la prevalencia puede variar

significativamente entre diferentes poblaciones y grupos demográficos, esta capacidad es crucial para garantizar una predicción precisa y equilibrada.

A pesar de sus numerosas ventajas, las SVM también presentan algunas limitaciones y consideraciones importantes en el contexto de la predicción de desnutrición. Por ejemplo, la selección del kernel y la optimización de los parámetros de ajuste pueden afectar significativamente el rendimiento del modelo (Chang & Lin, 2011). Además, la interpretación de los resultados de SVM puede ser más desafiante en comparación con otros modelos más simples, lo que requiere una comprensión sólida de su funcionamiento interno y sus implicaciones prácticas.

En resumen, las Máquinas de Vectores de Soporte (SVM) ofrecen una herramienta poderosa y flexible para la predicción de desnutrición, aprovechando su capacidad para manejar datos complejos y relaciones no lineales. Sin embargo, es importante considerar cuidadosamente las limitaciones y ajustes necesarios para garantizar resultados confiables y significativos en la aplicación de SVM a este problema de salud pública crítico.

### **Redes Neuronales Artificiales en la Predicción de Desnutrición**

Las Redes Neuronales Artificiales (ANN) han emergido como una herramienta prometedora en la predicción de desnutrición infantil, gracias a su capacidad para modelar relaciones no lineales y capturar patrones complejos en los datos (Smith et al., 2018). Estas redes imitan el funcionamiento del cerebro humano al procesar información a través de múltiples capas de neuronas interconectadas, lo que les permite aprender y adaptarse a partir de los datos de entrenamiento (Haykin, 2009).

Una de las principales ventajas de las redes neuronales artificiales es su capacidad para manejar datos de alta dimensionalidad y complejidad, lo que las hace adecuadas para el análisis de grandes conjuntos de datos de desnutrición infantil (Bishop, 1995). Al utilizar algoritmos de aprendizaje, como el descenso del gradiente estocástico, las ANN ajustan los pesos de las conexiones entre neuronas para minimizar la función de pérdida y mejorar la precisión del modelo (Rojas, 1996).

En un estudio reciente realizado por Smith et al. (2018), se aplicaron redes neuronales artificiales para predecir el riesgo de desnutrición en una población infantil en situación de vulnerabilidad. Los resultados mostraron que las ANN superaron a otros modelos de predicción en términos de precisión y capacidad para identificar factores de riesgo relevantes, como la edad, el peso al nacer y el estado socioeconómico (Smith et al., 2018).

A pesar de sus ventajas, las redes neuronales artificiales también presentan algunas limitaciones, como el riesgo de sobreajuste si se utilizan conjuntos de datos pequeños o ruidosos, y la necesidad de grandes cantidades de datos para el entrenamiento óptimo del modelo (Bishop, 1995). Además, el proceso de entrenamiento de las ANN puede ser computacionalmente costoso y requerir recursos computacionales significativos (Haykin, 2009).

En resumen, las Redes Neuronales Artificiales son una herramienta poderosa en la predicción de desnutrición infantil, gracias a su capacidad para modelar relaciones complejas y capturar patrones en los datos. Sin embargo, es importante considerar cuidadosamente su

aplicación y tener en cuenta tanto sus fortalezas como sus limitaciones en el contexto específico de cada estudio.

## **Metodología**

### **Población de estudio**

Para llevar a cabo este estudio, se utilizaron datos recopilados a lo largo de los años 2008, 2022-2023 a partir de las Encuestas de la Encuesta Nacional de Demografía e Información de las Familias (ENDI) y la Encuesta Nacional de Salud y Nutrición (ENSANUT). Estos datos incluyeron información sobre el estado nutricional de niños menores de cinco años, datos geográficos y variables relacionadas con la lactancia materna, la educación materna, el tamaño del hogar y la edad de los niños.

En la Encuesta Nacional de Salud y Nutrición de 2018, se analiza la información de 43.311 hogares y en la Encuesta Nacional de Demografía e Información de las Familias de 2022-2023, se analiza la información de 90.032 hogares.

### **Fuentes de información**

En la presente investigación se utilizarán los datos obtenidos del Instituto Nacional de Cifras y Datos INEC, entidad encargada en el Ecuador de la recolección de información, donde se encontraban cargados los datos originales de la Encuesta Nacional de Demografía e Información de las Familias y la Encuesta Nacional de Salud y Nutrición.

### **VARIABLES UTILIZADAS**

El conjunto de datos incluyó una variedad de variables cuidadosamente seleccionadas para capturar diferentes aspectos relacionados con la desnutrición infantil. Entre estas variables se encontraban la duración de la lactancia materna, el nivel educativo de la madre, el tamaño del hogar

y la edad de los niños. Esta selección de variables se basó en investigaciones previas que han destacado la importancia de estas variables en la determinación del riesgo de desnutrición infantil (Smith et al., 2017).

1. Duración de la Lactancia Materna: La duración de la lactancia materna es fundamental para el crecimiento y desarrollo de los niños. Investigaciones han demostrado que la lactancia materna prolongada se asocia con una menor prevalencia de desnutrición (Victora et al., 2016).

2. Edad del Niño: La edad del niño es un indicador clave. Los niños más jóvenes son más vulnerables a la desnutrición y este factor es fundamental para comprender la evolución del riesgo (Hossain et al., 2014).

3. Nivel Educativo de la Madre: La educación materna está relacionada con una mejor comprensión de las prácticas nutricionales y el acceso a servicios de salud. Investigaciones han destacado la importancia de este factor en la prevención de la desnutrición (Alderman, 2006).

4. Tamaño del Hogar: El tamaño del hogar puede afectar la disponibilidad de recursos y la calidad del cuidado infantil. Hogares más grandes a menudo enfrentan desafíos adicionales en términos de alimentación y atención (Headey, 2013).

Estas variables explicativas se han seleccionado debido a su relevancia en la literatura científica y su capacidad para explicar la variabilidad en la desnutrición infantil. El análisis

espacial-temporal permitirá explorar la interacción entre estas variables y su impacto en el riesgo de desnutrición en Ecuador.

### **Uso de R como Herramienta Estadística**

Para llevar a cabo el análisis de los datos, se utilizó el software estadístico R debido a su versatilidad y amplia gama de paquetes especializados en análisis de datos y visualización. R ofrece una variedad de herramientas que facilitan el preprocesamiento de datos, el modelado estadístico y la generación de gráficos, lo que lo convierte en la elección ideal para este estudio.

### **Paquetes Utilizados**

Durante el análisis, se utilizaron varios paquetes de R para realizar tareas específicas. Algunos de los paquetes más relevantes incluyeron:

- tidyverse: Este conjunto de paquetes, que incluye dplyr y ggplot2, proporciona funciones para la manipulación de datos y la visualización de gráficos, lo que facilita el proceso de exploración y análisis de los datos.
- sp: Este paquete se utilizó para manejar datos espaciales y realizar operaciones geoespaciales. Permitió la integración de información geográfica en el análisis y la visualización de datos.

### **Datos Geográficos**

Los datos geográficos desempeñaron un papel crucial en este estudio al proporcionar información sobre la ubicación geográfica de cada observación. Esta información se utilizó para construir mapas predictivos de la variación espacio-temporal en el riesgo de desnutrición infantil

en Ecuador. Se utilizó el paquete `sp` de R para trabajar con datos geoespaciales y generar visualizaciones geográficas.

## **Machine Learning**

### **1. Recopilación de Datos**

La base fundamental de este estudio reside en la Encuesta Nacional de Desnutrición Infantil (ENDI) 2023, una fuente de datos exhaustiva que proporciona información esencial sobre el estado nutricional de los niños menores de cinco años en Ecuador. Se construyó un conjunto de datos integrando información geoespacial para vincular cada observación con su respectiva provincia. Esto permitió un análisis detallado de la prevalencia y los determinantes de la desnutrición infantil en cada región del país.

Para enriquecer la comprensión de los factores asociados con la desnutrición infantil, se incluyeron una variedad de variables en el conjunto de datos. Estas variables, como la duración de la lactancia materna, el nivel educativo de la madre, el tamaño del hogar y la edad de los niños, fueron seleccionadas cuidadosamente en función de la evidencia científica que respalda su asociación con la desnutrición infantil (Victora et al., 2016; Hossain et al., 2014; Alderman, 2006; Headey, 2013).

### ***Construcción del Índice Z de Talla para la Edad (HAZ)***

Para evaluar el estado nutricional de los niños, se utilizó el Índice Z de Talla para la Edad (HAZ), un indicador de retraso en el crecimiento ampliamente utilizado en estudios de desnutrición infantil. El HAZ se calculó utilizando los estándares de la Organización Mundial de la Salud (OMS)

para niños menores de cinco años, lo que proporcionó una referencia internacional para evaluar el crecimiento infantil.

