



## Bases para la aplicación de machine learning en el monitoreo y anticipación de crisis alimentarias en Centroamérica

Miguel Angel García-Arias<sup>1</sup>; Lorena Aguilar; Alfredo Tolón-Becerra<sup>2</sup>; Francisco J. Abarca-Álvarez<sup>3</sup>; Ronny Adrián Mesa-Acosta; José Manuel Veiga López-Peña

Recibido: 6 de abril del 2024 / Enviado a evaluar: 15 de abril del 2024 / Aceptado: 19 de julio del 2024

**Resumen.** El artículo ofrece una detallada y actualizada revisión sobre la aplicación de herramientas de ciencia de datos basadas en algoritmos de machine learning con el fin de predecir a corto y medio plazo la probabilidad de ocurrencia de crisis alimentarias en territorios de países con alta vulnerabilidad a este tipo de situaciones. Tras efectuar un breve repaso sobre la definición de seguridad alimentaria y sus métricas, se describen los principales esfuerzos internacionales para monitorear los factores agroclimáticos, económicos y sociopolíticos que más inciden en el deterioro alimentario de grupos de población o zonas geográficas concretas, y tras ello, generar alertas que desencadenen asistencia humanitaria que impidan el aumento del hambre y sus efectos en la salud de quienes la padecen. A partir de la revisión efectuada se propone un modelo de predicción adaptado al contexto los países Centroamericanos, en el que se consideran variables estructurales a ser utilizadas en la determinación anual de perfiles de vulnerabilidad alimentaria, así como otras sometidas a cambios permanentes y que por tanto permiten identificar shocks o perturbaciones que pueden impactar en la seguridad alimentaria. El modelo propuesto busca mejorar la toma de decisiones y la priorización de recursos y atención humanitaria en regiones con limitada disponibilidad de datos.

**Palabras clave:** Machine learning; crisis alimentarias; seguridad alimentaria; Centroamérica.

### [en] Basis for the application of machine learning in monitoring and anticipating food crises in Central America

**Abstract.** The article offers a detailed and updated review on the application of data science tools based on machine learning algorithms in order to predict the short and medium term probability of food crises in territories of countries with high vulnerability to this type of situation. After a brief review of the

---

<sup>1</sup> Universidad de Almería. Acción Contra el Hambre. Director regional América Central.

E-mail: [mgarcia@ca.acfspain.org](mailto:mgarcia@ca.acfspain.org)

<sup>2</sup> Área de Proyectos de Ingeniería. Universidad de Almería (España).

E-mail: [atolon@ual.es](mailto:atolon@ual.es)

<sup>3</sup> Universidad de Granada (España).

E-mail: [fcoabarca@ugr.es](mailto:fcoabarca@ugr.es)

definition of food security and its metrics, the main international efforts are described to monitor the agroclimatic, economic and sociopolitical factors that most affect the nutritional deterioration of population groups or specific geographic areas, and then generate alerts that trigger humanitarian assistance to prevent the increase in hunger and its effects on the health of those who suffer from it. Based on the review carried out, a prediction model adapted to the context of the Central American countries is proposed, in which structural variables are considered to be used in the annual determination of food vulnerability profiles, as well as others subject to permanent changes and that therefore allow the identification of shocks or disturbances that can impact food security. The proposed model seeks to improve decision-making and prioritization of resources and humanitarian assistance in regions with limited data availability.

**Keywords:** Machine learning; food crises; food security; Central America.

## [fr] Bases pour l'application du machine learning dans le suivi et l'anticipation des crises alimentaires en Amérique centrale

**Résumé.** L'article propose une revue détaillée et actualisée de l'application des outils de science des données basés sur des algorithmes d'apprentissage automatique afin de prédire à court et moyen terme la probabilité d'apparition de crises alimentaires sur les territoires des pays à forte vulnérabilité à ce type de crise. situations. Après un bref examen de la définition de la sécurité alimentaire et de ses paramètres, les principaux efforts internationaux visant à surveiller les facteurs agro-climatiques, économiques et sociopolitiques qui influencent le plus la détérioration nutritionnelle de groupes de population ou de zones géographiques spécifiques sont décrits, puis, génèrent des alertes qui déclenchent une aide humanitaire qui évite l'augmentation de la faim et ses effets sur la santé de ceux qui en souffrent. Sur la base de l'analyse réalisée, on propose un modèle de prévision adapté au contexte des pays d'Amérique centrale, dans lequel les variables structurelles sont considérées comme étant utilisées dans la détermination annuelle des profils de vulnérabilité alimentaire, ainsi que d'autres qui sont sujettes à des changements permanents. et que donc Ils permettent l'identification des chocs ou perturbations pouvant avoir un impact sur la sécurité alimentaire. Le modèle proposé vise à améliorer la prise de décision et la priorisation des ressources et des soins humanitaires dans les régions où les données sont limitées.

