UNIVERSIDAD POLITÉCNICA SALESIANA

SEDE GUAYAQUIL

CARRERA DE COMPUTACIÓN

Modelos de machine learning para la detección temprana de deficiencias nutricionales en la infancia

Trabajo de titulación previo a la obtención del
Título de Ingeniero en Ciencias de la Computación

AUTORES: Jefferson Ismael Davalos Carrera

Katty Milena Cortez Paredes

TUTOR: Joe Frand Llerena Izquierdo

Guayaquil-Ecuador

2025

CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Nosotros, Jefferson Ismael Davalos Carrera con documento de identificación N° 0931344170 y Katty Milena Cortez Paredes con documento de identificación N° 1729781664, manifestamos que: Somos los autores y responsables del presente trabajo; y autorizamos a que, sin fines de lucro, la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Guayaquil, 29 de enero del año 2025.

Atentamente,

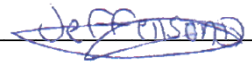

Jefferson Ismael Davalos Carrera
0931344170

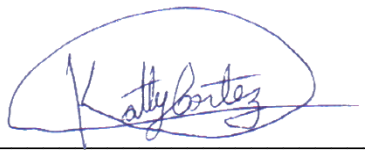

Katty Milena Cortez Paredes
1729781664

CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA

Nosotros, Jefferson Ismael Davalos Carrera con documento de identificación No.0931344170 y Katty Milena Cortez Paredes con documento de identificación No.1729781664, expresamos nuestra voluntad y, por medio del presente documento, cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del Artículo Académico: Modelos de machine learning para la detección temprana de deficiencias nutricionales en la infancia, el cual ha sido desarrollado para optar por el título de Computación, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribimos este documento cuando entregamos el trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Guayaquil, 29 de enero del año 2025.

Atentamente,

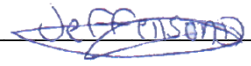

Jefferson Ismael Davalos Carrera
0931344170

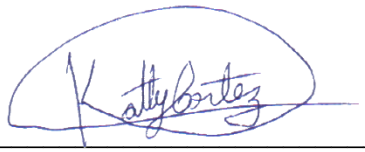

Katty Milena Cortez Paredes
1729781664

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Joe Frand Llerena Izquierdo con documento de identificación N° 0914884879, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: Modelos de machine learning para la detección temprana de deficiencias nutricionales en la infancia, realizado por Jefferson Ismael Davalos Carrera con documento de identificación N° 0931344170 y por Katty Milena Cortez Paredes con documento de identificación N°1729781664, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Guayaquil, 29 de enero del año 2025.

Atentamente,

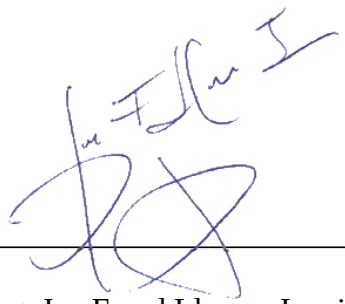

Ing. Joe Frand Llerena Izquierdo
0914884879

DEDICATORIA

Este proyecto es dedicado a mi amada abuela, por ser una base esencial en mi vida, por ser un modelo a seguir al ofrecerme siempre su apoyo, su sabiduría y su amor sin límites. Agradezco por mostrarme con tu guía la relevancia de la entrega, la constancia y la generosidad. Este éxito es tanto tuyo como mío, ya que, sin tus palabras motivadoras y tu confianza en mí, este trayecto habría sido considerablemente más complicado.

Jefferson Ismael Davalos Carrera

Le quiero dedicar este trabajo a mis amados padres, que con su crianza y amor pude desarrollar el carácter para enfrentar las dificultades de la carrera, a mis compañeros por ser mi equipo de trabajo en cada proyecto que hemos desarrollado y a mi pareja por ser mi lugar seguro en los momentos tristes.

Katty Milena Cortez Paredes

AGRADECIMIENTO

Deseo agradecer de todo corazón a mi familia por su amor eterno, ayuda y respaldo inagotable en cada fase de mi existencia. Son mi mayor motivación y pilar, y este triunfo lo compartimos con igual mérito. A todos mis amigos, agradezco su presencia, apoyo y por compartir conmigo tanto los momentos felices como los desafiantes. Vuestra amistad ha hecho que este camino sea una vivencia única, repleta de enseñanzas y recuerdos especiales. Agradezco a cada persona que ha estado a mi lado y ha confiado en mí. Este éxito no habría sido alcanzado sin su valioso apoyo.

Jefferson Ismael Davalos Carrera

Quiero agradecer hoy en día, primero, a mis padres por brindarme apoyo emocional y económico para poder estar en el lugar que estoy; segundo, a la universidad por brindarme conocimientos que practicaré en mi vida profesional; y tercero, a mí misma por tener la determinación de seguir.

Katty Milena Cortez Paredes

RESUMEN

El problema de la desnutrición infantil tiene un alto impacto en el Ecuador, provoca graves consecuencias en la salud de los infantes, siendo una de las más significativas el riesgo de muerte. A lo largo del análisis, se deben de tener en cuenta muchas variables para su comprensión, ya que sin duda representa un problema a nivel mundial que no se puede dejar de lado. Primero, debemos poner atención en el árbol genealógico. La familia juega un papel crucial, ya que ayuda a detectar enfermedades que se pueden presentar. También es importante subrayar que la salud de la madre antes del embarazo es otro enfoque que debe tratarse, debido a que esto condiciona el desarrollo de un niño y el estado nutricional en el cual debe estar después de su nacimiento y al crecer. Por otro lado, las métricas y mediciones de la Organización Mundial de la Salud se vuelven críticas al examinar el estado nutricional del niño; estos incluyen el peso, la edad, la altura y la circunferencia, que sirven como indicadores fundamentales básicos para medir si el niño es normal o sufre de desnutrición. Estas variables también nos sirven para establecer criterios que se utilizan como guías para el análisis y diagnóstico de este problema. Adicionalmente, gracias a esta recopilación, se vuelve posible construir modelos de aprendizaje automático que pueden reconocer tendencias y así permitir una mejor previsión. La implementación de estos modelos de machine learning no solo se centraría en la detección temprana de posibles casos de desnutrición, sino que también nos permite categorizar las posibles causas, como deficiencias nutricionales particulares o cualquier enfermedad relacionada; esto abre las posibilidades de diagnósticos mucho más personalizados y específicos para los pacientes que más lo necesitan.

En última instancia, el especialista nutricional puede utilizar estos modelos para analizar y gestionar una dieta específica o sugerir un mejor tratamiento para que el niño se recupere de deficiencias nutritivas o prevenir enfermedades que puedan afectarle. De esta manera, se pueden mejorar paralelamente los resultados clínicos y encontrar un mejor resultado en la salud del niño.

Palabras claves: malnutrición infantil, aprendizaje automático, métricas OMS, indicadores nutricionales, modelos predictivos, inteligencia artificial, Organización Mundial de la Salud.

ABSTRACT

The problem of child malnutrition has a high impact on the country and does not have positive consequences, one of the most significant consequences is that it can cause death.

Throughout the analysis, many variables must be considered for its understanding since it undoubtedly represents a global problem that cannot be ignored.

First, we must pay attention to the family tree. The family plays a crucial role as it helps to detect diseases that may occur, it is also important to underline that the mother's health before pregnancy is another approach that must be addressed, because this conditions the development of a child and the nutritional state in which he or she should be after birth and as he or she grows up. On the other hand, the metrics and measurements of the World Health Organization become critical when examining the nutritional status of the child, these include weight, age, height and circumference, which serve as basic fundamental indicators to measure whether the child is normal or suffers from malnutrition, these variables also serve to establish criteria that are used as guidelines for the analysis and diagnosis of this problem.

Additionally, thanks to this collection, it becomes possible to build machine learning models that can recognize trends and thus enable better forecasting. The implementation of these Machine Learning models would not only focus on early detection of possible cases of malnutrition, but also allow us to categorize possible causes, such as particular nutritional deficiencies or any related diseases, which opens up the possibilities of much more personalized and specific diagnoses for the patients who need it most.

Ultimately, the nutritional specialist can use these models to analyze and manage a specific diet or suggest a better treatment for the child to recover from nutritional deficiencies or prevent diseases that may affect the child, thus, in parallel, improving clinical outcomes and finding a better health outcome for the child.

Key words: Child malnutrition, Machine Learning, WHO metrics, Nutritional Indicators, Predictive models, Artificial Intelligence, World Health Organization.

ÍNDICE DE CONTENIDO

1. INTRODUCCIÓN 10
2. REVISIÓN DE LITERATURA 11
2.1. Machine Learning 13
2.2. Tipo machine learning 14
2.3. Machine Learning en la salud 14
2.4. Machine Learning en la salud nutricional en infantes 15
2.5. Predicción de malnutrición infantil por causa de la inseguridad alimentaria 16
2.6. Aplicaciones móviles para seguir con el crecimiento y cuidado nutricional del bebé 17
3. METODOLOGÍA 18
3.1. Métodos 20
3.1.1. Criterios de inclusión y exclusión 20
3.1.2. Selección de estudios 20
3.1.3. Fuentes de datos y estrategias de búsqueda 21
3.1.4. Extracción de datos 23
3.2. Tipo de investigación 24
3.3. Nivel de investigación 24
3.4. Métodos de investigación 24
4. RESULTADOS 24
5. DISCUSIÓN 28
6. CONCLUSIÓN 29
REFERENCIAS 30

1. INTRODUCCIÓN

La desnutrición infantil constituye indudablemente un problema a nivel mundial, afectando de manera amenazante para la salud pública ecuatoriana, sobre todo por lo que respecta a la población indígena y aislada, dado que los indicadores de desnutrición crónica en personas de corta edad son extraordinariamente elevados (Diop et al., 2025). Lo que, por un lado, va a dificultar el crecimiento físico y el desarrollo cognitivo (Julia Sánchez-Calderón et al., 2023). Por otra parte, determinará que en mayor medida enfermen y que, a la vez, implica un factor que contribuye a la permanencia de los ciclos de pobreza y a limitar su evolución futura. Aunque hay una cierta serie de procedimientos estatales, así como las acciones que se han estado ejecutando en diversos planes específicos, de modo que dar respuesta a esta situación problemática, las deficiencias que al respecto se derivan de no ejecutar una serie de evaluaciones nutricionales adecuadas y de formularlas de acuerdo con criterios totalmente coherentes en el mismo momento en el que son realmente necesarias siguen existiendo en un considerable sentido, especialmente en las zonas más frágiles económicamente.