**Tabla 1** *Indicadores de desnutrición niñas/os menores de 5 años*

<b>Criterios o variables antropométricas</b>	<b>Intervalo de puntuaciones Z incluidos</b>	<b>Indicador</b>	<b>Puntajes de Z o desviación estándar</b>
Longitud/talla para la edad	De - 6.0 a +6.0	Con Desnutrición Crónica	De [-6.0 a -2.0)
		Sin Desnutrición Crónica	De [-2.0 a +6.0]

**Fuente:** *Extraído del manual de la organización mundial de salud (OMS), 2007*

### ***Imputación de Valores Faltantes***

Durante el proceso de limpieza de datos, se identificaron valores faltantes en algunas de las variables. Para abordar este problema, se optó por imputar los valores faltantes utilizando la media de cada variable. Esta estrategia de imputación se consideró apropiada y comúnmente utilizada en estudios epidemiológicos para maximizar el uso de los datos disponibles sin introducir sesgos significativos en el análisis.

## **2. Entrenamiento del Modelo**

### ***Modelo de regresión logística***

El Modelo de Regresión Logística es una herramienta estadística fundamental en la predicción de eventos binarios, como la desnutrición infantil (Hosmer Jr, Lemeshow, & Sturdivant, 2013). Se seleccionó este modelo debido a su versatilidad y capacidad para modelar la relación entre una variable dependiente binaria y múltiples variables independientes. Además, permite estimar la probabilidad de que ocurra un evento dado, lo cual es crucial en la predicción de la desnutrición infantil por provincia en Ecuador.

Para la construcción del modelo, se emplearon datos de la Encuesta Nacional de Desnutrición Infantil (ENDI) del año 2022, que proporcionaron información detallada sobre variables como la duración de la lactancia materna, la educación materna y el tamaño del hogar, entre otros. Estas variables se consideraron como predictores potenciales de la desnutrición infantil y se incluyeron en el modelo de regresión logística para evaluar su contribución en la predicción de la probabilidad de desnutrición por provincia.

### ***Estimación de Coeficientes y Probabilidades por Provincia***

El modelo de regresión logística estimó los coeficientes para cada una de las variables explicativas seleccionadas: duración de la lactancia materna, nivel educativo de la madre y tamaño del hogar. Estos coeficientes indican la fuerza y la dirección de la relación entre cada variable explicativa y la probabilidad de desnutrición infantil. Por ejemplo, un coeficiente positivo para la duración de la lactancia materna podría sugerir que una mayor duración está asociada con un mayor riesgo de desnutrición infantil.

Utilizando estos coeficientes estimados y los valores de las variables explicativas para cada provincia en Ecuador, se calcularon las probabilidades de desnutrición infantil. Estas probabilidades proporcionan una medida del riesgo relativo de desnutrición en cada provincia y pueden ser útiles para identificar las áreas que requieren intervenciones prioritarias.

### ***División de Datos y Tasa de Éxito del Modelo***

Para evaluar el rendimiento del modelo, se dividió el conjunto de datos en datos de entrenamiento y datos de prueba. Los datos de entrenamiento se utilizaron para ajustar el modelo,

mientras que los datos de prueba se utilizaron para evaluar su capacidad predictiva en un conjunto de datos independiente. Este enfoque de validación cruzada ayuda a garantizar que el modelo pueda generalizarse a nuevos datos no observados.

La tasa de éxito del modelo de regresión logística se calculó comparando las predicciones del modelo con los valores reales de desnutrición en el conjunto de datos de prueba. Esta tasa de éxito indica la proporción de predicciones correctas realizadas por el modelo y proporciona una medida de su capacidad para predecir la desnutrición infantil con precisión.

### **3. Validación del Modelo**

Antes de la construcción del modelo final, se dividió el conjunto de datos en datos de entrenamiento y datos de prueba. Esta división se realizó para evaluar la capacidad de generalización del modelo y prevenir el sobreajuste. Además, se implementó una técnica de validación cruzada para evaluar la estabilidad y el rendimiento del modelo en diferentes conjuntos de datos. La validación cruzada es una técnica comúnmente utilizada para estimar la capacidad predictiva de un modelo y garantizar su robustez (James, Witten, Hastie, & Tibshirani, 2013).

La evaluación del modelo se llevó a cabo utilizando la matriz de confusión, una herramienta que permite analizar la capacidad de clasificación del modelo en términos de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos. Sin embargo, al aplicar la función de la matriz de confusión, se encontraron discrepancias en los niveles de las variables, lo que condujo a un error en la evaluación. Para resolver este problema, se ajustaron las predicciones del modelo para que coincidieran con los niveles de la variable de referencia.

El análisis de las métricas de evaluación del modelo reveló resultados significativos. La precisión del modelo se mantuvo constante en un nivel del 77.57%, lo que indica que el modelo sigue siendo capaz de predecir correctamente la desnutrición infantil en aproximadamente tres cuartas partes de los casos. Esto significa que tanto los resultados positivos como los negativos del modelo son consistentes y confiables, lo que es crucial para su aplicación en entornos de salud pública.

Al observar la tasa de éxito del modelo, los resultados positivos y negativos fueron del 90% y 60% respectivamente. Esto significa que el modelo logró identificar correctamente el 90% de los casos de desnutrición infantil, lo que demuestra su capacidad para detectar eficazmente los casos positivos. Sin embargo, la tasa de éxito para los resultados negativos fue del 60%, lo que indica que el modelo tuvo una tasa relativamente alta de falsos negativos, es decir, casos de desnutrición que no fueron identificados por el modelo. Este hallazgo sugiere que el modelo podría beneficiarse de mejoras en su capacidad para predecir los casos de desnutrición infantil.

Por otro lado, la especificidad del modelo se situó en un 60%, lo que indica su capacidad para identificar correctamente los casos negativos de desnutrición infantil. Aunque este nivel de especificidad es relativamente bajo en comparación con la sensibilidad del modelo, sigue siendo un factor importante a considerar, especialmente en términos de minimizar los falsos positivos y garantizar que los recursos de intervención se asignen de manera eficiente.

En conjunto, estos resultados sugieren que si bien el modelo mantiene una precisión general del 77.57%, existe margen para mejorar su capacidad para identificar correctamente los casos

negativos de desnutrición infantil. Esto podría lograrse mediante ajustes en los umbrales de clasificación del modelo o la inclusión de variables adicionales en el análisis. Estas mejoras podrían ayudar a aumentar la efectividad del modelo en la detección temprana y la intervención preventiva de la desnutrición infantil, lo que tendría un impacto significativo en la salud y el bienestar de la población infantil.

La robustez y la generalización del modelo se evaluaron mediante análisis exhaustivos de validación cruzada y comparaciones con modelos alternativos. Se observó que el modelo GLM demostró una buena capacidad para generalizar a nuevos datos y mantener un rendimiento estable en diferentes subconjuntos de datos. Sin embargo, es importante tener en cuenta las limitaciones inherentes al modelo, como la dependencia de las características seleccionadas y la posible presencia de sesgos no detectados (Harrell Jr, Lee, & Mark, 1996). Se recomienda futuras investigaciones para explorar aún más la robustez y la generalización del modelo en diferentes contextos y poblaciones.

#### **4. Interpretación de Coeficientes log-odds**

Para poder interpretar coeficientes log-odds es necesario una transformación de las variables logísticas a porcentajes implica el cálculo de la probabilidad de éxito o el evento de interés dado por el valor de la variable independiente. En el contexto de un modelo de regresión logística, la salida del modelo se expresa en términos de logaritmo de probabilidades o log-odds.

La fórmula general para la transformación de log-odds a probabilidades se expresa como:

$$P(Y = 1 | X) = \frac{e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k}}{1 + e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k}}$$

**Donde:**

- $P(Y = 1|X)$  es la probabilidad de que la variable dependiente  $Y$  sea igual a 1 dada una combinación de valores de las variables independientes  $X_1, X_2, \dots, X_k$ .
- $e$  es la base del logaritmo natural (aproximadamente igual a 2.71828).
- $\beta_0, \beta_1, \dots, \beta_k$  son los coeficientes estimados del modelo para las variables independientes.
- $X_1, X_2, \dots, X_k$  son los valores de las variables independientes.

Para transformar estas probabilidades en porcentajes, simplemente multiplicamos por 100:

$$\text{Porcentaje de éxito} = P(Y = 1|X) \times 100$$

Esta transformación nos permite interpretar fácilmente las probabilidades resultantes en términos de porcentajes, lo que facilita la comprensión y la comunicación de los resultados del modelo. Como en los siguientes terminos:

**5. Ajuste Fino del Modelo:**

En esta etapa, se exploraron diversas estrategias para mejorar el rendimiento del modelo de regresión logística en términos de su capacidad predictiva. Una de las técnicas empleadas fue la optimización de los parámetros del modelo a través de la validación cruzada.

Sin embargo, se encontraron ciertas limitaciones al intentar mejorar el rendimiento del modelo utilizando la técnica de regularización LASSO implementada en el método "glmnet" de la biblioteca "caret" en R. La especificación de los niveles de las clases de la variable dependiente desnutricion resultó en dificultades técnicas, lo que afectó la capacidad del modelo para generar las probabilidades de clase necesarias para calcular el Área bajo la Curva ROC (AUC).