**Mots Clès:** Apprentissage automatique ; les crises alimentaires ; sécurité alimentaire; Amérique centrale.

**Cómo citar.** García-Arias, M.A., Aguilar, L., Tolón-Becerra, A., Abarca-Álvarez, F.J., Mesa-Acosta, R.A. y Veiga López-Peña, J.M. (2024): Bases para la aplicación de machine learning en el monitoreo y anticipación de crisis alimentarias en Centroamérica. *Anales de Geografía de la Universidad Complutense*, 44(2), 417-447.

**Sumario.** 1. Introducción. 2. Seguridad alimentaria, y sus métricas. 3. Sistemas de alerta temprana alimentaria. 4. Revisión de variables a predecir y variables predictoras en modelos de machine learning aplicados a la seguridad alimentaria. 4.1. Variables independientes o predictoros. 5. Propuesta de variables a ser consideradas en modelos de machine learning aplicados en Centroamérica. 5.1. Variables targets o dependientes sobre las que generar predicciones. 5.2. Variables independientes con las que establecer perfiles de vulnerabilidad. 5.3. Variables independientes o predictoras vinculadas a amenazas, perturbaciones o crisis. 6. Conclusiones y recomendaciones. 7. Referencias bibliográficas.

## 1. Introducción

Alimentarse, obtener suficiente energía para que el cuerpo y el cerebro funcionen bien es la necesidad humana más básica, junto con hidratarse, sin embargo, a lo largo de la historia ambas necesidades no han estado cubiertas para la mayoría de quienes nos

antecedieron (Norberg, 2017). Tampoco lo es en la actualidad para cerca de 282 millones de personas en 59 países y territorios que de acuerdo con el registro más detallado disponible proporcionado por el Global Report on Food Crises 2024 (FSIN, 2024) enfrentan niveles altos de inseguridad alimentaria aguda, y por tanto requieren de asistencia alimentaria. Según este mismo informe auspiciado por Naciones Unidas, la cifra de personas en este estado dobla las registradas en 2016, cuando se puso en marcha esta iniciativa de análisis de las crisis alimentarias a lo largo del mundo. En su cómputo del hambre, FAO estimó que en 2022 enfrentaron esta situación cerca de 800 millones de personas, esto es 122 millones más que antes de la pandemia (FAO, 2023). De los datos de este mismo informe para América Latina y Caribe se desprende que 247,8 millones de personas (37,5% de sus habitantes) en esta región experimentaron inseguridad alimentaria moderada o grave en 2022, mientras que la inseguridad alimentaria grave afectó al 12,6 % de la población (83,4 millones de personas) a lo largo de esta región (FAO et al., 2023).

Este artículo tiene por objetivo ofrecer un panorama general sobre los esfuerzos más actuales en la predicción de crisis alimentarias con el apoyo de nuevas herramientas de gestión de datos surgidas con el reciente desarrollo de la inteligencia artificial. Este propósito parte de la convicción de que disponer de información más precisa y conocer tendencias sobre los factores que provocan el hambre son el primer paso para enfrentar el desafío alimentario, proponer soluciones, valorar su impacto y focalizar recursos allí donde son más requeridos. El artículo se inicia con una revisión sobre la conceptualización del hambre y su definición técnica; la seguridad alimentaria. Tras ello, se efectúa una descripción crítica de las principales iniciativas internacionales focalizadas en el monitoreo de la situación alimentaria en países en los que son recurrentes las crisis humanitarias. En este trabajo se realiza una síntesis y discusión de artículos publicados en los últimos cinco años en los que se desarrollan modelos de predicción de la seguridad alimentaria aplicados a grupos de población vulnerables, territorios o países en su conjunto. En las publicaciones revisadas académicos de diferentes países adscritos a universidades u organismos internacionales como el Programa Mundial de Alimentos (WFP) o el Banco Mundial (WB) realizan predicciones de cuáles podrían ser los valores probables de seguridad alimentaria en zonas en las que no se dispone de información primaria, mediante el uso masivo de datos y la aplicación a los mismos de distintas técnicas y algoritmos de machine learning que son comparadas y evaluadas. El resultado de esta investigación es la formulación de una propuesta de un modelo de predicción de la seguridad alimentaria adaptado al contexto Centroamericano, región en la que se estima en 4.3 millones las personas en situación de inseguridad alimentaria severa (FAO et al., 2023) y de la que se dispone de mucha menos información en comparación con otras zonas del mundo. La propuesta de modelo compendia cuales deberían ser las variables target o a predecir, así como las variables independientes o predictoras. Finalmente, junto a las conclusiones se sugieren pautas para poner en práctica este modelo de predicción con la colaboración de diferentes instituciones interesadas en la cuestión alimentaria.