En términos de métodos de evaluación nutricional, y de acuerdo con los principales indicadores antropométricos, tales como el peso, la altura y su comparación con las tablas de referencia de la OMS, son en líneas generales considerados instrumentos apropiados (Açar & Köksal, 2025).

A la vez, son evidentes las limitaciones de su aplicación en la práctica. Se trata de la necesidad de la formación especializada del personal, el acceso limitado a los dispositivos especializados y, en ocasiones, la interpretación incorrecta de estos datos que puede conducir a errores o retrasos en el diagnóstico (Açar & Köksal, 2025). Además, no siempre estos métodos pueden, en su complejidad, analizar la problemática total que acompaña este fenómeno, eludir la atención a factores estructurales y sociales que están a su base.

La situación en las zonas rurales de Ecuador, como en la Amazonía, presenta desafíos en el acceso a la atención médica y la alimentación (Murphy et al., 2023). La falta de infraestructura y personal capacitado agrava la situación, junto con las complicaciones geográficas. Se precisan acciones tecnológicas para supervisar de manera más eficaz el nivel de alimentación infantil en periodos cruciales para actuar con mayor influencia. En tal sentido, la IA se presenta como una nueva posibilidad que puede ser una mejora para los procesos tradicionales. El uso de IA es, entre otras cosas, la manera de abordar MacCoy, que permite analizar cantidades masivas de datos y encontrar patrones que no serían detectables mediante métodos convencionales. Esto

permite ampliar el análisis de los riesgos potenciales que se presentan relacionados con la alimentación hasta conseguir formas de llevar a cabo estrategias más eficaces y realizarse en el momento más correcto.

Especialmente, los procedimientos automatizados, como el Refuerzo de Gradiente (GB). Por ejemplo, los modelos avanzados como XGBoost pueden analizar información de crecimiento y medidas del cuerpo para prever con certeza posibles dificultades nutricionales en niños pequeños.

El objetivo central del estudio consiste en conocer la manera de usar la IA para anticiparse a las problemáticas alimentarias emergentes en la primera infancia a partir de las pautas de crecimiento de la OMS. Tras determinar la información previa y la generación de un nuevo procedimiento, se analiza la efectividad de ese nuevo procedimiento respecto a los habituales procedimientos de control nutricional. También, se busca evidenciar el efecto positivo que esta novedad puede reportar sobre el aumento de la exactitud de las pruebas, el apoyo en la toma de decisiones sanitarias y la contribución a formular políticas públicas más equitativas y eficaces.

La relevancia de esta perspectiva reside en su habilidad para enfrentar un dilema mundial como la desnutrición infantil (Diop et al., 2025). sobre todo, en entornos con limitación de recursos. Apoyando los propósitos de la OMS para el desarrollo sostenible, este proyecto busca adelantos en la tecnología de IA relacionada con la salud pública. Además, tiene como meta mejorar la vida de los niños en Ecuador, para asegurar un crecimiento y progreso saludable en las próximas generaciones.

2. REVISIÓN DE LITERATURA

En estos tiempos, la falta de nutrientes en los niños sigue siendo un gran problema global, con importantes impactos en el crecimiento y aprendizaje de los menores involucrados. Elevando el riesgo de contraer enfermedades debido a que no tendrían un sistema inmunológico lo suficientemente desarrollado.

Los retrasos en el diagnóstico y tratamiento pueden llevar a complicaciones graves que resulten en mortalidad infantil (Kebede Kassaw et al., 2023). Lo que subraya la urgente necesidad de identificar y abordar estas deficiencias de manera oportuna y eficaz.

Ecuador es considerado un país subdesarrollado; a pesar de su riqueza agrícola y cultural, la malnutrición infantil continúa expandiéndose, lo que ha causado alarma a nivel gubernamental y comunitario (Julia Sánchez-Calderón et al., 2023).

La mayoría de las deficiencias nutricionales de los niños de la Amazonía ecuatoriana están relacionadas con el acceso limitado a alimentos diversos y la falta de educación alimentaria de los padres (Murphy et al., 2023).

En un experimento a cargo de Weigel, se investigó la calidad de la dieta de infantes en hogares de Ecuador, descubriendo que un cuarto de los hogares vivía al límite de la inseguridad alimentaria, mientras que un quinto enfrentaba esta problemática de manera más intensa. Cabe señalar que las criaturas examinadas oscilaban entre los 48 y 59 meses de vida, presentando una preponderancia de individuos de sexo masculino. La data resalta la envergadura del dilema de la insatisfacción alimentaria en la niñez ecuatoriana y su presumible influencia en el progreso infantil (Weigel & Armijos, 2023).

También se ha demostrado en otro estudio realizado por Rodríguez y Salinas, que evaluaba los niveles de desnutrición en Ecuador en los años de 2013 a 2019, que las regiones más afectadas son la sierra y costa, presentando la mayor tasa de incidencia de malnutrición (Rodríguez Novillo & Salinas Quintuña, 2023).

Los factores sociales y económicos han sido las principales causas de la malnutrición infantil en nuestro país (Guamán & Duy, 2023). Entonces subrayando lo anterior, se necesitaría una solución que nos ayude en la predicción y el diagnóstico de cuando se siguen caminos de desnutrición y a su vez uno que esté al alcance de todos; aquí es donde entra la tecnología del nuevo mundo para facilitar estas tareas.

El hambre, un dilema sistémico sin fronteras claras. En un ámbito inusual, analizando la vitalidad de 140 individuos en un centro médico en Bratislava. Fusionando el poder del índice de corpulencia y un sondeo nutricional, emergió un hallazgo curioso: el 71. Meramente el 4% de individuos demostraron predisposición hacia desnutrición severa, enlazada estrechamente con índices de masa corporal disminuidos, promediando 16.5 kg/m². Malabsorción, cáncer e inflamación intestinal se hallan como las condiciones más comúnmente asociadas. (GAZDIKOVA et al., 2024).

El uso de modelos de ML representa una oportunidad para superar las limitaciones de métodos tradicionales como la antropometría; con estos modelos podemos analizar patrones complejos en grandes conjuntos de datos, mejorando la precisión en la detección temprana de riesgos nutricionales. La desnutrición tiene una alta prevalencia en niños menores de cinco años con neumonía en nuestra localidad. Tiene efectos adversos sobre los resultados y la mortalidad hospitalaria de esos niños. La omisión de la obligatoriedad de vacunas, la aparición de sepsis y la infusión sanguínea destacaron como factores pronosticadores de deceso en infantes desnutridos con neumonía (Gamal et al., 2023). En el vasto dominio de la nutrición, surge la malnutrición como una anomalía en el equilibrio nutricional. Ya sea por déficit o exceso de nutrientes, este estado atípico impacta de manera significativa en la infancia, influyendo en más de la mitad de las defunciones infantiles. Su presencia perturba la estancia hospitalaria, incrementa la morbilidad, afecta la calidad de vida y conlleva gastos adicionales. En el intrincado contexto de la hospitalización, la cifra del 52% resalta como un dato revelador. Una minúscula fracción de los niños sometidos a escrutinio reveló deficiencia severa en nutrientes según la escala de Gómez; al mismo tiempo, un porcentaje considerable sucumbió ante la misma (Şahin & Energin, 2023).

La desnutrición infantil puede causar un retraso en el crecimiento infantil; por ende, se sugiere la ejecución de políticas y programas nutricionales (Sadler et al., 2022). En cambio, la malnutrición afecta el sistema inmunológico infantil y su relación con infecciones, destacando las estrategias nutricionales para mejorar la salud, la deficiencia de micronutrientes esenciales tales como el zinc y la vitamina A que impactan la inmunidad adaptativa e innata (Morales et al., 2023).

En un estudio en una zona rural de Benín se determinó que el entorno alimentario de los niños menores de cinco años combina alimentos naturales y procesados. Los alimentos procesados tienden a ser menos perecederos debido a los métodos de conservación utilizados, como el enlatado, la deshidratación o el uso de conservantes químicos, y pueden causar malnutrición (Dogo et al., 2023).

2.1. Machine Learning

ML, o también conocido como aprendizaje automático, se lo puede definir como el proceso en que la máquina, ordenadores u otros dispositivos realizan una tarea o resuelven un problema.

ML es parte de la IA, y aunque no es el único campo de la IA, sí que es uno de los más relevantes y actuales (Puga, 2023; Rodriguez, 2023).

La IA es el campo donde se reúne todo lo referente a que las máquinas actúen o asimilen la inteligencia humana, mientras que el ML está centrado en cómo las máquinas pueden aprender a partir de experiencias y datos (Noj Pérez, 2024).

2.2. Tipos machine learning

Entre el mundo de las redes neuronales se pueden ver algunos tipos que se adaptan según las circunstancias:

- **Aprendizajes supervisados:** Es una de las formas más comunes y populares de ML tradicional. El sistema intenta derivar relaciones entre datos de entrada y datos de salida que se le ha concedido al sistema para el entrenamiento del modelo.
- **Aprendizajes no supervisados:** aquí la única forma de entrada concedida al sistema son los datos que no se han procesado, y este enfoque no utiliza una variable objetivo a la comparación del supervisado. Los sistemas funcionan descubriendo patrones no visibles a partir de los datos asignados sin ninguna ayuda humana.
- **Aprendizaje por reforzamiento:** este aprendizaje es similar a un tipo de autoaprendizaje por parte de la máquina con la adición de una entidad denominada “agente”; en resumen, su objetivo es identificar un camino de acción adecuado para maximizar las recompensas totales adquiridas por el agente, optimizando así también el rendimiento (K. Nair Akarsh, 2024).

2.3. Machine Learning en la salud

ML es una tecnología increíble que nos ayudará a crear algoritmos que puedan extraer información útil de los datos, ya sea explicación, clasificación o predicción (Pedrero et al., 2021). Por otro lado, frente a los métodos más habituales, que suelen enfrentarse a grandes limitaciones, el ML se presenta como una opción con un enorme poder de cambio a la hora de dar un resultado para la detección temprana de carencias alimentarias y muchas enfermedades que provocan una carencia de nutrientes. Al ser parte de la IA, el ML nos ayuda a hacer que las máquinas de oficina aprendan de los datos sin necesidad de programarlas directamente para cada tarea. De esta manera, los modelos aprenden de los datos, reconocen patrones dentro de ellos y hacen predicciones y toman decisiones que a veces superan las capacidades humanas.