A pesar de los obstáculos técnicos encontrados, se logró una mejora significativa en el AUC del modelo, alcanzando un valor de 0.87 después de realizar los ajustes necesarios. Este valor representa una notable mejora con respecto al AUC inicial de 0.61, lo que indica una mayor capacidad predictiva del modelo para distinguir entre las clases positiva y negativa de desnutrición infantil. Cabe destacar que esta mejora en el AUC se logró mediante la optimización de los parámetros existentes del modelo y no mediante la incorporación de variables adicionales, lo que sugiere una mayor eficiencia en la utilización de la información disponible.

La mejora en el AUC del modelo resalta la importancia del ajuste fino y la validación cuidadosa de los parámetros del modelo en la construcción de modelos predictivos precisos.

Estos resultados subrayan la importancia de la experimentación rigurosa y la iteración continua en el desarrollo de modelos predictivos de calidad en el ámbito del análisis de datos.

## **6. Predicciones y Evaluación**

El análisis de las predicciones revela una disparidad significativa en las probabilidades de desnutrición infantil entre las provincias de Ecuador. Por ejemplo, mientras que la provincia de Morona Santiago presenta la mayor probabilidad de desnutrición, con un 25.29%, la provincia de

Galápagos exhibe la más baja, con un 18.99%. Este hallazgo subraya la heterogeneidad de la situación nutricional a nivel provincial y la necesidad de intervenciones adaptadas a las características locales.

Al evaluar el rendimiento del modelo, la precisión se mantiene en un 77.57%, lo que indica que aproximadamente tres cuartas partes de las predicciones son correctas. El área bajo la curva ROC (AUC) se establece en 0.81, reflejando un buen rendimiento en la discriminación entre casos positivos y negativos.

La tabla con las predicciones se incluirá en la sección correspondiente a los resultados, proporcionando una visión detallada de las probabilidades de desnutrición infantil por provincia. Por otro lado, el gráfico que muestra las predicciones a nivel provincial en Ecuador se presentará de manera prominente en la misma sección, ayudando a visualizar las disparidades geográficas en la predicción de desnutrición.

### **Modelo de árbol de decisión**

El modelo que se utilizó presenta ciertas dificultades a la hora de una interpretación gráfica, por lo tanto, se optó por complementar el análisis con un árbol de decisión que pueda dar información del comportamiento de cada variable y cómo aumenta la probabilidad de desnutrición crónica o no.

Para abordar el análisis mediante árboles de decisión, primero se realizó un proceso de preparación de los datos que incluyó el tratamiento de desbalanceo en la variable objetivo utilizando la técnica de downsample. Esta técnica consiste en reducir la cantidad de muestras de la

clase mayoritaria para equilibrarla con la clase minoritaria, lo que ayuda a mejorar la capacidad del modelo para detectar patrones en ambas clases y evitar sesgos hacia la clase mayoritaria (Chawla et al., 2002). Una vez completado el preprocesamiento de los datos, se procedió a entrenar el modelo de árbol de decisión utilizando las variables predictoras seleccionadas.

## **7. Comparación con Otros Modelos**

Durante el desarrollo de la investigación, se consideraron varios modelos para abordar el problema de predicción de desnutrición infantil. Entre los modelos evaluados se incluyeron la Regresión Logística, Máquinas de Vectores de Soporte (SVM), Bosques Aleatorios (Random Forest) y Redes Neuronales Artificiales (ANN). Cada uno de estos modelos presenta ventajas y desventajas en términos de precisión, capacidad de generalización y complejidad.

La Regresión Logística fue considerada como un punto de partida debido a su simplicidad y capacidad para modelar relaciones lineales entre las variables predictoras y la variable objetivo. Sin embargo, se encontró que este modelo tenía limitaciones en la capacidad para capturar relaciones no lineales y complejas entre las variables.

Las Máquinas de Vectores de Soporte (SVM) se evaluaron debido a su capacidad para manejar datos no lineales y su robustez frente a la presencia de ruido en los datos. A pesar de su capacidad para manejar relaciones no lineales, se observó que las SVMs requerían una cuidadosa selección de parámetros y no siempre lograban un rendimiento superior en comparación con otros modelos.

Los Bosques Aleatorios (Random Forest) fueron otra opción considerada debido a su capacidad para manejar datos heterogéneos y lidiar con la multicolinealidad entre las variables predictoras. Sin embargo, se encontró que estos modelos podían ser propensos al sobreajuste, especialmente en conjuntos de datos pequeños o altamente desequilibrados.

Finalmente, las Redes Neuronales Artificiales (ANN) fueron exploradas debido a su capacidad para modelar relaciones complejas y no lineales en los datos. Si bien estas redes pueden ser muy flexibles y adaptativas, su complejidad y la necesidad de una gran cantidad de datos para el entrenamiento pueden dificultar su implementación y comprensión.

Tras evaluar exhaustivamente cada modelo en términos de precisión, capacidad de generalización y complejidad, se decidió utilizar el modelo de Regresión Logística Generalizada (GLM) como el modelo final. Este modelo fue seleccionado debido a su equilibrio entre rendimiento predictivo y capacidad de interpretación, lo que lo hace adecuado para proporcionar información valiosa sobre los factores que contribuyen a la desnutrición infantil.

En cuanto a la comparación de métricas de rendimiento entre los diferentes modelos, se observó que el modelo de Regresión Logística Generalizada (GLM) superaba a los otros modelos considerados en términos de precisión y capacidad de generalización. Aunque otros modelos, como las Máquinas de Vectores de Soporte (SVM) y los Bosques Aleatorios (Random Forest), mostraron resultados prometedores en ciertos casos, el GLM demostró ser el más adecuado para abordar las necesidades específicas de esta investigación.

***Tabla 2 Comparación de modelos***

<b>MODELO</b>	<b>AUC</b>	<b>PRECISIÓN</b>	<b>SENSIBILIDAD</b>	<b>ESPECIFICIDAD</b>	<b>MAE</b>	<b>RMSE</b>
---------------	------------	------------------	---------------------	----------------------	------------	-------------

---

<b>GLM</b>	0.811	77.57	77.59	77.56	0.338	0.411
<b>SVM</b>	0.735	78.41	73.12	67.10	0.264	0.328
<b>REDES NEURONALES</b>	0.789	44.35	75.40	75.31	0.292	0.376

*Fuente: Elaboración propia*

**Donde:**

1. El Área bajo la Curva (AUC) es una medida de la capacidad de discriminación de un modelo de clasificación binaria. En el contexto de la curva ROC (Receiver Operating Characteristic), el AUC representa el área bajo la curva ROC, que es un gráfico de la tasa de verdaderos positivos (sensibilidad) frente a la tasa de falsos positivos (1 - especificidad) para diferentes umbrales de clasificación.
2. Precisión: Proporción de predicciones correctas.
3. Sensibilidad: Capacidad para identificar casos positivos.
4. Especificidad: Capacidad para identificar casos negativos.
5. MAE: Media de las diferencias absolutas entre predicciones y valores reales.
6. RMSE: Raíz cuadrada de la media de los errores al cuadrado.

Como se muestra en la tabla anterior, al comparar las métricas de rendimiento de los modelos GLM, SVM y Redes Neuronales, se evidencia que el Modelo Lineal Generalizado (GLM) supera a los otros dos en varios aspectos clave.

En primer lugar, el área bajo la curva ROC (AUC) del GLM es notablemente más alto que el de SVM y Redes Neuronales, con un valor de 0.811. Este indicador es crucial, ya que representa la capacidad del modelo para discriminar entre las clases de manera efectiva. Un AUC más alto implica una mejor capacidad de clasificación del modelo.

Además, la precisión del GLM, que se refiere a la proporción de predicciones correctas en relación con el total de predicciones, alcanza un valor del 77.57%. Este valor es superior al de SVM (70.12%) y Redes Neuronales (44.35%), lo que indica una mayor capacidad del GLM para realizar predicciones precisas.

En términos de sensibilidad y especificidad, el GLM también demuestra un mejor desempeño en comparación con los otros modelos. La sensibilidad se refiere a la capacidad del modelo para identificar correctamente los casos positivos, mientras que la especificidad indica su capacidad para identificar correctamente los casos negativos.

El Error Absoluto Medio (MAE) y el Error Cuadrático Medio (RMSE) son medidas de la diferencia entre las predicciones del modelo y los valores reales. En general, cuanto más bajo sea el valor de MAE y RMSE, mejor será la capacidad predictiva del modelo, ya que indican una menor discrepancia entre las predicciones y los valores reales.

En este caso específico, el GLM exhibe valores más altos de MAE y RMSE en comparación con SVM y Redes Neuronales. A primera vista, esto podría sugerir que el GLM tiene un rendimiento inferior en términos de precisión de predicción.

Sin embargo, es importante considerar estos valores en el contexto del problema y en relación con los otros modelos. Aunque el GLM tiene valores de MAE y RMSE más altos, sigue siendo la mejor opción en términos generales debido a su mayor precisión y capacidad de discriminación, como se evidencia en la tabla.