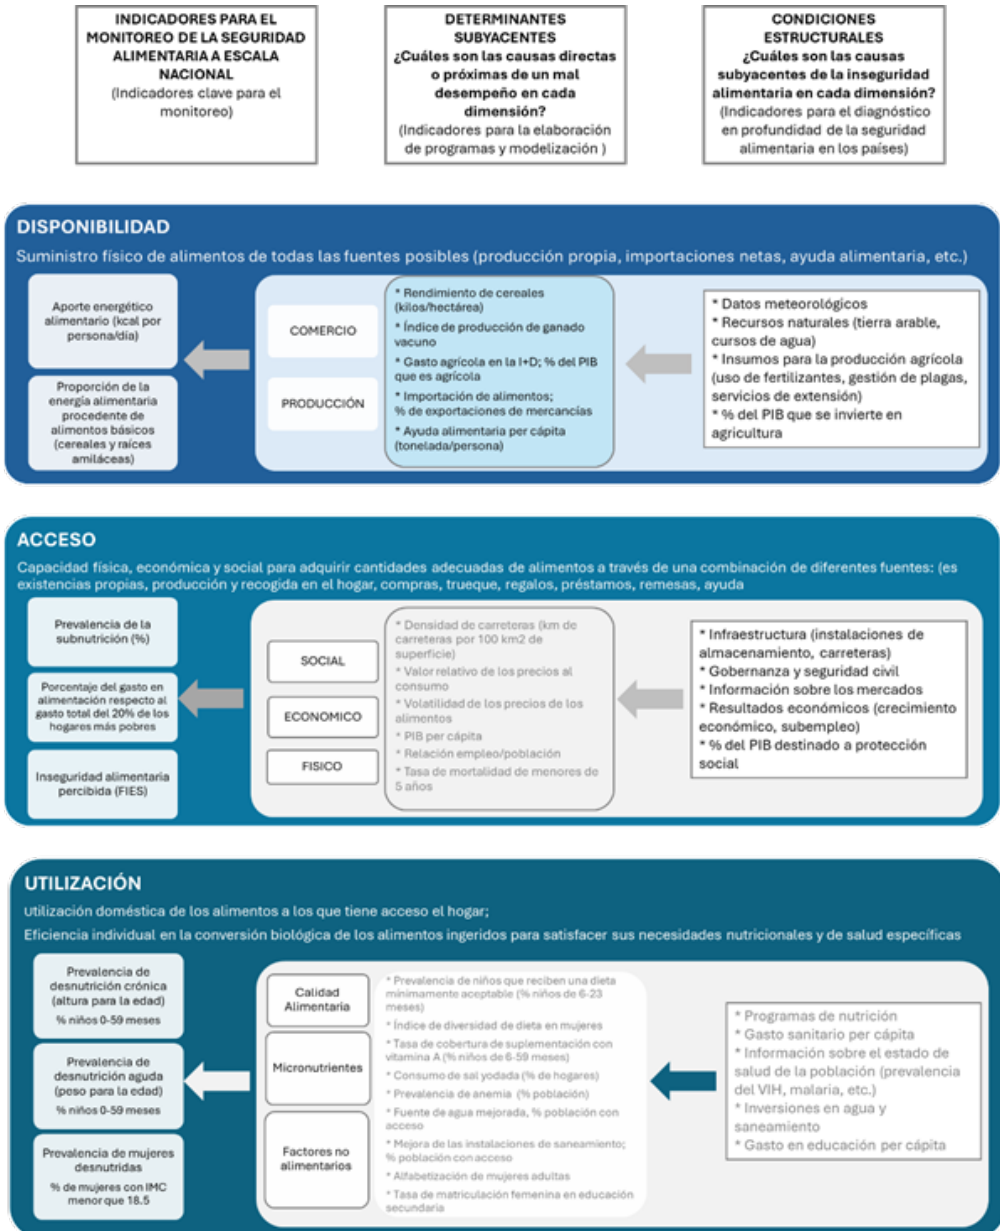
## 2. Seguridad alimentaria, y sus métricas