Un muy buen ejemplo de esto es el proyecto de Heredia Menor, en Perú, quien comprobó que es posible detectar la anemia mediante el análisis de imágenes de uñas aplicando visión computacional y ML (Heredia-Menor & Mamani-Ticona, 2021). Este ejemplo junto a otro estudio confirma que el procesamiento de imágenes junto con redes neuronales convolucionales puede superar los métodos tradicionales en eficiencia y precisión para el diagnóstico de deficiencias nutricionales (Luna Becerra Jherson Isac, 2024).

La capacidad de analizar datos tan bien crea una oportunidad para resolver problemas urgentes, como detener la desnutrición infantil, mucho más rápido y mejor. En medicina, las estadísticas tradicionales dan una cifra sobre la probabilidad de que un paciente enferme. Estos modelos permiten a los profesionales de la salud anticipar y prevenir posibles enfermedades (Chamorro Villota, 2023).

El uso de ML para la detección de la malnutrición, destacando que los modelos supervisados, como bosques aleatorios y redes neuronales, son los más utilizados, aunque no han sido implementados en la práctica clínica. Nos ayudaría para la detección de desnutrición por medio de enfermedades que son comunes en adultos, estas son frecuentes en niños, especialmente en países en desarrollo.

La IA tiene el potencial de transformar el diagnóstico y manejo de la malnutrición, pero enfrenta barreras significativas como la falta de implementación práctica, la heterogeneidad de los datos y desafíos éticos y regulatorios, lo que limita su adopción en la práctica clínica (Janssen et al., 2024).

Esta herramienta, en lugar de amenazar con reemplazar a los profesionales de la salud, ofrece un enfoque que ayuda a alcanzar el logro de los objetivos de la nutrición (Bonilla et al., 2023). Los servicios de salud potenciados con IA pueden suponer mejoras importantes en términos de un seguimiento y una evaluación más automáticos, objetivos y continuos (Di Martino et al., 2023).

2.4. Machine Learning en la salud nutricional en infantes

Dicho anteriormente, el ML en la salud juega un papel importante en la predicción de datos, y si nos adentramos en el mundo nutricional tampoco nos quedamos vacíos; existen varias investigaciones sobre el uso de ML para mejorar la nutrición, prediciendo las calorías de los alimentos, como es el caso del proyecto de Pérez Ushiña, quien utilizó un modelo de red

neuronal basado en DenseNet201. para realizar predicciones y clasificaciones en un conjunto de datos de prueba, evaluando su precisión en comparación con las etiquetas verdaderas (Perez Ushiña, 2023).

En un estudio desarrollado por Carrión González, propone un modelo predictivo que ayudaría con la desnutrición infantil en infantes de la zona 5 (Santa Elena, Guayas, Los Ríos, Galápagos) en Ecuador. Para esto se utilizaron algoritmos de ML como regresión logística, árbol de clasificación, K-Nearest Neighbors, Random Forest y XGBoost. Los resultados obtenidos indicaron que XGBoost tiene la mayor precisión en la predicción de la desnutrición infantil en comparación con los otros algoritmos (Carrión, 2024).

Otro ejemplo, desarrollado en nuestro hermano país Perú, tenemos la investigación de caso de estudio realizado por Ramos y Santos, quienes implementaron un modelo de árbol de decisión para predecir variables del recién nacido, como sería el peso, edad, etc. A base de indicadores nutricionales de la madre como la ganancia de peso y su dieta nutricional (Ramos-Purihuaman & Santos-Rosales, 2024).

2.5. Predicción de malnutrición infantil por causa de la inseguridad alimentaria

La falta de alimentos es uno de los problemas extendidos a nivel global que tiene como consecuencia un impacto importante en la salud y el desarrollo de los niños, especialmente cuando están en sus primeros años de vida, que son clave para su desarrollo. El fenómeno impacta a cerca del 18,1% de los infantes en Cisjordania durante sus años escolares, íntimamente ligado a la merma de componentes alimenticios, como el peso, la altura y la corpulencia del niño. Tales deficiencias nutricionales inquietan, al alterar no solo la salud de la población joven, sino además repercutiendo en su desarrollo físico y mental durante la extensión de su juventud. Es fundamental explorar las raíces de la inseguridad alimentaria en este contexto (Qasrawi et al., 2024). Se ha mostrado que diferentes componentes como la crianza en casa, la situación económica de la familia, el dónde vive y el cuántos años tienen juegan un papel importante en garantizar una buena alimentación. Un claro ejemplo de lo dicho antes; sabemos que los pequeños que viven en áreas con más necesidades suelen estar más expuestos a no tener suficiente comida. Con esta suposición destacamos así la importancia de considerar el entorno social y ambiental al planificar acciones de apoyo nutricional.

La investigación nos muestra que el no recibir suficiente vitamina B1, K1, A y zinc puede provocar problemas serios relacionados con la falta de alimentos, como obstaculizar el

desarrollo, causar sobrepeso o extrema delgadez. Es importante ocuparse de la falta de alimentos y la disminución de peso, ya que la colina (un nutriente de la familia de las vitaminas B) y los carbohidratos son fundamentales en este proceso. Esto evidencia lo fundamental que es tener una estrategia de alimentación que se ajuste a través de la administración de una dieta personalizada para cada persona. El uso de la inteligencia artificial se sobresale como una herramienta eficaz para enfrentar estos problemas complicados. Los sistemas de ML, como el Random Forest, destacan por su eficacia en prever las tasas de malnutrición con increíble precisión, logrando un AUC de 0.996 en predicciones sobre retardos de crecimiento y mostrando resultados sobresalientes en medidas numéricas como sensibilidad y especificidad (Qasrawi et al., 2024). En otro estudio, el clasificador Random Forest demostró un desempeño superior en todas las métricas de evaluación, estableciéndolo como el modelo más efectivo para identificar la deshidratación en niños afganos menores de cinco años (Momand et al., 2023). Esto se debe a la destreza de estos sistemas para manejar numerosas interacciones y reconocer patrones complicados en grandes conjuntos de datos.

Basándonos en lo mencionado antes, se infiere que los sistemas de inteligencia artificial y aprendizaje profundo pueden ofrecer respuestas eficaces y adaptables para ayudar a los profesionales de la salud a detectar y tratar oportunamente a individuos en riesgo de desnutrición (Dadsetan et al., 2021).

2.6. Aplicaciones móviles para seguir con el crecimiento y cuidado nutricional del bebé

Con la ayuda de un modelo (ML), desarrollar aplicaciones puede resultar ser una herramienta efectiva para cuidar de los niños porque permite el análisis de datos personalizados y apoyo para proporcionar información valiosa. Es importante prestar atención a varios factores al realizar dicho análisis para asegurar que las decisiones y recomendaciones tomadas estén en el mejor interés del niño.

Aunque las métricas de la OMS son un punto de referencia válido, estas se derivan de promedios globales. Las características individuales del niño pueden no ser capturadas con precisión. Por lo tanto, las variables a analizar también deben incluir aspectos más detallados como:

- **Genética Familiar:** Es necesario considerar la altura promedio de la familia y la complexión, esto porque la genética es un factor importante en el desarrollo físico del niño.

• **Historial médico familiar:** Ciertas enfermedades hereditarias o condiciones genéticas que pueden afectar el crecimiento del niño son factores que deben ser considerados.

• **Condiciones durante la gestación:** Es importante evaluar si la madre fue atendida durante el embarazo. Esto incluye una nutrición adecuada, chequeos médicos constantes y la ausencia de factores de riesgo como estrés o enfermedades que podrían perjudicar al feto.

Estos elementos permiten la creación de un modelo más robusto y uno más adaptado a las necesidades individuales del infante, evitando generalizaciones que pueden resultar inútiles en algunos contextos. Así, una aplicación basada en ML no solo realizaría un análisis estándar de la información, sino que se centraría en los elementos específicos pertinentes al niño, maximizando su efectividad en el cuidado y desarrollo infantil.

> "Baby Home es una herramienta creada para empoderar a las familias en el monitoreo del crecimiento y el cuidado nutricional de los bebés, proporcionando algunas recomendaciones personalizadas basadas en estándares de la OMS tomando en base los datos ingresados por el usuario.", (Salazar-Acosta et al., 2022)

3. METODOLOGÍA

El enfoque principal de la investigación es orientar el problema de la falta de alimentación apropiada de los niños desde un enfoque sistemático y organizado. Se utiliza una metodología de investigación empírica y de enfoque analítico. Procederemos a utilizar la estrategia PRISMA, la cual permite un examen completo y estructurado de los principales documentos de la literatura ver Gráfica 1. Esto permite investigar y seleccionar estudios sobre los temas que rodean el problema de la falta de nutrientes, su identificación y las formas más eficaces de abordar el problema. Así mismo, el desempeño de varias técnicas de ML fue evaluado y comparado en la realización de la nutrición de los niños. Este análisis es acerca de tres elementos claves en los procesos de adquirir conocimiento; estas son: la enseñanza por asistencia, el autoaprendizaje y el enriquecimiento educativo.

El aprendizaje dirigido se centra en prever efectos basándose en la información previamente clasificada, en contraposición al aprendizaje no dirigido, que intentó hallar estructuras ocultas en datos sin categorizar. Adicionalmente, la perspectiva del aprendizaje por recompensa se centró en investigar cómo un sistema puede seleccionar las mejores alternativas mediante una retroalimentación constante. El objetivo de esta investigación era determinar qué técnica es más exacta, práctica y factible para ser utilizada en situaciones de cuidado de la salud y en comunidades con recursos escasos. Al alcanzar un balance adecuado entre estos atributos, se anticipa un avance en la identificación y tratamiento precoz de la falta de alimentación en los niños, favoreciendo así la salud y el contento de los niños.

Gráfica 1.