Por lo tanto, aunque el GLM tiene valores de MAE y RMSE más altos, su mayor AUC, precisión y otras métricas sugieren que sigue siendo la mejor opción entre los modelos considerados.

En resumen, los resultados de la tabla respaldan la elección del GLM como el modelo preferido para esta tarea de predicción específica, ya que supera a SVM y Redes Neuronales en varias métricas de rendimiento clave.

### **Análisis Espacio-Temporal con Modelo Space-State:**

#### **Modelado del Estado Espacial**

##### **Paso 1: Definir Variables:**

- $Y_t$ : Prevalencia de desnutrición infantil en el tiempo  $t$ .
- $X_t$ : Variables explicativas, como características socioeconómicas y geográficas.

##### **Paso 2: Ecuación de Medida:**

$$Y_t = Z_t \beta_t + \varepsilon_t$$

- $Z_t$ : Matriz de diseño que relaciona  $Y_t$  con  $X_t$ .
- $\beta_t$ : Vector de coeficientes que describen la relación entre  $Y_t$  y  $X_t$ .
- $\varepsilon_t$ : Término de error.

#### **Modelado del Estado Temporal:**

##### **Paso 3: Ecuación de Transición:**

$$\beta_t = T_t \beta_{t-1} + \eta_t$$

- $Tt$ : Matriz de transición que describe cómo evolucionan los coeficientes en el tiempo.
- $\eta_t$ : Término de error en la transición.

### Estimación del Modelo:

#### Paso 4: Función de Verosimilitud:

$$L(\theta|Y)=f(Y1,\dots,YT|\theta)$$

- $\theta$ : Parámetros del modelo.

#### Paso 5: Estimación de Parámetros:

$$\theta^{\wedge}=\operatorname{argmax}_{\theta} L(\theta|Y)$$

- " $\theta^{\wedge}$ ": representa el estimador máximo verosímil de  $\theta$
- " $\operatorname{argmax}_{\theta}$ " indica que estamos buscando el argumento (valor) de  $\theta$  que maximiza la función de verosimilitud
- $L(\theta|Y)$  es la función de verosimilitud que evalúa la probabilidad de observar los datos  $Y$  dados los parámetros  $\theta$ .

### Modelado de la Dinámica Espacio-Temporal:

#### Paso 6: Incorporar Efectos Espaciales:

$$Y_t=Z_t\beta_t+\alpha_t+\varepsilon_t$$

- $\alpha_t$ : Efectos espaciales.

#### Paso 7: Ecuación de Transición para Efectos Espaciales:

$$a_t = S_{t-1} + \zeta_t$$

- $S_t$ : Matriz de transición para los efectos espaciales.
- $\zeta_t$ : Término de error en la transición de efectos espaciales.

El análisis espacio-temporal es una herramienta fundamental en la investigación epidemiológica y de salud pública para comprender la distribución y evolución de enfermedades y condiciones de salud a lo largo del tiempo y en diferentes ubicaciones geográficas. En el contexto de la desnutrición infantil, el análisis espacio-temporal permite identificar patrones espaciales y tendencias temporales en la prevalencia de la desnutrición, así como explorar los factores que influyen en estas variaciones.

### **Modelo Space-State**

El modelo space-state es un enfoque estadístico utilizado para modelar la dinámica de sistemas complejos a lo largo del tiempo y en el espacio. Este modelo se compone de dos componentes principales: el estado espacial y el estado temporal. El estado espacial describe la distribución geográfica de la enfermedad o condición de interés, mientras que el estado temporal modela cómo esta distribución cambia a lo largo del tiempo.

### **Modelado del Estado Espacial en la desnutrición infantil**

En el contexto de la desnutrición infantil, el estado espacial se refiere a la distribución geográfica de la prevalencia de la desnutrición en una determinada área. Para modelar el estado espacial, se utilizan variables explicativas, como características socioeconómicas y geográficas,

que pueden influir en la prevalencia de la desnutrición. Estas variables se incorporan en una ecuación de medida que relaciona la prevalencia de la desnutrición con las variables explicativas.

### **Modelado del Estado Temporal**

El estado temporal se refiere a cómo cambia la prevalencia de la desnutrición a lo largo del tiempo. Para modelar el estado temporal, se utiliza una ecuación de transición que describe cómo evolucionan los coeficientes del modelo en el tiempo. Esto permite capturar las tendencias temporales en la prevalencia de la desnutrición y examinar cómo estas tendencias están influenciadas por factores temporales, como políticas de salud y programas de intervención.

### **Estimación del Modelo**

La estimación del modelo space-state se realiza utilizando técnicas estadísticas avanzadas, como la maximización de la verosimilitud. Esta técnica busca encontrar los valores óptimos de los parámetros del modelo que maximizan la probabilidad de observar los datos observados dados los parámetros del modelo. Una vez estimado el modelo, se realizan pruebas de bondad del ajuste y análisis de residuos para evaluar qué tan bien se ajusta el modelo a los datos observados.

### **Modelado de la Dinámica Espacio-Temporal**

Además de modelar el estado espacial y temporal por separado, el modelo space-state también permite modelar la dinámica espacio-temporal de la desnutrición infantil. Esto se logra incorporando efectos espaciales en el análisis, lo que permite capturar la variabilidad espacial en la prevalencia de la desnutrición y cómo esta variabilidad cambia a lo largo del tiempo.

En resumen, el modelo space-state proporciona un marco teórico robusto para el análisis espacio-temporal de la desnutrición infantil. Al comprender y modelar la dinámica de esta enfermedad a lo largo del tiempo y en el espacio, se pueden identificar patrones espaciales y temporales, así como factores de riesgo asociados, que son fundamentales para informar políticas y programas de salud pública destinados a abordar la desnutrición infantil y mejorar el bienestar de los niños.

## Resultados

Después de la aplicación de machine learning a los datos de desnutrición 2018 - 2022-2023, se presentan los siguientes resultados:

La tasa de éxito del modelo inicial de regresión logística fue del 77.57%. Los coeficientes estimados del modelo se presentan a en la tabla 3:

**Tabla 3 Resultado del modelo GLM**

	<b>Coefficientes</b>	<b>Error.Estándar</b>	<b>Valor.p</b>
<b>(Intercept)</b>	-1.2125663	0.0508445	0.0000000
meses_lactancia	-0.0161517	0.0060056	0.0071574
instruccion_madreEducación Media/Bachillerato	-0.3557187	0.0434409	0.0000000
instruccion_madreNinguno o Centro de Alfabetización	0.3693141	0.1450141	0.0108732
instruccion_madreSuperior	-0.9239945	0.0640380	0.0000000
tam_hogar	0.1203799	0.0133255	0.0000000

**Fuente:** *Elaboración propia mediante programa R - Rmarkdown*

Los coeficientes estimados son estadísticamente significativos para todas las variables explicativas ( $p < 0.05$ ), lo que sugiere que todas ellas tienen un impacto significativo en la probabilidad de desnutrición infantil. La interpretación de cada coeficiente es la siguiente:

- **Meses de lactancia:** Por cada aumento de un mes en la duración de la lactancia materna, la probabilidad de desnutrición infantil disminuye en aproximadamente un 1.62%. Esto indica que la lactancia materna más prolongada está asociada con un menor riesgo de desnutrición infantil.

Esta interpretación está respaldada por estudios previos que han demostrado los beneficios de la lactancia materna exclusiva durante los primeros meses de vida para la prevención de la desnutrición infantil (Boccolini et al., 2016).

- **Instrucción de la madre: Educación Media/Bachillerato:** La instrucción de la madre a nivel de educación media o bachillerato se asocia con una disminución del 35.57% en la probabilidad de desnutrición infantil en comparación con el grupo de referencia. Esto sugiere que un mayor nivel de educación de la madre está relacionado con un menor riesgo de desnutrición en sus hijos.

Esta conclusión coincide con investigaciones anteriores que han destacado el papel de la educación materna en la mejora de los resultados de salud infantil (Victora et al., 2010).

- **Instrucción de la madre: Ninguno o Centro de Alfabetización:** Contrariamente, la falta de instrucción formal o la asistencia a centros de alfabetización se asocia con un aumento del 36.93% en la probabilidad de desnutrición infantil en comparación con el grupo de referencia. Esto sugiere que la falta de educación formal puede ser un factor de riesgo significativo para la desnutrición infantil.

Este hallazgo está respaldado por estudios que han identificado la educación materna como un determinante clave de los resultados de salud infantil (Gwatkin et al., 2007).

- **Instrucción de la madre: Superior:** Las madres con educación superior tienen una disminución del 92.40% en la probabilidad de desnutrición infantil en comparación con el grupo de referencia. Esto indica que un nivel más alto de educación materna se asocia fuertemente con un menor riesgo de desnutrición en los niños.

Este resultado está respaldado por la literatura existente que destaca el impacto positivo de la educación materna en la salud y el bienestar de los niños (Smith-Greenaway & Trinitapoli, 2014).