En la Cumbre Alimentaria Mundial de 1996 se define la seguridad alimentaria, afirmando que ésta se alcanza "cuando todas las personas tienen en todo momento acceso físico y económico a suficientes alimentos inocuos y nutritivos que satisfagan sus necesidades alimenticias y sus preferencias en cuanto a los alimentos para llevar una vida activa y sana". Inicialmente se consideró que la seguridad alimentaria abarcaba tres dimensiones; i) disponibilidad física de alimentos relacionada con la capacidad de producción, almacenamiento y comercio de los alimentos, y que abarca especialmente el ámbito nacional e internacional; ii) el acceso económico y físico a los alimentos que afecta especialmente a los hogares y viene dado por su capacidad económica para adquirir alimentos en los mercados; iii) la utilización de los alimentos: entendida como la forma en que el cuerpo aprovecha al máximo los diversos nutrientes de los alimentos ingeridos, y que está condicionado no solo por la cantidad, calidad y diversidad de los alimentos consumidos, sino también por buenas prácticas de cuidado y alimentación, preparación de los alimentos y distribución intrafamiliar de los alimentos, lo que combinado con una buena utilización biológica de los alimentos, determina el estado nutricional de quienes los consumen (FAO, 1996). En 2009 se añadió una cuarta dimensión; iv) estabilidad, la cual afecta a las tres primeras en tanto que una persona, familia o población pueda verse condicionada en su alimentación de manera periódica o estacional (Berry et al., 2015; FAO, 2009).

Esta variabilidad entre diferentes meses o estaciones es uno de los rasgos que se asocian a la inseguridad alimentaria, junto con la dependencia respecto de un gran número de variables de tipo climático, económico, productivo, o comercial, lo que dificultan su monitoreo en comparación con otras características socioeconómicas como la pobreza o el grado de educación promedio en una población, y que tienen una evolución más regular y menos sujeta a cambios bruscos (Martini et al., 2022).

La medición de la seguridad alimentaria en sus diferentes dimensiones, así como el seguimiento de los factores o variables que puedan incidir en la situación alimentaria de una persona, un hogar, un territorio o un país, en un momento dado, a lo largo del tiempo, o con el propósito de anticipar una potencial crisis, constituye un reto de enorme complejidad (Jones et al., 2013). Hoddinott (1999) contabiliza hasta 450 indicadores vinculados a distintos aspectos relacionados con la seguridad alimentaria. Aquellos que miden el estado alimentario de una persona o un hogar, y que por agregación y utilizando promedios, permiten caracterizar la situación alimentaria de un municipio, territorio o país. Incluyen por ejemplo las mediciones antropométricas como peso, talla y edad que combinados nos permiten establecer si un niño o adulto se encuentra en desnutrición crónica, aguda, estado normal o con sobrepeso.

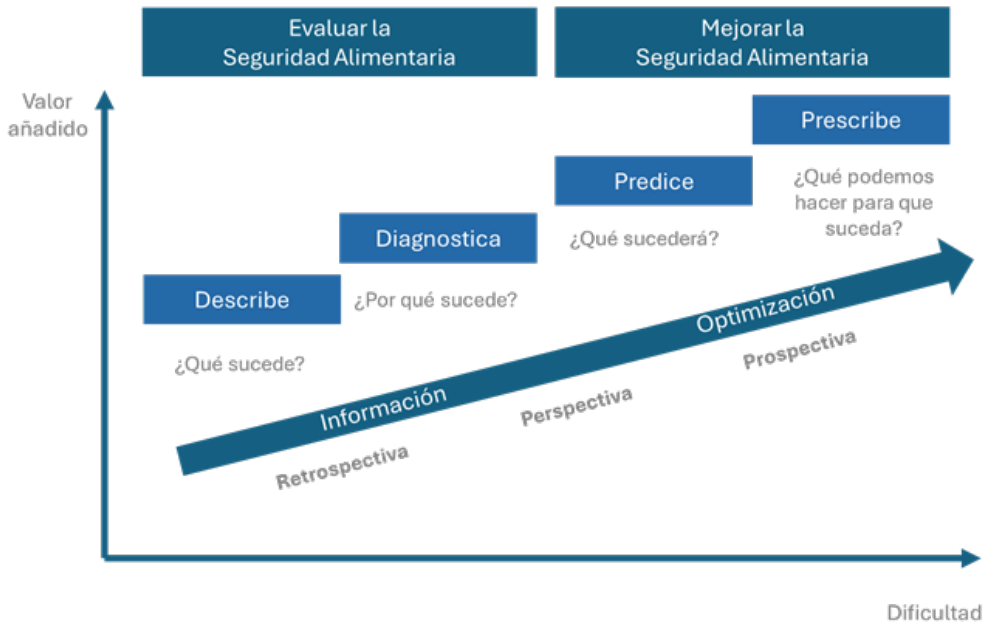
Figura 1. Propuesta de indicadores adaptados a diferentes dimensiones de la seguridad alimentaria.