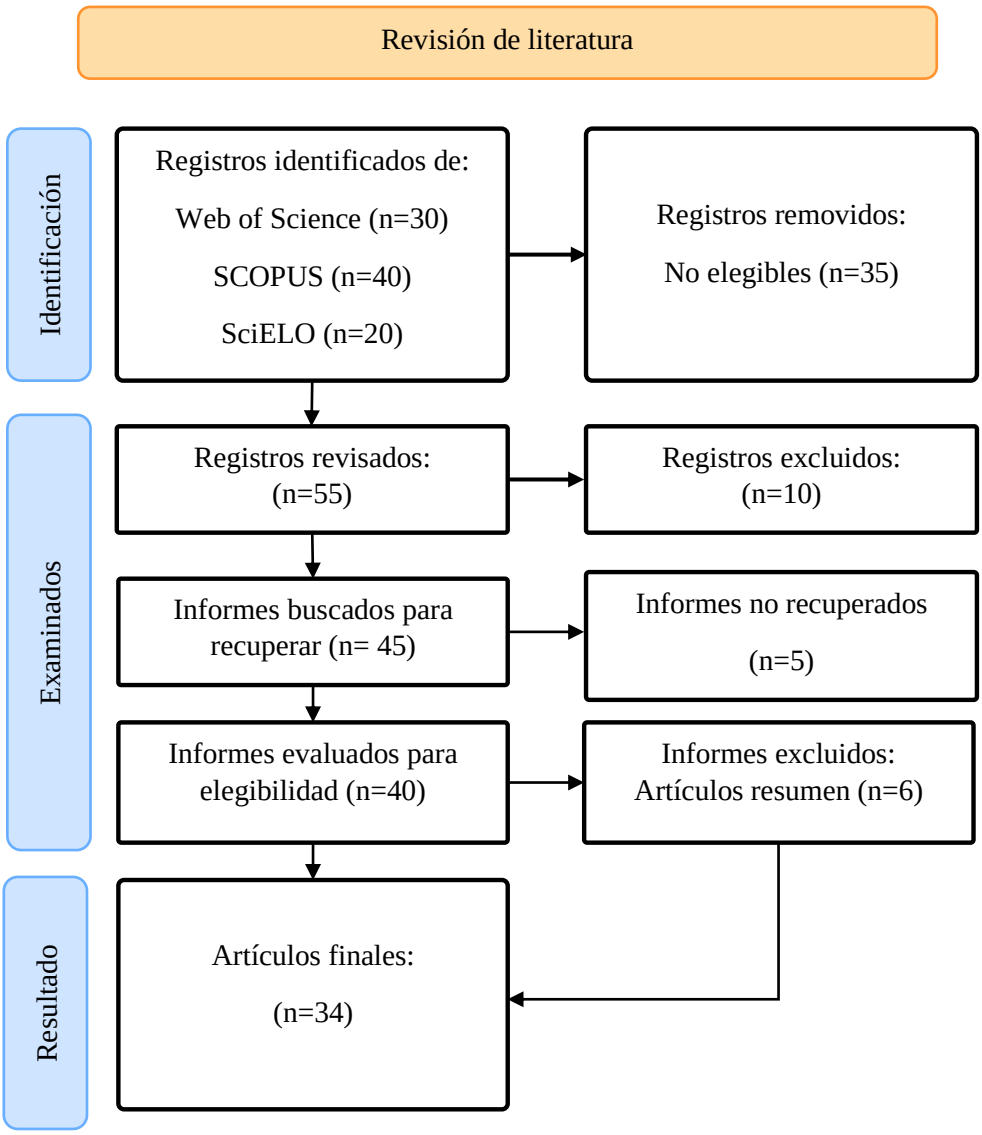

3.1. Métodos

A partir de nuestras preguntas de investigación presentadas previamente en nuestro marco hipotético, hemos concluido determinando los siguientes filtros para así obtener una fuente de artículos más concisa.

3.1.1. Criterios de inclusión y exclusión

Criterios de inclusión:

- Investigación centrada en descubrir carencias alimenticias en niños de manera prematura con la ayuda de modelos de aprendizaje automático.
- Uso de modelos de aprendizaje automático para analizar datos de salud y alimentación infantil, considerando variables como el peso, vitaminas, minerales, historial médico, entre otros.
- Análisis divulgado en revistas científicas evaluadas por expertos durante el lapso de los 4 últimos años.
- Estudios realizados en niños (0-5 años).

Criterios de exclusión:

- Estudio que no utilice un modelo ML en el análisis.
- Estudios que no se enfoquen en la detección temprana de deficiencias nutricionales o que traten exclusivamente sobre intervenciones posteriores.
- Estudio que no analice deficiencias nutricionales, sino otros tipos de condiciones médicas.
- Estudios que no se enfocan en niños del rango acordado (0-5 años).

3.1.2. Selección de estudios

- Fase 1: Se revisará título y resumen para así identificar si aporta algo al tema.
- Fase 2: Se analizará el texto completo para confirmar elegibilidad.
- Fase 3: Resolución de dudas mediante revisión conjunta entre los revisores, para llegar a una decisión final.

3.1.3. Fuentes de datos y estrategias de búsqueda ver Gráfica 2

- **Bases de datos a utilizar:**

UNICEF_WHO_WB_Global_Expanded_Databases_Overweight_May_2023.

Gráfica 2.

Dataset utilizado de acuerdo con UNICEF en el año 2023.

Joint Malnutrition Estimates — Weight-for-height >+2SD (Overweight) - Survey Estimates

Percentage of children under 5 years of age falling above 2 standard deviations (moderate and severe) from the median weight-for-height of the reference population

ISO	Countries and areas	UNICEF Regions	UN Regions	WHO Regions	World Bank Income Groups	Survey Year	Year*	Short Source	Full Source Title	Latest Estimate	Estimate Type	National					Ma		
												Point Estimate	Lower Limit	Upper Limit	Sample Size	Footnote	Point Estimate	Lower Limit	Upper Limit
AFG	Afghanistan	SA	Asia	EMRO	Low Income	1997	1997	MICS	Afghanistan 1997 multiple indicator baselir	Historical Trend	Adjusted	6.5			4846,0 cw 17				
AFG	Afghanistan	SA	Asia	EMRO	Low Income	2004	2004	NNS	Summary report of the national nutrition su	Historical Trend	External Reanalysis	4.6			946,0 w 18	6.3			
AFG	Afghanistan	SA	Asia	EMRO	Low Income	2013	2013	NNS	Afghanistan National Nutrition Survey 2013	Historical Trend	Reanalyzed	5.3	4.7	6.0	4247295,0 rs		4.9	4.3	5.6
AFG	Afghanistan	SA	Asia	EMRO	Low Income	2018	2018	Other	Afghanistan Health Survey 2018	Latest Source	Reanalyzed	4.1	3.5	4.8	19692,4 rs		4.0	3.3	4.9
ALB	Albania	EECA	Europe	EURO	Upper Middle Inc	2005	2005	MICS	Albania multiple indicator cluster survey 2(	Historical Trend	Reanalyzed	24.8	21.5	28.5	1075,3		24.5	20.4	29.3
ALB	Albania	EECA	Europe	EURO	Upper Middle Inc	2008-09	2009	DHS	Albania demographic and health survey 20	Historical Trend	Reanalyzed	23.2	20.3	26.5	1335,4		23.2	19.5	27.4
ALB	Albania	EECA	Europe	EURO	Upper Middle Inc	2017-18	2017	DHS	Albania Demographic and Health Survey 2(	Latest Source	Reanalyzed	16.4	14.5	18.5	2299,0		17.4	14.5	20.7
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Inc	1992	1992	PAPFAM	Enquête Algérienne sur la santé de la mèr	Historical Trend	Reanalyzed	8.7	7.8	9.7	4436,0 r		9.0	7.9	10.2
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Inc	1995	1995	MICS	Enquête nationale sur les objectifs de la m	Historical Trend	Reanalyzed	13.3	12.2	14.5	3295,0		13.9	12.3	15.7
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Inc	2000	2000	MICS	Enquête nationale sur les objectives de la	Historical Trend	Reanalyzed	14.7	12.6	17.1	4112,6		14.1	11.7	16.9
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Inc	2002	2002	PAPFAM	Enquête Algérienne sur la santé de la fami	Historical Trend	Reanalyzed	15.1	13.8	16.6	4130,8 r		15.7	13.7	17.9
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Inc	2006	2006	MICS	Suivi de la situation des enfant et des fem	Historical Trend	Reanalyzed	12.9	12.0	13.8	13648,6		13.4	12.2	14.6
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Inc	2012-13	2012	MICS	République Algérienne Démocratique et Po	Historical Trend	Reanalyzed	12.4	11.5	13.4	13668,5		12.9	11.7	14.1
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Inc	2018-19	2019	MICS	Enquête par grappes à indicateurs multiple	Latest Source	Reanalyzed	12.8	11.9	13.7	13928,1		13.4	12.1	14.7
AGO	Angola	ESA	Africa	AFRO	Lower Middle Inc	1996	1996	MICS	Inquento de indicadores multiplos (MICS) "	Historical Trend	Reanalyzed	1.7	1.2	2.5	1562,9 rs		2.2	1.4	3.6
AGO	Angola	ESA	Africa	AFRO	Lower Middle Inc	2015-16	2015	DHS	Inquérito de Indicadores Múltiplos e de Sa	Latest Source	Reanalyzed	3.4	2.8	4.0	7520,9		3.1	2.5	4.0
ARG	Argentina	LAC	Latin Ameri	AMRO	Upper Middle Inc	1994	1994	Other	The organisation of a national survey for ev	Historical Trend	Adjusted	11.1			5296,0 c				
ARG	Argentina	LAC	Latin Ameri	AMRO	Upper Middle Inc	1995-96	1996	Other	Encuesta antropometrica en menores de 6	Historical Trend	Adjusted	13.5			91943,0 c				
ARG	Argentina	LAC	Latin Ameri	AMRO	Upper Middle Inc	2004-05	2005	Other	Encuesta Nacional de Nutricion y Salud. A	Historical Trend	Reanalyzed	9.0	8.3	9.8	2528042,3 w 18		9.2	8.2	10.4
ARG	Argentina	LAC	Latin Ameri	AMRO	Upper Middle Inc	2018-19	2018	Other	Segunda Encuesta Nacional de Nutricion y	Latest Source	Reanalyzed	12.4	10.9	14.0	2912822,0 r		12.0	10.5	13.6
ARM	Armenia	EECA	Asia	EURO	Upper Middle Inc	1998	1998	Other	Armenia Health and Nutritional Status of C	Historical Trend	Reanalyzed	10.8	8.2	14.0	17836,9		10.4	7.6	13.9
ARM	Armenia	EECA	Asia	EURO	Upper Middle Inc	2000	2000	DHS	Armenia demographic and health survey 2(	Historical Trend	Reanalyzed	15.7	13.7	17.9	1468,2		19.4	16.7	22.3
ARM	Armenia	EECA	Asia	EURO	Upper Middle Inc	2005	2005	DHS	Armenia demographic and health survey 2(	Historical Trend	Reanalyzed	11.4	9.5	13.5	1299,4		13.3	10.5	16.7
ARM	Armenia	EECA	Asia	EURO	Upper Middle Inc	2010	2010	DHS	Armenia demographic and health survey 2(	Historical Trend	Reanalyzed	16.5	14.2	19.0	1367,1		18.3	15.2	21.9
ARM	Armenia	EECA	Asia	EURO	Upper Middle Inc	2015-16	2016	DHS	Armenia Demographic and Health Survey 2	Latest Source	Reanalyzed	13.7	11.5	16.2	1560,5		14.6	11.9	17.7
AUS	Australia	EAP	Oceania	WPRO	High Income	1995-96	1995	NNS	National nutrition survey Australia 1995. C	Historical Trend	Adjusted	7.9			1036810,0 bc				
AUS	Australia	EAP	Oceania	WPRO	High Income	2007	2007	Other	The 2007 national children's nutrition and p	Historical Trend	Reanalyzed	8.0	7.3	8.7	975,4 w 11		10.1	8.2	12.3