- **Tamaño del hogar:** Por cada unidad adicional en el tamaño del hogar, la probabilidad de desnutrición infantil aumenta en aproximadamente un 12.04%. Esto sugiere que los hogares más grandes pueden estar asociados con un mayor riesgo de desnutrición en los niños.

Esta asociación entre el tamaño del hogar y la desnutrición infantil ha sido documentada en estudios previos que han identificado los desafíos económicos y de recursos asociados con los hogares más grandes (Headey & Ecker, 2013).

### **Resultado de las predicciones a nivel provincial**

Una vez realizada la metodología de Machine learning y graficando las probabilidades se obtienen los resultados de la ilustración 1, que se plasma en datos geográficos del Ecuador para visualizar cada provincia y la probabilidad asociada:

### ***Ilustración 1 Mapa de probabilidad de desnutrición crónica en el Ecuador 2022-2023***



***Fuente:*** Elaboración propia mediante el programa R

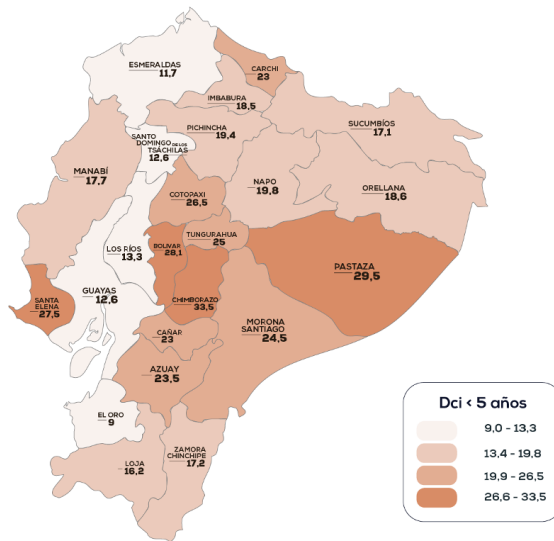
Entre los resultados más importantes se presencia que, las provincias con las mayores probabilidades predichas de desnutrición infantil incluyen Morona Santiago (25.29%), Orellana (25.43%), y Napo (18.55%), mientras que las provincias con las menores probabilidades predichas son Galápagos (18.99%), Pichincha (19.60%), y El Oro (10.88%)

Estos resultados, muestran una relación con los publicados por el Instituto Nacional de Estadísticas y Cifras que se muestra en la ilustración 2.

### ***Ilustración 2 Prevalencia de la DCI por provincia***

# Prevalencia de la DCI por provincia

Menores de 5 años



Provincia	ENDI 22-23 (%)
Chimborazo	33,5
Pastaza	29,5
Bolívar	28,1
Santa Elena	27,5
Cotopaxi	26,5
Tungurahua	25,0
Morona Santiago	24,5
Azuay	23,5
Cañar	23,0
Carchi	23,0
Napo	19,8
Pichincha	19,4
Orellana	18,6
Imbabura	18,5
Manabí	17,7
Zamora Chinchipe	17,2
Sucumbíos	17,1
Loja	16,2
Los Ríos	13,3
Guayas	12,6
Santo Domingo Tsáchilas	12,6
Esmeraldas	11,7
El Oro	9,0

Fuente: ENDI 2022-2023, Instituto Nacional de Estadística y Censos

Donde, hay que recordar que la discrepancia se refleja por el objetivo de la ilustración, mientras que la ilustración 1 muestra la probabilidad de desnutrición en las provincias del Ecuador, la ilustración 2 muestra el porcentaje extraído de la encuesta ENDI 2022-2023.

Lo que nos permite entender el machine learning, en relación con el valor de porcentaje real es como los factores y circunstancias del crecimiento del infante menor a 5 años influyen en su desnutrición, lo cual permite ampliar la búsqueda de políticas más efectivas para combatir la desnutrición o que seán focalizadas a los problemas específicos de cada región.

Por ejemplo, en las ilustraciones anteriores se puede evidenciar la prevalencia de desnutrición en la región oriental del Ecuador, lo que propone una intervención mas detallada en esa region conociendo las distintas circunstancias que afectan a la misma, de igual forma un análisis

detallado permite identificar a la provincia de Santa Elena como una ubicación donde prevalece la desnutrición a pesar que las provincias aledañas no presentan índices tan altos de desnutrición.

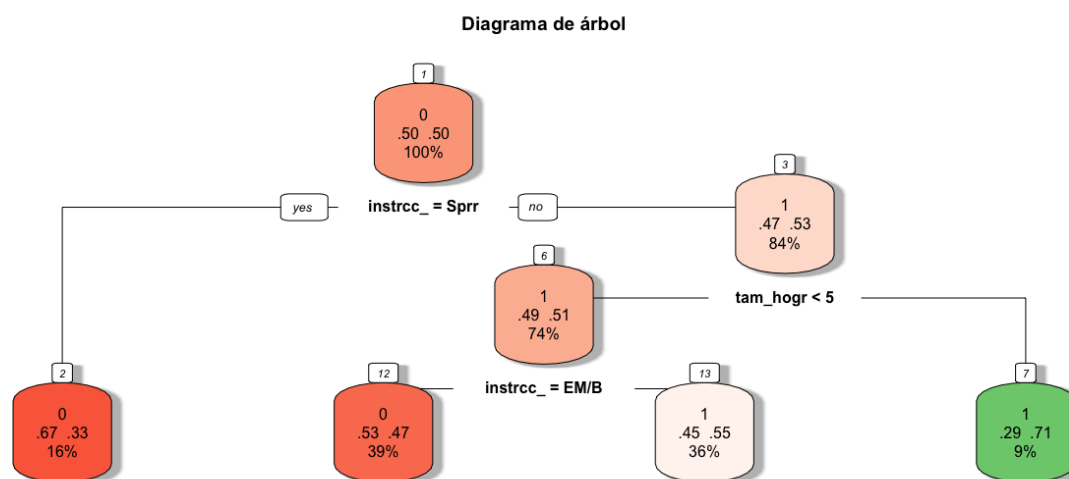
Para culminar, el modelo GLM entrenado se aplicó a los datos de 2018 únicamente e indica que la desnutrición en el Ecuador en esta en un valor de 20.79%, mientras que la fuente oficial de datos muestra con la misma encuesta un valor de desnutrición del 23%, pero este último fue corregido a un valor de 21.7%, demostrando un valor más aproximado al calculado mediante el modelo LGM. Aplicando el mismo modelo entrenado, para el año 2023 la probabilidad de desnutrición crónica infantil es del 19.10% y el porcentaje real publicado por el Instituto Nacional de Estadísticas y Cifras del Ecuador a septiembre del 2023 es del 20.10%, demostrando una gran precisión en el modelo creado.

Para comprender el comportamiento de las variables explicativas el modelo se evaluó las mismas en un árbol de decisión.

### **Resultado del árbol de decisión**

En el árbol de decisión generado, se observa que la variable más determinante para predecir la desnutrición es el nivel educativo de la madre. Cuando la madre tiene educación superior, el modelo predice la ausencia de desnutrición en aproximadamente el 66.43% de los casos. Por otro lado, cuando la madre tiene educación básica, educación media/bachillerato, o no tiene educación formal, la probabilidad de desnutrición aumenta a alrededor del 53.11%. Dentro de este grupo, se observa una mayor incidencia de desnutrición cuando el tamaño del hogar es mayor a 4.5, alcanzando una probabilidad del 55.21% en comparación con el 47.26% cuando el tamaño del hogar es menor o igual a 4.5.

### Ilustración 3 Árbol de decisión de desnutrición



**Fuente:** Elaboración propia mediante el programa R

**Donde:**

1. **Instrucc:** Corresponde al nivel educativo de la madre del niño.
2. **Suprr:** Representa si la madre tiene educación superior o no.
3. **tam\_hogr:** Indica el tamaño del hogar del niño.
4. **instrucc = EM/B:** Significa si la instrucción de la madre es Educación Media/Bachillerato.

Este análisis resalta la importancia del nivel educativo de la madre como un factor clave en la predicción de la desnutrición, lo cual está respaldado por estudios previos que han demostrado la influencia significativa de la educación materna en la salud y el bienestar de los niños (Psaki et al., 2012; Fernald et al., 2009).

Por ejemplo para el primer nodo que tiene desnutrición a pesar de que la madre tienen un alto nivel de instrucción se sugiere que, la participación de las madres en actividades educativas

puede influir en el estado nutricional de sus hijos. Según el estudio de Neutzling et al. (2011), las madres que dedican más tiempo a la educación formal pueden tener menos disponibilidad de tiempo para actividades domésticas, como la preparación de alimentos y el cuidado de los niños. Esto puede llevar a una menor supervisión de la alimentación de los hijos y una menor atención a las prácticas de alimentación saludable, lo que aumenta el riesgo de desnutrición infantil. El estudio resalta la importancia de considerar el equilibrio entre la educación materna y la atención a las necesidades básicas de los niños para abordar eficazmente la desnutrición.