Fuente: Elaboración propia, a partir de Aurino (2014).

Otros indicadores de este tipo serían la valoración de la diversidad alimentaria de los hogares (HDDS por sus siglas en inglés de Household Dietary Diversity Score), el puntaje de consumo de alimentos (FCS del inglés Food Consumption Score), la escala de acceso a la inseguridad alimentaria de los hogares (HFIAS del inglés Household Food Insecurity Access Scale), la escala de hambre en el hogar (HHS, acrónimo de Household Hunger Scale) o la escala de experiencia de inseguridad alimentaria (FIES, acrónimo de Food Insecurity Experience Scale), el índice de estrategias de supervivencia (CSI, acrónimo en inglés de Coping Strategies Index), incluida su versión reducida, rCSI (Deléglise et al., 2022). En la figura 1 se muestran las cuatro dimensiones de la seguridad alimentaria junto con indicadores que permiten su evaluación.

Figura 2. Modelo de Ascendencia Analítica de Gartner adaptado al ámbito de la seguridad alimentaria



Fuente: Elaboración propia, a partir de Kaut et al., (2022).

Kaut et al., (2022), en su revisión y síntesis sobre cómo la moderna ciencia de datos puede ayudar a la anticipación de crisis alimentarias, proponen una adaptación al ámbito de la seguridad alimentaria del Modelo de Ascendencia Analítica impulsado por la empresa Gartner (Laney y Kart, 2012). De acuerdo con estos autores el conocimiento sobre cualquier temática o desafío se puede acometer de forma gradual de manera que con una mayor cantidad de datos y profundidad de análisis podemos pasar de la simple descripción, al diagnóstico, la predicción y por último la capacidad de prescribir o recomendar acciones concretas para intervenir y obtener resultados

ante ese desafío en cuestión. Kaut et al., (2022) nos ofrecen un esquema general basado en Laney y Kart, (2012) en el que se muestra como los análisis sobre la seguridad alimentaria responden a preguntas cada vez más complejas, mientras que al responderlas se puede tener una mayor capacidad para intervenir en factores que inciden en la seguridad alimentaria (véase figura 2).

### **3. Sistemas de alerta temprana alimentaria**

De acuerdo con la agencia de Naciones Unidas para la Reducción del Riesgo de Desastres (UNISDR) un sistema de alerta temprana (SAT) es una iniciativa que busca anticipar y prevenir a la población, instituciones y autoridades sobre la ocurrencia de un desastre, y que abarca cuatro ámbitos interconectados: i) el conocimiento del riesgo asociado a un tipo determinado de desastre, a partir de la recopilación sistemática de datos y evaluaciones de impacto y daños asociadas a episodios previos; ii) el monitoreo permanente de variables asociadas con un tipo concreto de desastre, el análisis permanente de los datos obtenidos y la realización de pronósticos de amenazas y sus posibles consecuencias; iii) la difusión de alertas, esto es, información adaptada a diferentes públicos para que puedan tomar decisiones adecuadas con el fin de prevenir y mitigar daños asociados a un desastre; iv) la preparación de la población, empresas y diferentes instituciones para responder de manera adecuada a las diferentes alertas recibidas por un SAT (UNISDR, 2017).

Esta definición general también se adapta y aplica a la anticipación de crisis alimentarias mediante el monitoreo de variables que permiten establecer la probabilidad de que se produzca un determinado nivel de deterioro de la situación alimentaria de la población de un territorio o país. Este seguimiento debe asociarse con la correspondiente emisión de alertas y la adopción de medidas para evitar daños, que en el caso alimentario pueden asociarse a diferentes tipos de desnutrición, una merma en la salud de las personas más vulnerables, en especial niños y mujeres embarazadas y lactantes, e incluso el fallecimiento por hambre (Backer y Billing, 2021; Krishnamurthy et al., 2020b).

En las últimas décadas organismos internacionales como FAO y agencias para el desarrollo internacional de diferentes países como EE. UU. y la Unión Europea han impulsado distintas iniciativas de alerta temprana frente a la inseguridad alimentaria. El primer esfuerzo reseñable de este tipo fue el Famine Early Warning Systems Network (FEWS NET por sus siglas en inglés), promovido por USAID, la agencia de ayuda internacional del Gobierno de los EEUU.