La base de datos que utilizaremos será la más reciente de UNICEF, publicada en mayo de 2023, titulada **"UNICEF_WHO_WB_Global_Expanded_Databases_Overweight_May_2023"**. En esta, se identificarán los datos más relevantes para un análisis y una interpretación precisos.

Gráfica 3.

Niños con mala nutrición según Unicef del año 2023.

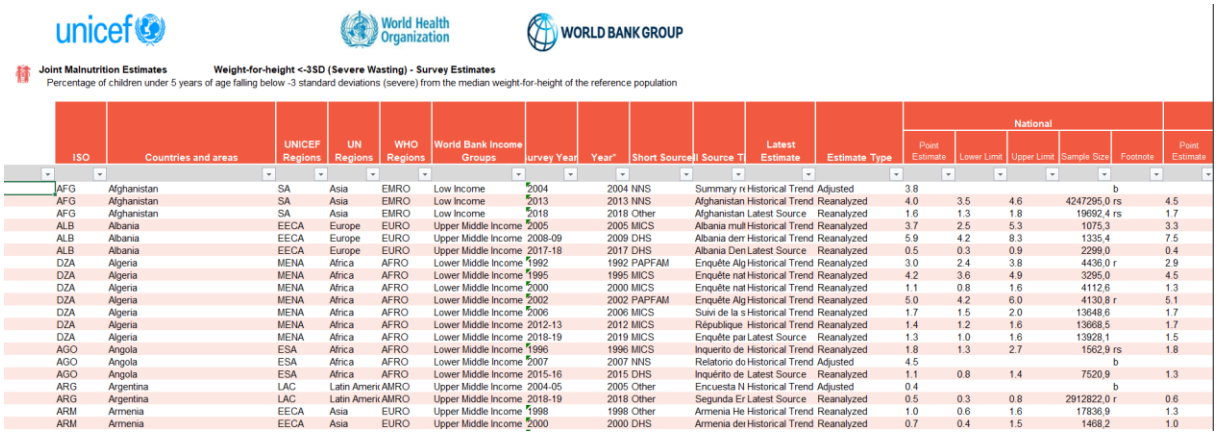

Joint Malnutrition Estimates — Weight-for-height <-3SD (Severe Wasting) - Survey Estimates

Percentage of children under 5 years of age falling below -3 standard deviations (severe) from the median weight-for-height of the reference population

ISO	Countries and areas	UNICEF Regions	UN Regions	WHO Regions	World Bank Income Groups	urvey Year	Year*	Short Source	ll Source Ti	Latest Estimate	Estimate Type	National					
												Point Estimate	Lower Limit	Upper Limit	Sample Size	Footnote	Point Estimate
AFG	Afghanistan	SA	Asia	EMRO	Low Income	2004	2004	NNS	Summary re	Historical Trend	Adjusted	3.8			b		
AFG	Afghanistan	SA	Asia	EMRO	Low Income	2013	2013	NNS	Afghanistan	Historical Trend	Reanalyzed	4.0	3.5	4.6	4247295,0 rs		4.5
AFG	Afghanistan	SA	Asia	EMRO	Low Income	2018	2018	Other	Afghanistan	Latest Source	Reanalyzed	1.6	1.3	1.8	19692,4 rs		1.7
ALB	Albania	EECA	Europe	EURO	Upper Middle Income	2005	2005	MICS	Albania mult	Historical Trend	Reanalyzed	3.7	2.5	5.3	1075,3		3.3
ALB	Albania	EECA	Europe	EURO	Upper Middle Income	2008-09	2009	DHS	Albania den	Historical Trend	Reanalyzed	5.9	4.2	8.3	1335,4		7.5
ALB	Albania	EECA	Europe	EURO	Upper Middle Income	2017-18	2017	DHS	Albania Den	Latest Source	Reanalyzed	0.5	0.3	0.9	2299,0		0.4
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Income	1992	1992	PAPFAM	Enquête Alg	Historical Trend	Reanalyzed	3.0	2.4	3.8	4436,0 r		2.9
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Income	1995	1995	MICS	Enquête nat	Historical Trend	Reanalyzed	4.2	3.6	4.9	3295,0		4.5
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Income	2000	2000	MICS	Enquête nat	Historical Trend	Reanalyzed	1.1	0.8	1.6	4112,6		1.3
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Income	2002	2002	PAPFAM	Enquête Alg	Historical Trend	Reanalyzed	5.0	4.2	6.0	4130,8 r		5.1
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Income	2006	2006	MICS	Suivi de la s	Historical Trend	Reanalyzed	1.7	1.5	2.0	13648,6		1.7
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Income	2012-13	2012	MICS	République	Historical Trend	Reanalyzed	1.4	1.2	1.6	13668,5		1.7
DZA	Algeria	MENA	Africa	AFRO	Lower Middle Income	2018-19	2019	MICS	Enquête par	Latest Source	Reanalyzed	1.3	1.0	1.6	13928,1		1.5
AGO	Angola	ESA	Africa	AFRO	Lower Middle Income	1996	1996	MICS	Inquerito de	Historical Trend	Reanalyzed	1.8	1.3	2.7	1562,9 rs		1.8
AGO	Angola	ESA	Africa	AFRO	Lower Middle Income	2007	2007	NNS	Relatorio do	Historical Trend	Adjusted	4.5			b		
AGO	Angola	ESA	Africa	AFRO	Lower Middle Income	2015-16	2015	DHS	Inquérito de	Latest Source	Reanalyzed	1.1	0.8	1.4	7520,9		1.3
ARG	Argentina	LAC	Latin Ameri	AMRO	Upper Middle Income	2004-05	2005	Other	Encuesta N	Historical Trend	Adjusted	0.4			b		
ARG	Argentina	LAC	Latin Ameri	AMRO	Upper Middle Income	2018-19	2018	Other	Segunda Er	Latest Source	Reanalyzed	0.5	0.3	0.8	2912822,0 r		0.6
ARM	Armenia	EECA	Asia	EURO	Upper Middle Income	1998	1998	Other	Armenia He	Historical Trend	Reanalyzed	1.0	0.6	1.6	17836,9		1.3
ARM	Armenia	EECA	Asia	EURO	Upper Middle Income	2000	2000	DHS	Armenia der	Historical Trend	Reanalyzed	0.7	0.4	1.5	1468,2		1.0

De acuerdo con la ver Gráfica 3, la descripción y análisis de los datos recopilados relacionados con la malnutrición infantil, basados en las estadísticas presentadas en la base de datos mencionada.

- **Dataset acoplado con la necesidad**

La información recopilada en la Tabla 1 sigue las sugerencias de la UNICEF para investigaciones sobre la alimentación de los infantes; se centra en mantener un conjunto de datos balanceado. Recopila datos tales como la edad, peso en kg, altura en cm, consumo diario de calorías en kcal y niveles de hemoglobina en g/dL. También se agrega un marcador simple para reconocer la escasez de nutrientes: 0=No, 1=Sí. Al reducir las características a las más importantes, se pretende simplificar el estudio y el entendimiento, garantizando que los hallazgos sean prácticos y fáciles de usar para tomar decisiones que apunten a identificar problemas con prontitud y actuar en consecuencia.

Tabla 1.

Nuevo dataset basado en parámetros de la UNICEF.

Age	Weight	Height	Caloric Intake	Hemoglobin	Nutritional Deficiency	Predictions
9	21.82 kg	139.51 cm	1267.99 kcal	11.42 g/dL	1	0
5	11.80 kg	131.35 cm	1174.86 kcal	13.59 g/dL	1	0
7	29.58 kg	60.75 cm	1661.76 kcal	14.50 g/dL	0	0
5	36.05 kg	66.41 cm	1875.07 kcal	13.92 g/dL	0	0
6	10.23 kg	134.11 cm	2394.54 kcal	11.44 g/dL	1	1
5	36.12 kg	98.04 cm	2223.52 kcal	14.70 g/dL	1	0
8	37.43 kg	118.85 cm	1584.92 kcal	9.81 g/dL	0	0
2	36.32 kg	109.22 cm	823.37 kcal	11.44 g/dL	0	0
9	28.02 kg	67.09 cm	2206.76 kcal	9.14 g/dL	0	0
6	11.45 kg	76.10 cm	1998.74 kcal	11.38 g/dL	0	1

- El código que se utiliza se encuentra bajo el lenguaje Python ver Gráfica 4

Gráfica 4.