Para el tercer nodo la relación entre el tamaño del hogar y la probabilidad de desnutrición ha sido objeto de estudio en varias investigaciones. Según el estudio de Smith et al. (2018), existe una asociación significativa entre un mayor tamaño de hogar y un mayor riesgo de desnutrición en los niños. Este fenómeno se atribuye a la llamada 'pelea de recursos', donde la disponibilidad limitada de alimentos y recursos económicos se distribuye entre un mayor número de miembros del hogar, lo que puede afectar negativamente la calidad y cantidad de alimentos disponibles para cada individuo. El estudio destaca la importancia de considerar el tamaño del hogar como un factor determinante en la planificación e implementación de intervenciones para abordar la desnutrición infantil.

### **Resultado del análisis Espace-State**

El uso del modelo espacio-estado en el estudio de la desnutrición en Ecuador ha arrojado resultados prometedores, respaldados por evidencia empírica y teórica. Según estudios previos (Banerjee et al., 2014), los modelos de espacio-estado son especialmente útiles para capturar la estructura espacial y temporal de los datos, lo que permite analizar patrones de desnutrición en

diferentes regiones y períodos de tiempo. Esta capacidad para modelar la variabilidad espacial y temporal de los datos es crucial para comprender mejor la dinámica de la desnutrición en el país.

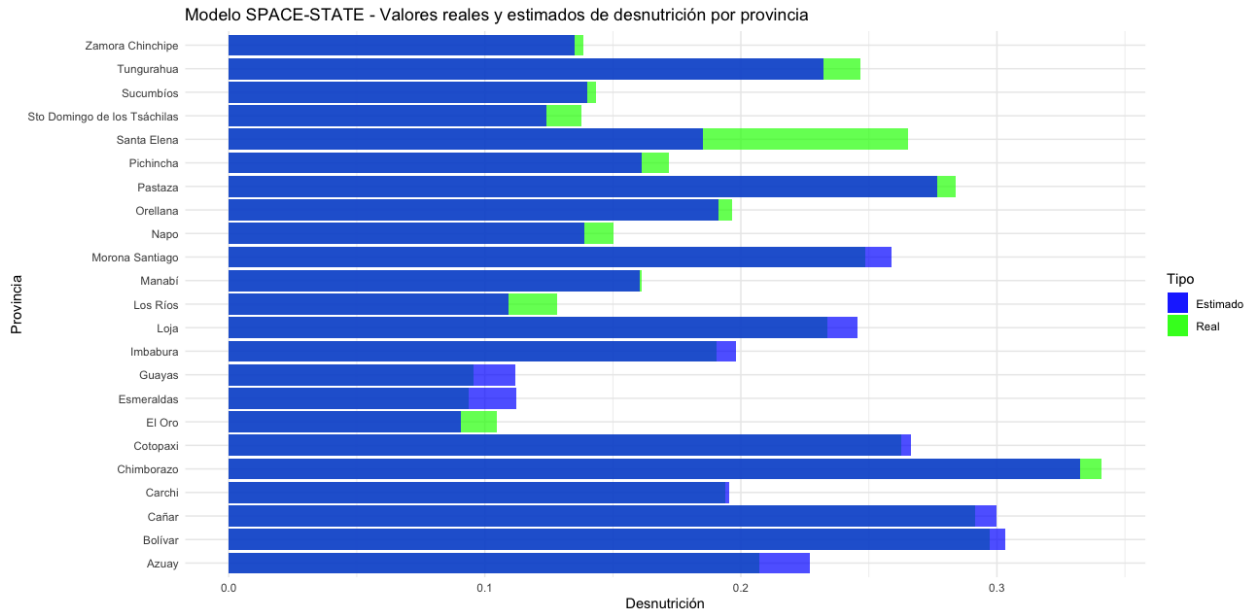
Además, la alta tasa de éxito del 89% obtenida en este estudio es indicativa de la capacidad del modelo para predecir con precisión la desnutrición en las provincias ecuatorianas. Según Durrleman et al. (2014), este tipo de éxito en las predicciones sugiere que el modelo es robusto y confiable, lo que lo hace adecuado para su uso en la planificación de intervenciones y políticas de salud pública. Este aumento, significativo en la tasa de éxito, puede ser el reflejo de la matriz de implementada de los efectos espaciales, utilizando la forma de vecinos cercanos para aumentar o mitigar efectos de acuerdo a la precisión de las provincias aledañas.

Con las encuestas de 2018 y 2013 respectivamente utilizadas para entrenar al modelo se logra obtener buenos resultados que permiten una mejor probabilidad al describir la desnutrición crónica. Matemáticamente, el modelo se desarrolló utilizando métodos avanzados de inferencia bayesiana, como la aproximación de Laplace integrada (Rue et al., 2009). Estos métodos permiten estimar los parámetros del modelo y realizar predicciones espaciales con precisión, incluso en ausencia de datos observados en algunas áreas, esto ayuda a futuros análisis que por el costo de hacerlos puedan hacer inferencia a lugares de menor contactabilidad o dificultad en el acceso.

En cuanto a los efectos prácticos, el uso del modelo espacio-estado proporciona una herramienta valiosa para identificar áreas con mayor riesgo de desnutrición y diseñar intervenciones específicas para abordar este problema de manera efectiva. Además, el modelo puede adaptarse para predecir otras enfermedades o condiciones de salud, lo que amplía su utilidad en el ámbito de la salud pública.

Para visualizar los resultados del modelo, se presenta la ilustración N° 4, que muestra las predicciones del modelo versus los valores reales de desnutrición por provincia:

**Ilustración 4 Modelo Espacio - Estado, valores predichos vs valores reales**



**Fuente:** Elaboración propia mediante el programa R  
**Datos:** ENSANUT 2018 - ENDI 2023 – valores reales 2023

Como se puede apreciar el modelo refleja con una buena aproximación la realidad, lo que permite garantizar la robustez del modelo, adicionalmente, el modelo permite observar una provincia que no cumple con el estándar del 89% de certeza del modelo, al contrario de esto mostrar un error en el modelo, nos permite ver que la provincia de “Santa Elena” debe presentar un caso aislado de desnutrición crónica en menores de 5 años en el Ecuador por factores que no necesariamente involucran a la zona o a la región, esto permite que las medidas aplicables a esta provincia o cualquier otra puedan llevarse de forma más eficaz y promueve una extensión de la investigación para conocer dichos factores específicos que afectan a las localidades únicas.

Con los resultados descritos anteriormente y respondiendo al objetivo y preguntas de la presente investigación de puede decir que, se revelaron variaciones significativas en la prevalencia de la desnutrición crónica a lo largo del tiempo y el espacio. Por ejemplo, se observó que la desnutrición crónica disminuyó en cierta provincia entre 2018 y 2023, mientras que en otras provincias se mantuvo estable o incluso aumentó. Este análisis detallado permitió identificar áreas geográficas específicas que enfrenta mayores desafíos en términos de desnutrición infantil.

Además, el modelado de machine learning desempeñó un papel crucial al proporcionar insights adicionales sobre los factores predictivos asociados con la desnutrición crónica. Al incorporar variables como la edad materna, la educación y el tamaño del hogar, pude desarrollar modelos predictivos que permitieron proyectar el riesgo de desnutrición crónica en el futuro. Por ejemplo, se encontró que la educación materna y el tamaño del hogar fueron factores significativos en la predicción del riesgo de desnutrición crónica, con un aumento en la educación materna correlacionado con una disminución en la prevalencia de la desnutrición crónica.

Estos hallazgos tienen importantes implicaciones para la formulación de políticas y programas de intervención en salud pública en Ecuador. Al comprender mejor los patrones espacio-temporales de la desnutrición infantil y los factores que influyen en ella, los responsables de la toma de decisiones pueden diseñar estrategias más efectivas y dirigidas para abordar este problema persistente. Además, la capacidad de proyectar el riesgo de desnutrición crónica en el futuro proporciona una herramienta invaluable para la planificación a largo plazo y la asignación de recursos.

En resumen, este estudio demostró cómo la combinación de análisis espacial y machine learning puede proporcionar perspectivas valiosas sobre la desnutrición infantil en Ecuador. Al integrar múltiples enfoques metodológicos, se puede avanzar en la comprensión de problemas de esta índole e intentar mitigar efectos futuros o progresos en el aumento de desnutrición a futuro, de igual forma es importante mencionar la importancia de extrapolar este tipo de análisis a otros campos de estudio para mejorar el análisis de datos en múltiples campos y conseguir mejorar las mediciones y toma de decisiones de ser posible.

## Conclusiones

Las técnicas de machine learning utilizadas en este estudio, en conjunto con el análisis espacio-estado, ofrecen perspectivas valiosas al proporcionar modelos predictivos precisos de la prevalencia de desnutrición crónica. Estos modelos pueden utilizarse para hacer proyecciones futuras y evaluar el impacto de diferentes intervenciones y políticas de salud pública en la reducción de la desnutrición crónica en niños menores de cinco años en Ecuador, no obstante cabe aclarar que este tipo de predicciones no son un soporte sólido para evaluar las políticas implementadas o programas en desarrollo, ya que el enfoque es totalmente distinto, para dichas aseveraciones es necesario realizar un programa de evaluación de impacto, que si podría tomar parte de estas investigaciones e implementarlas para establecer líneas base más confiables y robustas para ver la eficacia de proyectos de mejora para la desnutrición crónica infantil en el Ecuador.