A partir de 2011, FEWS NET incorporó en su proceso de análisis, que incluye hasta ocho etapas o pasos, las pautas establecidas por el sistema de Clasificación Integrada de las Fases de la seguridad alimentaria (CIF por sus siglas español e IPC por sus siglas en inglés) puesto en marcha con el liderazgo de FAO en 2004 y apoyado por otras agencias de Naciones Unidas, agencias de ayuda internacional de EEUU y la UE y ONGs internacionales (Jones et al., 2013). La CIF proporciona una guía técnica y protocolos tanto para monitorear variables asociadas a factores que

determinan la seguridad alimentaria, como para evaluar de manera consensuada variables de resultado que reflejan el estado de la seguridad alimentaria en una zona geográfica concreta o país (Frankenberger y Verduijn, 2011; IPC, 2019). La CIF establece cinco categorías o fases que reflejan un grado paulatino de deterioro alimentario tal y como se muestra en el cuadro 1 (IPC, 2019).

Cuadro 1. Escala de inseguridad alimentaria aguda por fases y principales rasgos que la definen (IPC, 2019)

<b>Fase 1 Seguro</b>	Los hogares son capaces de satisfacer sus necesidades alimentarias y no alimentarias esenciales, sin recurrir a estrategias inusuales e insostenibles para obtener ingresos económicos y acceder a los alimentos que requieren
<b>Fase 2 Estrés</b>	Los hogares tienen un consumo de alimentos mínimamente adecuado, pero no pueden permitirse algunos gastos no alimentarios esenciales sin recurrir a estrategias para hacer frente a una situación de estrés socioeconómico o ambiental
<b>Fase 3 Crisis</b>	Los hogares manifiestan; i) carencias en el consumo de alimentos que se reflejan en un incremento de la desnutrición aguda superior a la habitual; o bien; ii) son escasamente capaces de satisfacer sus necesidades alimentarias mínimas, y ello sólo lo logran mediante el agotamiento de sus medios de subsistencia esenciales o a través de estrategias para hacer frente a la crisis que limitan sus capacidades futuras de recuperación
<b>Fase 4 Emergencia</b>	Los hogares tienen; i) grandes carencias de consumo alimentario que se reflejan en una desnutrición aguda muy elevada y un exceso de mortalidad; o bien ii) son capaces de mitigar grandes déficits de consumo de alimentos pero sólo empleando estrategias de subsistencia de emergencia y liquidación de sus activos.
<b>Fase 5 Hambruna</b>	Los hogares tienen una carencia extrema de alimentos y/u otras necesidades básicas incluso después de emplear del todo las estrategias de supervivencia que aun tuvieran disponibles. Son evidentes las consecuencias del hambre, así como el aumento de la mortalidad, la pobreza extrema y niveles de desnutrición aguda muy elevados.

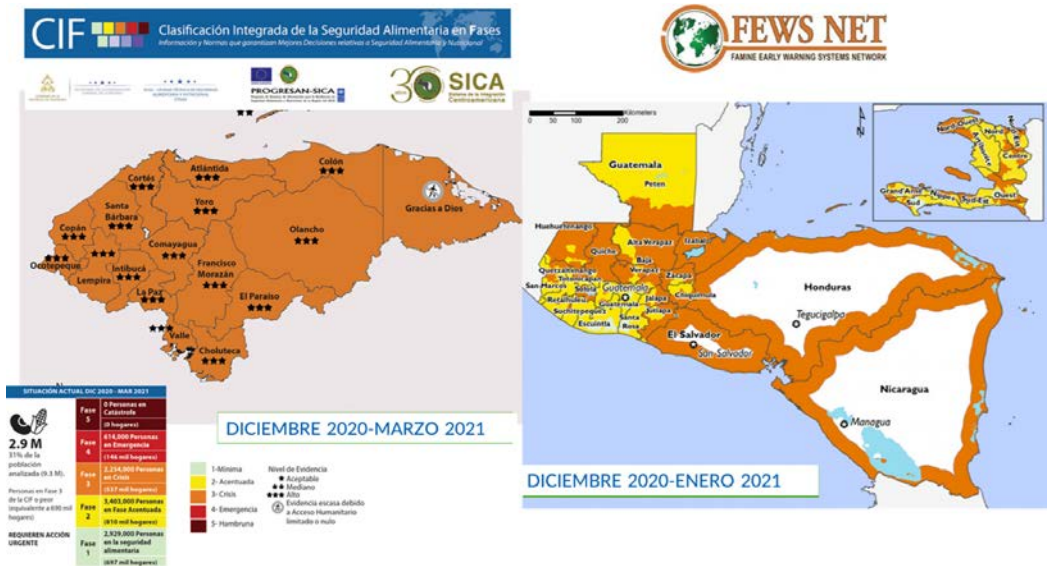
Fuente: Elaboración propia, a partir del IPCC (2019).