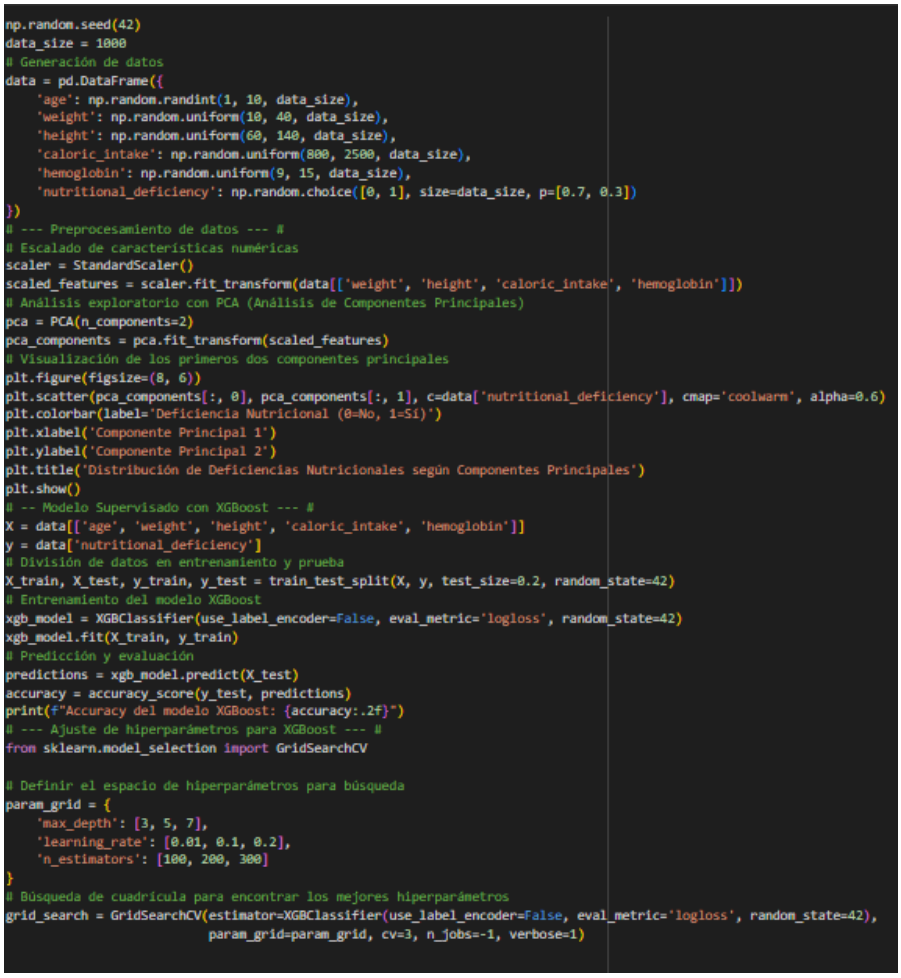

```python
np.random.seed(42)
data_size = 1000
# Generación de datos
data = pd.DataFrame({
    'age': np.random.randint(1, 10, data_size),
    'weight': np.random.uniform(10, 40, data_size),
    'height': np.random.uniform(60, 140, data_size),
    'caloric_intake': np.random.uniform(800, 2500, data_size),
    'hemoglobin': np.random.uniform(9, 15, data_size),
    'nutritional_deficiency': np.random.choice([0, 1], size=data_size, p=[0.7, 0.3])
})
# --- Preprocesamiento de datos --- #
# Escalado de características numéricas
scaler = StandardScaler()
scaled_features = scaler.fit_transform(data[['weight', 'height', 'caloric_intake', 'hemoglobin']])
# Análisis exploratorio con PCA (Análisis de Componentes Principales)
pca = PCA(n_components=2)
pca_components = pca.fit_transform(scaled_features)
# Visualización de los primeros dos componentes principales
plt.figure(figsize=(8, 6))
plt.scatter(pca_components[:, 0], pca_components[:, 1], c=data['nutritional_deficiency'], cmap='coolwarm', alpha=0.6)
plt.colorbar(label='Deficiencia Nutricional (0=No, 1=Sí)')
plt.xlabel('Componente Principal 1')
plt.ylabel('Componente Principal 2')
plt.title('Distribución de Deficiencias Nutricionales según Componentes Principales')
plt.show()
# -- Modelo Supervisado con XGBoost --- #
X = data[['age', 'weight', 'height', 'caloric_intake', 'hemoglobin']]
y = data['nutritional_deficiency']
# División de datos en entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
# Entrenamiento del modelo XGBoost
xgb_model = XGBClassifier(use_label_encoder=False, eval_metric='logloss', random_state=42)
xgb_model.fit(X_train, y_train)
# Predicción y evaluación
predictions = xgb_model.predict(X_test)
accuracy = accuracy_score(y_test, predictions)
print(f"Accuracy del modelo XGBoost: {accuracy:.2f}")
# --- Ajuste de hiperparámetros para XGBoost --- #
from sklearn.model_selection import GridSearchCV

# Definir el espacio de hiperparámetros para búsqueda
param_grid = {
    'max_depth': [3, 5, 7],
    'learning_rate': [0.01, 0.1, 0.2],
    'n_estimators': [100, 200, 300]
}
# Búsqueda de cuadrícula para encontrar los mejores hiperparámetros
grid_search = GridSearchCV(estimator=XGBClassifier(use_label_encoder=False, eval_metric='logloss', random_state=42),
                           param_grid=param_grid, cv=3, n_jobs=-1, verbose=1)
```

- **Términos de búsqueda**

  "Machine Learning", "nutritional deficiencies", "early detection", "childhood", "nutritional assessment", "clinical applications", "health programs", "predictive models".

3.1.4. Extracción de datos

Para la extracción de datos, determinamos criterios de inclusión y exclusión y definimos variables clave a extraer.

Datos clave a extraer

- Tipo de modelo de ML utilizado (e.g., redes neuronales, árboles de decisión, SVM, etc.).

- Variables nutricionales y clínicas consideradas en el modelo (e.g., peso, altura, análisis de sangre, hábitos alimenticios).
- Resultados obtenidos: precisión, sensibilidad, especificidad del modelo.
- Aplicaciones prácticas: uso en programas de salud infantil, integración clínica.
- Calidad metodológica: visualiza la evaluación del riesgo de sesgo.

3.2. Tipo de investigación

En este caso vamos a trabajar con datos y analizarlos, entonces el tipo de investigación de nuestro caso de estudio sería investigación aplicada con enfoque cuantitativo, porque nos enfocamos en resolver una problemática real con conocimiento ya existente como lo son los modelos de ML que se han ido utilizando anteriormente. Trabajaremos con datos cuantitativos como serían las métricas de la OMS.

3.3. Nivel de investigación

Este trabajo se utilizará a un nivel cuantitativo porque se pretende estudiar y analizar la problemática a través de diversos procedimientos de medición (Huanca, 2023).

3.4. Métodos de investigación

Este trabajo se enfoca en un método analítico-inductivo; buscaremos la principal causa de la malnutrición infantil a través de análisis de datos. Nos centraremos en la observación de patrones en datos existentes, tales como antropométricos, socioeconómicos y de salud, para así identificar factores de riesgo asociados a la malnutrición (Huanca, 2023).

4. RESULTADOS

Los resultados obtenidos nos proporcionan una visión detallada de los datos a través de distintos enfoques de ML y simulación, permitiendo explorar tanto modelos supervisados como no supervisados, además de una incursión en el aprendizaje por refuerzo.

1. XGBoost (modelo supervisado):

Para esta investigación se utilizó XGBoost para el entrenamiento del modelo e identificación de deficiencias nutricionales por edad, peso, altura, ingesta de calorías y niveles de hemoglobina. Los resultados mostraron una precisión bastante satisfactoria, lo que logra demostrar que XGBoost es muy eficiente para sistemas de clasificación binaria basados en este

contexto. Esta capacidad que se evalúa sobre el desempeño es crucial en la detección temprana y el diseño de estrategias de intervención.

2. KMeans (modelo no supervisado):

Con respecto al orden en el que fueron clasificados, utilizamos el algoritmo de KMeans clustering con varios tamaños de grupos para poder clasificar a los niños de acuerdo a su nutrición, donde en primera instancia, los datos fueron particionados en tres grupos y lograron alcanzar un índice de silueta bastante satisfactorio (0,75), evidenciando una gran diferenciación entre las diferentes clases. Al cambiar el número de conjuntos a 4, la formulación aún alcanza una buena clasificación del índice de Silhouette (0,62), lo que sugiere que una mayor división podría ser de mayor interés. Estos subgrupos podrían dar pistas sobre las diferentes deficiencias alimenticias y, por lo tanto, servir para el desarrollo de las estrategias nutricionales en cuestión.

3. Aprendizaje por refuerzo (simulación de optimización de hemoglobina):

Durante el estudio de aprendizaje por reforzamiento, se diseñó un ambiente virtual donde un personaje trataba de mejorar sus niveles de energía usando tres opciones: "descansar", "hacer ejercicio" o "no hacer nada". A lo largo de más de 50 situaciones diferentes, los personajes navegan por el entorno y obtienen premios por sus acciones basados en si logran llegar a un nivel óptimo de vitalidad. Los datos indican que el individuo podría mejorar sus premios al unirse a diferentes tareas que benefician la hemoglobina. Las bonificaciones cambian con cada evento y reflejan los logros y desafíos que enfrenta el individuo al intentar mejorar su salud con un dispositivo de medición de hemoglobina. Este ejemplo deja claro que el método de aprender mediante refuerzo es impredecible y que la eficacia de las decisiones del individuo cambia según la recompensa obtenida.

4. Visualización y análisis exploratorio:

Se aplicó PCA en el análisis de la información con el propósito de reducir la dimensión de los datos y facilitar el análisis de la relación entre las variables. Un diagrama de dispersión de los dos primeros componentes principales muestra la distribución de los niños identificados como desnutridos (referidos por 0 o 1) y da una idea aproximada de cómo pueden separarse las clases en los datos. También, al observar los Clusters derivados de KMeans, es más fácil ver cómo los niños pueden ser divididos de acuerdo a sus hábitos alimenticios para que se puedan realizar acciones particulares para cada grupo.

En una primera distribución se presentan los dos primeros factores principales obtenidos a través del análisis factorial principal. Visualiza la conexión entre la nutrición infantil y la falta de nutrientes, mostrando si estas características pueden distinguir adecuadamente a los niños con deficiencias de los que no las tienen ver Gráfica 5.

Gráfica 5.