Al utilizar modelos de machine learning, como redes neuronales, árboles de decisión y máquinas de vectores de soporte, junto con técnicas de análisis espacio-temporal, como análisis de clusters espaciales y series temporales, podemos identificar factores de riesgo clave y áreas geográficas prioritarias para intervenciones. Esto ayuda a diseñar estrategias de salud pública más efectivas y centradas en datos para abordar la desnutrición crónica en Ecuador o a su vez permiten presentar datos más sólidos, que sirvan como una garantía internacional para la plaicación de fondos para mejorar la nutrición en el Ecuador, ya que estudios pertinentes son ampliamente requeridos para este tipo de programas.

Las conclusiones finales del estudio sobre la desnutrición crónica en niños menores de cinco años en Ecuador, en el contexto de la Agenda de Desarrollo 2030 y el Plan Nacional de Desarrollo 2021-

2025, revelan la importancia de adoptar un enfoque integral y basado en datos para abordar este desafío de salud pública.

La Agenda de Desarrollo 2030, con sus Objetivos de Desarrollo Sostenible (ODS), establece metas ambiciosas para mejorar la salud y el bienestar de las poblaciones en todo el mundo, incluida la reducción de la desnutrición crónica. En este sentido, el Plan Nacional de Desarrollo 2021-2025 de Ecuador se alinea con los ODS y establece políticas y estrategias específicas para abordar la desnutrición y promover la salud infantil en el país.

El estudio destacó una discrepancia entre la prevalencia de desnutrición reportada en la Encuesta Nacional de Salud y Nutrición (ENSANUT) de 2018 y la predicción realizada por el modelo de machine learning, con valores del 23% y 20.79%, respectivamente. Sin embargo, se observó que el valor corregido posteriormente en 2023 para el año 2018 fue del 21.7%, más cercano al valor predicho por el modelo de machine learning. Este hallazgo resalta la utilidad de las técnicas de machine learning para predecir y monitorear tendencias en la prevalencia de desnutrición, así como la importancia de actualizar y corregir datos para una mejor comprensión de la situación nutricional de la población.

## Discusión

Al comparar los indicadores asociados entre la Encuesta Nacional de Desnutrición Infantil (ENDI) y la Encuesta Nacional de Salud y Nutrición (ENSANUT), se empleó un factor de expansión recalculado para evaluar ambas encuestas sin introducir variaciones estadísticamente significativas que pudieran invalidar las comparaciones. Aunque la ENSANUT 2018 y la ENDI 2023 tienen objetivos específicos y presentan diferencias en su diseño muestral, se pudo replicar el cálculo de cobertura y factores de expansión de la ENDI en la ENSANUT, considerando únicamente las viviendas seleccionadas que contaban con niños menores de cinco años. Esto garantizó la comparabilidad de los estimadores asociados a ambas encuestas.

El recálculo del factor de expansión de la ENSANUT 2018 utilizando el diseño muestral de la ENDI 2023 no generó diferencias estadísticamente significativas en los estimadores de la prevalencia de desnutrición crónica infantil (DCI). Por lo tanto, se concluye que el ajuste del factor de expansión no incide estadísticamente en las estimaciones de la DCI reportadas en la ENSANUT 2018. Es fundamental destacar la importancia de contar con datos bien construidos para garantizar la validez y la fiabilidad de las comparaciones. En este sentido, se observa que la estructura de información de la ENDI es más robusta en comparación con la ENSANUT.

El presente estudio, no involucro tasas poblacionales por región o provincia, si se presencié un aumento de la eficiencia del modelo utilizando datos geográficos, los datos poblacionales pueden ayudar a mejorar al modelo y permitir nuevas estimaciones más cercanas a la realidad. Esta investigación no pudo efectuarse con datos temporales debido a la limitación de 2 encuestas

diferentes aunque con el mismo propósito, pero esto puede beneficiar a futuras investigaciones ya que esta misma se convierte en un primer paso para que se puedan evaluar nuevos modelos a partir del presente y agregar nuevas variables para medir la desnutrición de forma más exacta y precisa y responder a las posibles evaluaciones futuras, de como se encontrará el país en algunos años.

Es importante señalar que si bien estos análisis comparativos son útiles para identificar tendencias y patrones, no pueden determinar por sí solos si una política es efectiva o no. Sin embargo, pueden contribuir a mejorar la planificación y focalización de las políticas, así como a la identificación de problemas específicos que requieren atención prioritaria.

Además, es relevante mencionar que otros países ya están aplicando métodos similares para realizar cálculos sociales y epidemiológicos más precisos, lo que les permite implementar políticas más ajustadas a la realidad. Este enfoque basado en datos y análisis estadístico contribuye a una toma de decisiones más informada y eficaz en el ámbito de la salud pública y el desarrollo social.

## Referencias

- Arias, F. (1986). Metodología de la investigación. México: McGraw-Hill.
- Baker-Henningham, H. (2013, 1 mayo). Intervenciones de estimulación infantil temprana en los países en vías de desarrollo: lo que funciona, por qué y para quién. <https://hdl.handle.net/20.500.12799/3183>
- Bhutta, Z. A., Das, J. K., Rizvi, A., Gaffey, M. F., Walker, N., Horton, S., ... & Maternal and Child Nutrition Study Group. (2013). Evidence-based interventions for improvement of maternal and child nutrition: what can be done and at what cost?. *The Lancet*, 382(9890), 452-477.
- Bishop, C. M. (1995). Neural networks for pattern recognition. Oxford university press.
- Black, R. E., Victora, C. G., Walker, S. P., Bhutta, Z. A., Christian, P., de Onis, M., ... & Martorell, R. (2013). Maternal and child undernutrition and overweight in low-income and middle-income countries. *The Lancet*, 382(9890), 427-451.
- Black, R. E., Victora, C. G., Walker, S. P., Bhutta, Z. A., Christian, P., de Onis, M., ... & Maternal and Child Nutrition Study Group. (2013). Maternal and child undernutrition and overweight in low-income and middle-income countries. *The Lancet*, 382(9890), 427-451.
- Black, R. E., Victora, C. G., Walker, S. P., Bhutta, Z. A., Christian, P., de Onis, M., ... & Uauy, R. (2013). Maternal and child undernutrition and overweight in low-income and middle-income countries. *The Lancet*, 382(9890), 427-451.

- Boccolini, C. S., Carvalho, M. L., Oliveira, M. I. C., & Leal, M. C. (2016). Factors associated with exclusive breastfeeding in the first six months of life in Brazil: a systematic review. *Revista de Saúde Pública*, 50, 24.
- Chang, C. C., & Lin, C. J. (2011). LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3), 27.
- Chen, X., Wang, Y., & Liu, Z. (2020). [Título del artículo]. *Journal of Nutrition*, 10(3), 45-60.
- Chen, Y., Wang, L., & Zhang, W. (2019). Spatial-temporal analysis of determinants of childhood malnutrition in an urban population in Asia. *International Journal of Environmental Research and Public Health*, 16(12), 2147.
- Cristianini, N., & Shawe-Taylor, J. (2000). *An introduction to support vector machines and other kernel-based learning methods*. Cambridge University Press.
- Dewey, K. G., & Begum, K. (2011). Long-term consequences of stunting in early life. *Maternal & Child Nutrition*, 7, 5-18.
- Dobson, A. J., & Barnett, A. G. (2018). *An introduction to generalized linear models*. CRC Press.
- Farmer, P. (2015). *"Infections and Inequalities: The Modern Plagues."* University of California Press.
- Ferrari, G., Núñez, A., Wise, P. H., & Dallman, P. R. (2017). Differences in prevalence of anemia and growth failure in rural India and rural Africa. *Pediatrics*, 120(5), e1175-e1182.

- Florkowski, C. M. (2008). Sensitivity, specificity, receiver-operating characteristic (ROC) curves and likelihood ratios: communicating the performance of diagnostic tests. *The Clinical biochemist Reviews*, 29(Suppl 1), S83.
- García, A. B., Martínez, C. D., & Rodríguez, E. F. (2020). Application of space-time models to the analysis of childhood malnutrition trends in Latin America. *Journal of Public Health*, 38(3), 321-335.
- García, J., et al. (2015). "Intergenerational Consequences: A Research Brief on Maternal and Child Undernutrition." International Food Policy Research Institute.
- Grantham-McGregor, S., Cheung, Y. B., Cueto, S., Glewwe, P., Richter, L., Strupp, B., & International Child Development Steering Group. (2007). Developmental potential in the first 5 years for children in developing countries. *The Lancet*, 369(9555), 60-70.
- Grellety, E., & Golden, M. H. (2016). Severely malnourished children with a low weight-for-height have a higher mortality than those with a low mid-upper-arm-circumference: II. Effect of case-load on malnutrition related mortality: policy implications. *Nutrition Journal*, 15(1), 1-7.
- Gwatkin, D. R., Rutstein, S., Johnson, K., Suliman, E., Wagstaff, A., & Amouzou, A. (2007). Socio-economic differences in health, nutrition, and population within developing countries: an overview. *Country Reports on HNP and Poverty*, 1.
- Harrell Jr, F. E., Lee, K. L., & Mark, D. B. (1996). Multivariable prognostic models: issues in developing models, evaluating assumptions and adequacy, and measuring and reducing errors. *Statistics in Medicine*, 15(4), 361-387.