La CIF ha representado una importante mejora en la forma en que se aborda el seguimiento de la situación alimentaria de países propensos a crisis, sin embargo, no está exenta de críticas que se centran en la subjetividad asociada a la determinación del nivel de inseguridad alimentaria por medio de valoraciones sustentadas en



evidencias de limitada fiabilidad y representatividad (Kaut et al., 2022; Deléglise et al., 2022).

Figura 3. Mapas que reflejan los análisis de la CIF para Honduras en 2020 (izquierda) y para Centroamérica según FEWS NET (derecha). Puede apreciarse la dificultad que implica distinguir entre municipios e incluso departamentos.



El acceso regular a datos es uno de los grandes desafíos que enfrenta la CIF, en especial en países en los que las crisis son menos frecuentes, y por tanto se destinan menos recursos a la realización periódica de encuestas de hogar a partir de las cuales efectuar los análisis conjuntos de evidencias (Martini et al. 2022; Deléglise et al., 2022), lo que a su vez dificulta poder determinar a tiempo y con fines anticipatorios cuando se produce un cambio de fase hacia niveles mayores de deterioro alimentario. Otra crítica a la aplicación de la CIF radica en la opacidad que varios autores encuentran en el modo en que se adjudican las fases, en un proceso en el que algunos especialistas o instituciones que participan en los ejercicios de análisis conjunto de las evidencias disponibles pueden tener mucho mayor peso o influencia que otros, en ocasiones con una finalidad puramente política o de imagen, al tiempo que se echa en falta el uso de datos y herramientas estadísticas más sólidas (Backer y Billing, 2024; Lentz et al., 2019; Maxwell y Hailey, 2021; Oakford, 2019). Finalmente, en contextos en los que no se dispone de suficientes datos, como el Centroamericano, los análisis efectuados por la CIF y FEWS NET carecen de la granulometría mínima que los haga útiles en la toma de decisiones y en la priorización de territorios en los que concentrar apoyo, algo esencial cuando los recursos son limitados (Lentz et al., 2019; Westerveld et al., 2021). Véase por ejemplo la figura 4 en la que se muestran mapas con el

resultado de las predicciones CIF para Centroamérica elaboradas en el último trimestre de 2020 por FEWS NET y por UTSAN-SICA en Honduras.

#### **4. Revisión de variables a predecir y variables predictoras en modelos de machine learning aplicados a la seguridad alimentaria**