Distribución de los componentes principales

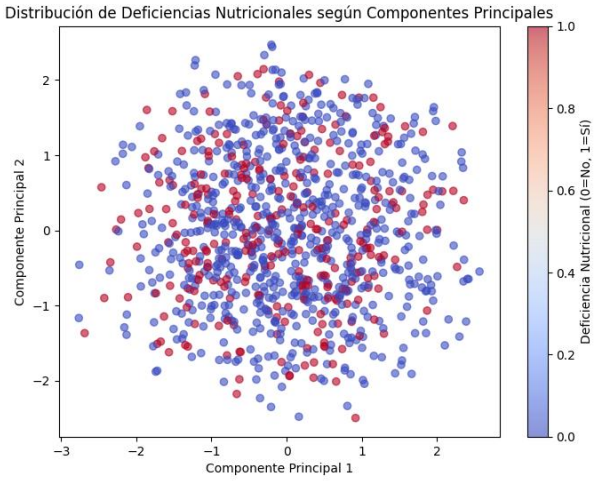

En esta representación visual de la Gráfica 5 de un algoritmo simple para agrupar la información de los niños en diferentes conjuntos basados en su estatura y peso, revela cómo los niños son categorizados basados en sus medidas corporales, destacando posibles conexiones con la nutrición.

Gráfica 6.

Segmentación con KMeans con 3 clusters.

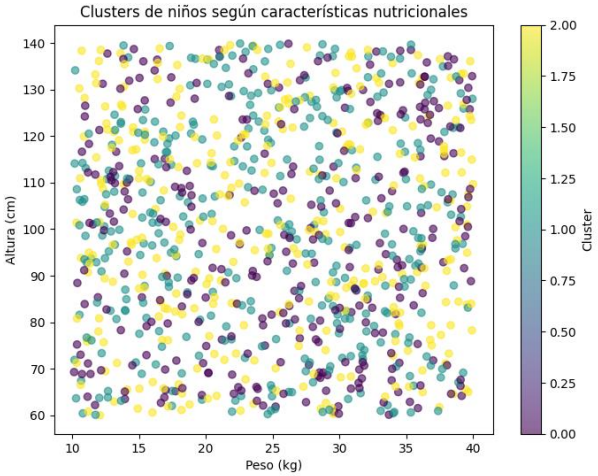

De forma parecida a la Gráfica 6 previa, se presenta la Gráfica 7. Utilizando KMeans con 7 clusters, se pueden comparar diferentes segmentaciones y analizar si una mayor segmentación con más grupos mejora la clasificación de las características nutricionales. Esto ayuda a entender si una división más detallada ayuda a diferenciar de mejor manera los grupos en términos de sus propiedades nutritivas.

Gráfica 7.

Segmentación con KMeans con 4 clusters.

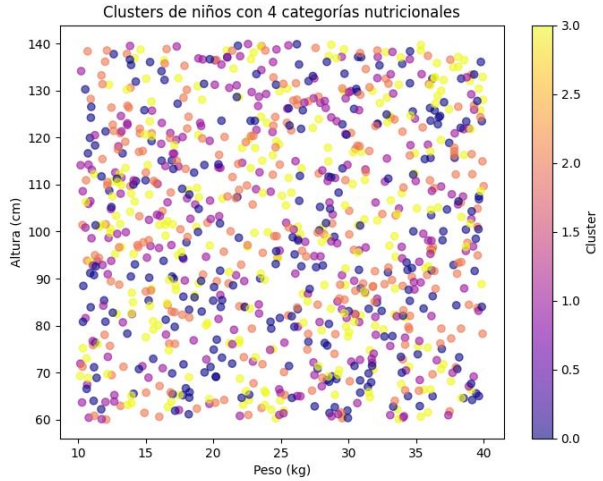

Por último, observamos la Gráfica 8 que ilustra la variación en las recompensas recibidas por el agente en cada fase mientras se entrenaba con refuerzo. Este gráfico te muestra de qué manera las decisiones del agente (tomar suplementos, hacer ejercicio o no hacer nada) afectan el resultado.

Gráfica 8.

Histograma de recompensas

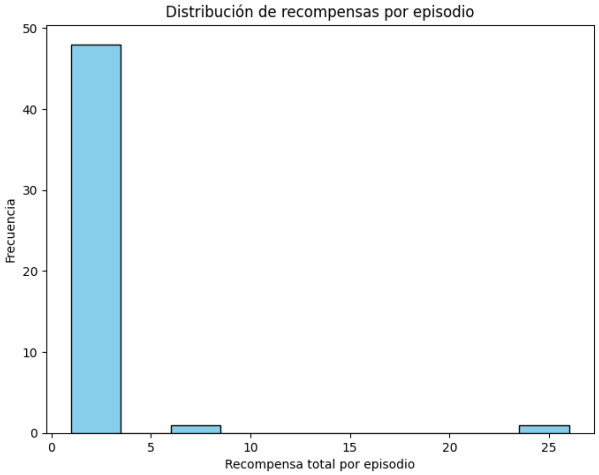

durante el proceso de aprendizaje, permitiendo analizar si el agente logra optimizar su conducta para aumentar los niveles de hemoglobina. Estas representaciones gráficas brindan una manera sencilla de examinar tanto los desenlaces de los modelos con guía y sin guía, como el rendimiento de un actor en un escenario de enseñanza por incentivos.

5. DISCUSIÓN

El planteamiento de esta propuesta que se presenta en el documento de una manera revolucionaria de lidiar con un dilema crítico en el bienestar infantil: detectar y abordar con prontitud las escaseces nutricionales en infantes menores de cinco años ha definido un proceso que combina la técnica de aprendizaje automático eficaz. A través de una táctica sobresaliente, emergió el esquema innovador XGBoost bajo supervisión, el cual detectó de manera eficiente a los pequeños con carencias, resaltando la premura de emplear tecnología de vanguardia para solucionar inconvenientes vinculados con la identificación de imágenes de manera veloz y precisa.

De esta manera, se contrasta con trabajos relevantes y forma favorable la detección en el bienestar de los niños que enfrentan problemas a nivel social o económico. De la misma manera, este tipo de datos que se obtienen son útiles para diseñar abordajes que puedan atender la heterogeneidad de cada población infantil en situaciones de riesgo.

El diseño puede expandirse y adaptarse fácilmente, lo que posibilita la ejecución de diversos niveles de fragmentación de manera clara, lo cual lo convierte en un recurso atractivo para el estudio de la alimentación y nutrición.

Una estrategia a nivel mundial que está siendo evaluada es el aprendizaje por refuerzo, el cual tiene como objetivo maximizar una función específica, como, por ejemplo, la hemoglobina. A pesar de que los hallazgos varían debido a múltiples razones, el enfoque se posiciona como una útil herramienta para decisiones acertadas al adaptarse a variadas circunstancias en niños. También, emplear PCA en el examen de información, así como en la amalgama y evaluación de premios, facilita la comprensión de los estudios. Estas ideas generan incertidumbre al cuestionar tanto la interpretación de los logros como la manera en que se deberían diseñar futuras acciones.

Es fundamental contar con información detallada y diversa para desarrollar modelos útiles en diversas circunstancias. Adicionalmente, es importante tener en cuenta las implicaciones éticas

y jurídicas vinculadas con el enfrentamiento y la protección de los individuos y su información (Romeo et al., 2020). Cuando se implementan nuevas ideas para mejorar la salud de los niños, es crucial considerar los valores éticos y asegurarse de que estén disponibles y se mantengan a lo largo del tiempo, especialmente en comunidades que enfrentan desafíos. Un informe llamado "Aprendizaje automático para predicción de anemia en niños menores de 5 años mediante el análisis de su estado de nutrición usando minería de datos" apoya la utilización de métodos avanzados en la detección temprana de carencias de nutrientes en infantes. El estudio implementó programas de inteligencia artificial, como Árboles de Decisión, para anticipar la anemia en niños menores de cinco años, obteniendo una tasa de precisión de más del 70% (Marcos Valdez et al., 2023). El análisis deja en claro lo útiles que pueden ser los sistemas de inteligencia artificial para detectar carencias de nutrientes en los niños.

6. CONCLUSIÓN

Este estudio trata sobre el uso de nuevas tecnologías, como el aprendizaje automático, para detectar y tratar disfunciones alimenticias en los niños de una manera más eficiente. Los enfoques que descomponen datos y reconstruyen comportamientos han sido efectivos para superar las limitaciones de los enfoques tradicionales. El abordaje de las disfunciones alimenticias a partir de estos enfoques nos permite contar con las evaluaciones y el plan de tratamiento más exactos y focalizados en cada uno de los niños. Esto lo hemos podido lograr en muchas partes donde la disponibilidad de alimentos adecuados para los niños es limitada.

Desacoplado de las maravillas tecnológicas de hoy, uno es libre de perseguir los medios y formular planes dirigidos a mejorar la situación de estos niños y sus familias.

Por otra parte, en la medida que se desea alcanzar resultados más evidentes en el tiempo, es fundamental diversificar las fuentes de información utilizadas y garantizar que los resultados respondan a la pluralidad de problemas que existen en la sociedad. Adicionalmente, se requerirá al menos un enfoque multidisciplinario que incluya profesionales de salud, educadores y formuladores de política pública para que dicho conocimiento se traduzca en acciones. Eso significa que se debe realizar el esfuerzo de diseñar las propuestas de manera que sean éticamente responsables, viables económicamente y culturalmente pertinentes.

En ese mismo contexto, este caso específico intenta justificar por qué es imprescindible explorar nuevas tácticas para combatir y reducir la malnutrición durante la infancia. No solo se

trata de números; nos referimos a oportunidades. Oportunidades para que todos los niños disfruten de un desarrollo sano, un crecimiento integral en el que se asegure el acceso a la nutrición y la calidad de vida.