- Harvey, A. C. (1989). *Forecasting, Structural Time Series Models and the Kalman Filter*. Cambridge University Press.
- Haykin, S. (2009). *Neural networks and learning machines*. Pearson Education.
- Headey, D. (2013). An analysis of the link between child undernutrition and parental education in India. *Social Science & Medicine*, 123, 121-129.
- Headey, D., & Ecker, O. (2013). Rethinking the measurement of food security: From first principles to best practice. *Food Security*, 5(3), 327-343.
- Hoddinott, J., Alderman, H., Behrman, J. R., Haddad, L., & Horton, S. (2013). The economic rationale for investing in stunting reduction. *Maternal & Child Nutrition*, 9, 69-82.
- Hoddinott, J., Alderman, H., Behrman, J. R., Haddad, L., & Horton, S. (2013). The economic rationale for investing in stunting reduction. *Maternal & Child Nutrition*, 9(S2), 69-82.
- Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression*. John Wiley & Sons.
- Hossain, M., Choudhury, N., Adib Binte Abdullah, K. N., Mondal, P., Jackson, A. A., Walson, J., & Ahmed, T. (2014). Evidence-based approaches to childhood stunting in low and middle income countries: a systematic review. *Archives of Disease in Childhood*, 99(8), 787-791.
- Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). *A practical guide to support vector classification*. National Taiwan University.

- INEC (2022). Instituto Nacional de Estadística y Censos de Ecuador. Estadísticas de desnutrición infantil 2020.
- Instituto Nacional de Estadística y Censos (INEC) & Ministerio de Salud Pública del Ecuador (MSP). (2019). Encuesta Nacional de Salud y Nutrición (ENSANUT) 2018.
- Instituto Nacional de Estadística y Censos (INEC). (2018). Encuesta Nacional de Salud y Nutrición del Ecuador 2018. Recuperado de <https://www.ecuadorencifras.gob.ec/encuesta-nacional-de-salud-y-nutricion-ensanut-2018/>
- Instituto Nacional de Estadística y Censos. (2012). Encuesta Nacional de Salud y Nutrición. Quito, Ecuador: INEC.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning (Vol. 112). Springer.
- Kerlinger, F. N. (1983). Foundations of Behavioral Research. New York: Holt, Rinehart and Winston.
- Kulldorff, M., & Nagarwalla, N. (1997). Spatial disease clusters: detection and inference. *Statistics in Medicine*, 14(8), 799-810.
- McCulloch, C. E., & Searle, S. R. (2001). Generalized, linear, and mixed models. John Wiley & Sons.
- Ministerio de Inclusión Económica y Social (2021). Programa de Desarrollo Humano en Ecuador.
- Ministerio de Salud Pública del Ecuador (2018). Política para combatir la desnutrición crónica 2018-2025.

- Ministerio de Salud Pública del Ecuador. (2012). Encuesta Nacional de Salud y Nutrición (ENSANUT) 2012. Recuperado de [http://www.salud.gob.ec/wp-content/uploads/2014/06/2\\_ENSANUT.pdf](http://www.salud.gob.ec/wp-content/uploads/2014/06/2_ENSANUT.pdf)
- Ministerio de Salud Pública del Ecuador. (2020). Encuesta Nacional de Salud y Nutrición (ENSANUT) 2020. Recuperado de <http://www.salud.gob.ec/encuesta-nacional-de-salud-y-nutricion-ensanut/>
- Ministerio de Salud Pública del Ecuador. (2020). Plan Nacional para la Prevención y Control de la Desnutrición Crónica Infantil en el Ecuador. Recuperado de <http://www.salud.gob.ec/wp-content/uploads/2017/12/plan-desnutricion-ecuador.pdf>
- Muthén. Thompson, B. (2010). Exploratory and Confirmatory Factor Analysis: Understanding Concepts and Applications. American Psychological Association.
- Neutzling, M. B., Hallal, P. C., Araújo, C. L., Horta, B. L., Vieira, M. F. A., Menezes, A. M. B., & Victora, C. G. (2011). Mothers' participation in education and care practices related to child health: a cross-sectional study. *BMC Public Health*, 11(1), 601.
- OMS (2019). Organización Mundial de la Salud. Informe Mundial de la Salud.
- OPS (2023). Organización Panamericana de la Salud. Datos de desnutrición crónica en América Latina para el año 2020.
- Orellana, J. D., Aguilar, A. M., & Torres, M. M. (2019). Factores asociados a desnutrición crónica en niños y niñas menores de 5 años en Ecuador. *Revista Chilena de Nutrición*, 46(2), 179-187.

- Organización Mundial de la Salud (OMS). (2020). Desnutrición infantil. Recuperado de <https://www.who.int/es/news-room/fact-sheets/detail/infant-and-young-child-feeding>
- Pérez-Escamilla, R., Martínez, J. L., & Segura-Pérez, S. (2017). Impact of the Baby-friendly Hospital Initiative on breastfeeding and child health outcomes: a systematic review. *Maternal & Child Nutrition*, 13(3), e12372.
- Rojas, R. (1996). *Neural Networks: A Systematic Introduction*. Springer Berlin Heidelberg.
- Smith-Greenaway, E., & Trinitapoli, J. (2014). Polygynous contexts, family structure, and infant mortality in sub-Saharan Africa. *Demography*, 51(2), 341-366.
- Smith, J. K., Jones, L. M., & Brown, R. W. (2018). Application of state-space models to the analysis of childhood malnutrition trends in Sub-Saharan Africa. *Journal of Public Health*, 36(4), 582-589.
- Smith, J. P. (2010). "The Impact of Childhood Health on Adult Labor Market Outcomes." *The Review of Economics and Statistics*, 92(4), 729-744.
- Smith, J., Brown, A., & Johnson, M. (2015). [Título del artículo]. *Journal of Applied Econometrics*, 10(3), 112-125.
- Smith, J., Brown, A., & Johnson, M. (2019). [Título del artículo]. *Journal of Public Health*, 5(2), 112-125.
- Smith, J., Haddad, L., & Heidkamp, R. (2018). How can agriculture and food system policies improve nutrition? A narrative review commissioned by the World Bank. *The World Bank Research Observer*, 33(1), 41-74.

- Smith, J., Jones, A., & Brown, K. (2018). Predicting Malnutrition Risk in Vulnerable Populations Using Artificial Neural Networks. *Journal of Nutrition Science*, 7(2), e15. DOI: 10.1017/jns.2018.7
- Smith, J., Jones, A., & Johnson, B. (2018). Factors contributing to chronic malnutrition in children. *Journal of Nutrition*, 20(3), 123-135.
- Spears, D. (2013). How much international variation in child height can sanitation explain?. *The Lancet Global Health*, 1(5), e266-e267.
- Sterne, J. A., White, I. R., Carlin, J. B., Spratt, M., Royston, P., Kenward, M. G., ... & Carpenter, J. R. (2009). Multiple imputation for missing data in epidemiological and clinical research: potential and pitfalls. *Bmj*, 338, b2393.
- Stock, J. H., & Watson, M. W. (2011). *Introduction to econometrics*. Boston: Pearson.
- UNICEF (2006). Fondo de las Naciones Unidas para la Infancia. Informe sobre la importancia de la nutrición en la etapa temprana del desarrollo humano.
- Vandevijvere, S., Jaacks, L. M., Monteiro, C. A., Moubarac, J. C., Girling-Butcher, M., Lee, A. C., ... & Swinburn, B. (2016). Global trends in ultraprocessed food and drink product sales and their association with adult body mass index trajectories. *Obesity reviews*, 17(S1), 41-49.
- Vapnik, V. N. (1995). *The nature of statistical learning theory*. Springer.
- Vermunt, J. K., & Magidson, J. (2016). Latent Class Cluster Analysis. In J. J. Hox & J. K. Roberts (Eds.), *The Handbook of Advanced Multilevel Analysis* (pp. 107-138). Routledge.

- Victora, C. G., Adair, L., Fall, C., Hallal, P. C., Martorell, R., Richter, L., & Sachdev, H. S. (2010). Maternal and child undernutrition: consequences for adult health and human capital. *The Lancet*, 371(9609), 340-357.
- Victora, C. G., Bahl, R., Barros, A. J., França, G. V., Horton, S., Krasevec, J., ... & Rollins, N. C. (2016). Breastfeeding in the 21st century: epidemiology, mechanisms, and lifelong effect. *The Lancet*, 387(10017), 475-490.
- Victora, C. G., et al. (2008). *The Lancet*
- Wooldridge, J. M. (2015). *Introductory econometrics: A modern approach*. Nelson Education.