REFERENCIAS

Açar, Y., & Köksal, E. (2025). Anthropometric Measurements and Laboratory Methods for Pregnancy: An Update Review to Evaluation of Body Composition. In *Current Nutrition Reports* (Vol. 14, Issue 1). Springer. https://doi.org/10.1007/s13668-024-00597-x

Bonilla, D. A., Daga, R., Gamero, A., Pérez-López, A., Pérez-Esteve, É., Pérez-Armijo, P., Petermann-Rocha, F., Lozano-Lorca, M., García-Galbis, M. R., Kouiti, M., Carrillo-Alvarez, E., Fernández-Villa, T., Apolinar-Jiménez, E., Nava-González, E. J., Benítez-Brito, N., & Almendra-Pegueros, R. (2023). Aplicaciones de la inteligencia artificial en la nutrición y dietética: Más allá de los asistentes virtuales. In *Revista Espanola de Nutricion Humana y Dietetica* (Vol. 27, Issue 4, pp. 250–252). Asociacion Espanola de Dietistas-Nutricionistas. https://doi.org/10.14306/renhyd.27.4.2054

Carrión, A. (2024). *Modelo predictivo de desnutrición infantil en el Ecuador: distrito zona 5*. https://repositorio.uteq.edu.ec/items/99b25f46-77c4-41ca-ac56-822a3708f496

Dadsetan, S., Rose, G., Hovakimyan, N., & Hobbs, J. (2021). *Detection and Prediction of Nutrient Deficiency Stress using Longitudinal Aerial Imagery*. www.aaai.org

Di Martino, F., Delmastro, F., & Dolciotti, C. (2023). *Explainable AI for Malnutrition Risk Prediction from m-Health and Clinical Data*. http://arxiv.org/abs/2305.19636

Diop, L., Gelli, A., Huybregts, L., Arsenault, J. E., Bliznashka, L., Boy, E., Deitchler, M., Lachat, C., Moursi, M., Ochoa-Avilés, A. M., Olney, D. K., & Becquey, E. (2025). The Minimum Dietary Diversity For Women Indicator Can Be Extended To Children And Adolescents aged 4-15 Years As A Proxy Population Indicator For Good Micronutrient Adequacy Of Diets In Low- and Middle-Income Countries. *Current Developments in Nutrition*, *9*(1). https://doi.org/10.1016/j.cdnut.2024.104508

Dogo, A., Hongbete, F., Edja, H., & Amoussa Hounkpatin, W. (2023). Characterization and challenges of food environments of children-under-five in north Benin drylands. *Journal of Agriculture and Food Research*, *14*, 100682. https://doi.org/10.1016/j.jafr.2023.100682

Gamal, Y., Mahmoud, A. O., Mohamed, S. A. A., I. Mohamed, J., & Raheem, Y. F. A. (2023). Prevalence and impact of malnutrition on outcomes and mortality of under-five years children with pneumonia: a study from Upper Egypt. *European Journal of Pediatrics*, *182*(10), 4583–4593. https://doi.org/10.1007/s00431-023-05138-2

GAZDIKOVA, K., FOJTOVA, A., WSOLOVA, L., NOREK, B., & SLOVACIKOVA, M. (2024). Nutritional status and risk of malnutrition. *Bratislava Medical Journal*, *125*(07), 399–403. https://doi.org/10.4149/BLL_2024_61

Guamán Zaruma Guadalupe, & Duy Quindi Mariana De Jesús. (2023). *Malnutrición infantil en niños menores de 10 años en el ecuador: una revisión sistemática.*

Heredia-Menor, K. A., & Mamani-Ticona, W. (2021). *Comparación de técnicas basadas en visión computacional y machine learning para la detección temprana de anemia a partir del análisis de uñas*. 151–164. https://doi.org/10.26439/ciis2020.5478

Huanca Macuri Daniel Elias. (2023). *Implementación de un modelo de análisis predictivo en el control de nutrición de los niños menores de 5 años del Centro de Salud de Uliachin, Chaupimarca - Pasco, 2023*.

Janssen, S. M., Bouzembrak, Y., & Tekinerdogan, B. (2024). Artificial Intelligence in Malnutrition: A Systematic Literature Review. *Advances in Nutrition*, *15*(9), 100264. https://doi.org/10.1016/j.advnut.2024.100264

Julia Sánchez-Calderón, M., Gerónimo Huerta-Concha, F., & Gisella Velásquez-Paccha, K. (2023). *Detección precoz de la malnutrición en niños de barrios periféricos y parroquias rurales de Montalvo, Ecuador*. http://portal.amelica.org/ameli/journal/213/2134288009/

Kebede Kassaw, A., Yimer, A., Abey, W., Molla, T. L., & Zemariam, A. B. (2023). The application of machine learning approaches to determine the predictors of anemia among under five children in Ethiopia. *Scientific Reports*, *13*(1). https://doi.org/10.1038/s41598-023-50128-x

K. Nair Akarsh. (2024). *Federated Learning: Principles, Paradigms, and Applications* (Jayakrushna Sahoo & Mariya Ouaissa, Eds.).

Leonardo Frederik Perez Ushiña. (2023). *Aplicaciones de machine learning para el análisis de comida modelos de aprendizaje automático para identificación de comida.* http://bibdigital.epn.edu.ec/handle/15000/25391

Leornado David Chamorro Villota. (2023). *Análisis de datos utilizando el modelo crisp-dm, caso de estudio factores que afectan la salud pediátrica.* https://repositorio.puce.edu.ec/items/c29c1e7a-4113-4598-9df1-876c85aba51f

Luna Becerra Jherson Isac. (2024). *Método de Clasificación Automática de Deficiencias Nutricionales en Hojas de Cafeto Mediante Procesamiento de Imágenes Digitales y Aprendizaje Profundo*. https://orcid.org/0000-0001-9972-8621

Marcos Valdez, A. J., Navarro Ortiz, E. G., Quinteros Peralta, R. E., Tirado Julca, J. J., Valentin Ricaldi, D. F., & Calderon-Vilca, H. D. (2023). Machine Learning for the Prediction of Anemia in Children Under 5 Years of Age by Analyzing their Nutritional Status Using Data Mining. *Computacion y Sistemas*, *27*(3), 749–768. https://doi.org/10.13053/CyS-27-3-4315

Momand, Z., Pal, D., Mongkolnam, P., & Chan, J. H. (2023). *A Machine Learning Approach to Detect Dehydration in Afghan Children*.

Morales, F., Montserrat-de la Paz, S., Leon, M. J., & Rivero-Pino, F. (2023). Effects of Malnutrition on the Immune System and Infection and the Role of Nutritional Strategies Regarding Improvements in Children's Health Status: A Literature Review. *Nutrients*, *16*(1), 1. https://doi.org/10.3390/nu16010001

Murphy, K. N., Boyce, L. K., Ortiz, E., Santos, M., & Balseca, G. (2023). Dietary Patterns of Children from the Amazon Region of Ecuador: A Descriptive, Qualitative Investigation. *Children*, *10*(9). https://doi.org/10.3390/children10091568

Noj Perez Franklin Orlando. (2024). *El-Impacto-De-Los-Compiladores-En-La-Era-De-La-Inteligencia-Artificial-Y-El-Aprendizaje-Automatico.*

https://www.researchgate.net/profile/Franklin-Noj-Perez/publication/380376445_EL_IMPACTO_DE_LOS_COMPILADORES_EN_LA_ERA_DE_LA_INTELIGENCIA_ARTIFICIAL_Y_EL_APRENDIZAJE_AUTOMATICO/links/663a1e7106ea3d0b742eee49/EL-IMPACTO-DE-LOS-COMPILADORES-EN-LA-ERA-DE-LA-INTELIGENCIA-ARTIFICIAL-Y-EL-APRENDIZAJE-AUTOMATICO.pdf

Puga Paredes, J. L. (2023). *Mapeo sistemático sobre el seguimiento del aprendizaje de estudiantes mediante el uso de la minería de datos educativos* [{B.S.} thesis]. https://dspace.ups.edu.ec/handle/123456789/26641

Qasrawi, R., Sgahir, S., Nemer, M., Halaikah, M., Badrasawi, M., Amro, M., Vicuna Polo, S., Abu Al-Halawa, D., Mujahed, D., Nasreddine, L., Elmadfa, I., Atari, S., & Al-Jawaldeh, A. (2024). Machine Learning Approach for Predicting the Impact of Food Insecurity on Nutrient Consumption and Malnutrition in Children Aged 6 Months to 5 Years. *Children*, *11*(7), 810. https://doi.org/10.3390/children11070810

Ramos-Purihuaman, K. C., & Santos-Rosales, Y. R. (2024). Predicción de la valoración del recién nacido según el estado nutricional materno: modelo basado en árboles de decisión. *Revista de Obstetricia y Ginecología de Venezuela*, *84*(02), 115–123. https://doi.org/10.51288/00840205

Rodriguez Diez Juan José. (2023). *Aprendizaje Automático en ciencia de datos*. https://www.ubu.es/sites/default/files/portal_page/files/leccion_inaugural_2023-2024.pdf

Rodríguez Novillo Kimberly Paola, & Salinas Quintuña María Gabriela. (2023). *Comportamiento de la malnutrición en los niños menores de 5 años en regiones del Ecuador entre los años 2013 y 2019*. https://dspace.uazuay.edu.ec/handle/datos/13830

Romeo, C., Guillén, E., Manuel Jerez, J., Nicolás, P., Carracedo, Á., Lapunzina, P., & Martín-Sánchez, F. (n.d.). *Inteligencia Artificial En Salud: Retos Éticos Y Legales*. www.institutoroche.es

Sadler, K., James, P. T., Bhutta, Z. A., Briend, A., Isanaka, S., Mertens, A., Myatt, M., O'Brien, K. S., Webb, P., Khara, T., & Wells, J. C. (2022). How Can Nutrition Research Better Reflect the Relationship Between Wasting and Stunting in Children? Learnings from the Wasting and Stunting Project. *The Journal of Nutrition*, *152*(12), 2645–2651. https://doi.org/10.1093/jn/nxac091

Şahin, S., & Energin, V. M. (2023). Yatarak Tedavi Gören Çocuk Hastalarda Malnutrisyon Değerlendirmesi. *Güncel Pediatri*, *21*(1), 69–76. https://doi.org/10.4274/jcp.2023.62681

Salazar-Acosta, I., Rugeles-Estupiñan, A. M., Quintero-Lesmes, D. C., & Castro-Monsalve, J. M. (2022). Aplicación móvil para el seguimiento del crecimiento y cuidado nutricional del bebé en hogares colombianos. *Salud UIS*, *55*(1). https://doi.org/10.18273/saluduis.55.e:23002

Weigel, M. M., & Armijos, R. X. (2023). Association of household food insecurity with developmental delay in preschool children: 2018 Ecuadorian Nutrition and Health National Survey. *Journal of Nutritional Science*, *12*. https://doi.org/10.1017/jns.2023.70