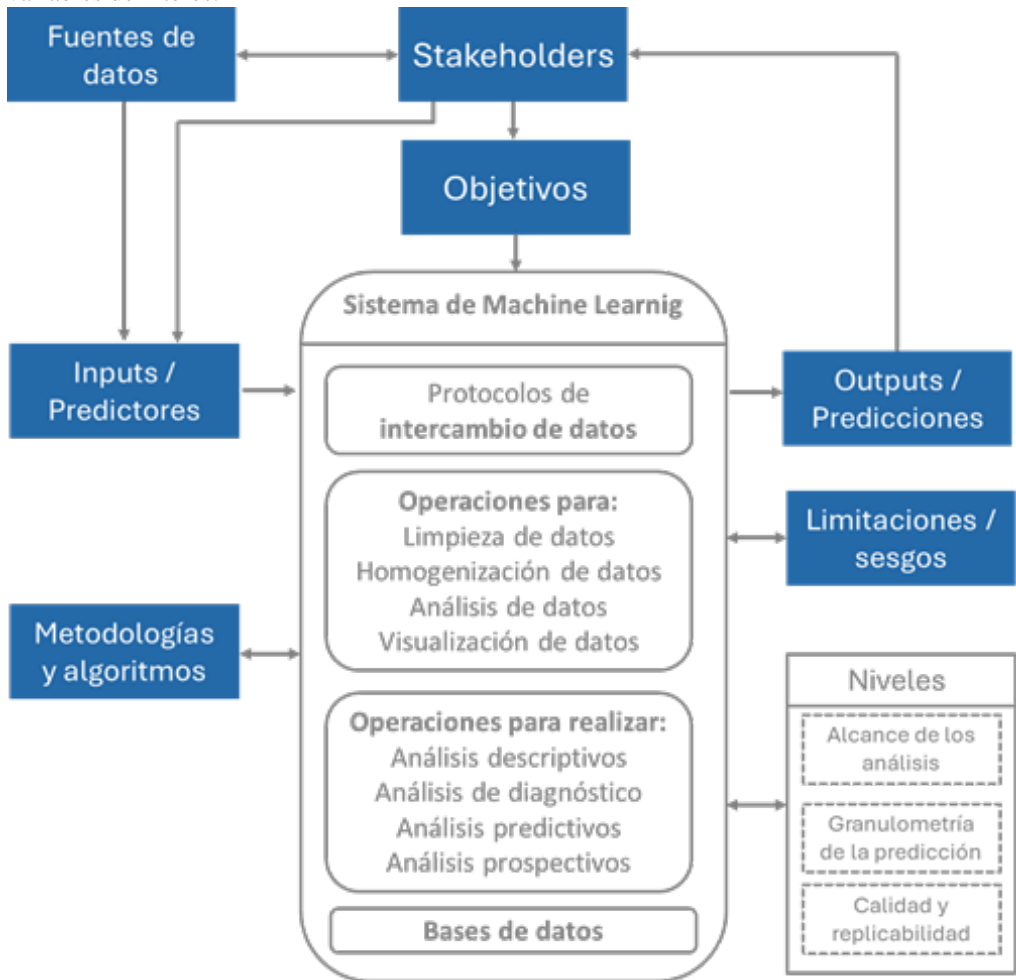
El llamado machine learning (ML) o aprendizaje automático, es una rama dentro del campo de la inteligencia artificial (IA) que se inspira en el modelo de aprendizaje experiencial propio de la inteligencia humana, al tiempo que tiene la capacidad de aprender y mejorar sus análisis mediante el uso de algoritmos computacionales. La utilización de nuevas herramientas informáticas con alta capacidad de cómputo permite a estos algoritmos emplear grandes bases de datos, y con ello identificar patrones entre una cantidad masiva de información. La determinación de pautas entre un volumen enorme de datos permite a softwares especializados entrenarse en el uso de los datos, y con ello "aprender" en un proceso de iteración hasta obtener los resultados más sólidos, que incluso permiten a la herramienta de machine learning ofrecer de manera autónoma conclusiones o recomendaciones derivadas de estos análisis. Cuando se dispone de los suficientes datos, estos algoritmos por medio de los softwares en los que operan pueden incluso ser capaces de predecir cuáles serán los valores que con mayor probabilidad adquirirán los indicadores o variables de interés (outputs, variables target o variables dependientes) a partir de la incorporación de datos previamente registrados (inputs del sistema, predictors o variables independientes) (El Naqa, y Murphy, 2015; Murdoch et al., 2019). Estas metodologías y herramientas se aplican en la actualidad a cualquier ámbito de la actividad humana, desde la salud pasando por la economía, el urbanismo, la agronomía o las múltiples disciplinas de las ciencias sociales.

En la literatura generada en los últimos cinco años en relación con el uso de técnicas de machine learning en el monitoreo y categorización de la seguridad alimentaria se diferencian tres grandes grupos de estudios de acuerdo con el tipo de variable objetivo o target sobre la que se busca aportar análisis de detalle, ya sea para generar predicciones proyectadas hacia el futuro, en predicciones contemporáneas, focalizadas en el presente, o bien en la caracterización más detallada de los grupos de población que se encuentran en situación de inseguridad alimentaria, identificando las variables que más contribuyen a dicho estado, pero sin valorar cómo podría evolucionar la situación.

El primer grupo está conformado por artículos en los que las variables targets son indicadores de resultado de la seguridad alimentaria como la prevalencia de desnutrición aguda, FCS, HDDS, FIES o rCSI. La mayoría de los artículos de este conjunto se centran en la predicción anticipada entre 1 ó 12 meses de una o dos variables, siendo FCS la más común. Tan solo dos de los artículos abordan indicadores antropométricos como es la prevalencia de desnutrición aguda (Backer y Billing, 2024; Browne et al., 2021), mientras que FIES, el indicador de percepción de la seguridad alimentaria promovido por FAO es la variable dependiente sobre la que

se realiza predicción en el trabajo llevado a cabo por Andréé, (2022). En el cuadro 2 se muestra mayor detalle de los artículos incluidos en este primer grupo. Casi todos ellos se apoyan en encuestas de hogar a partir de las cuales se obtienen series temporales de las variables dependientes de interés.

Figura 4. Esquema general de un sistema de machine learning aplicado a la predicción de variables de interés.



Fuente: Adaptado de Uskov et al., 2018.

En los trabajos revisados pertenecientes a este primer grupo, los análisis buscaban anticipación, (forecasting), de hasta un año en los casos de Andréé (2022), Backer y Billing (2024), Lentz et al., (2019) y Zhou (2020), mientras que otros se centran sobre todo en generar predicciones contemporáneas o actuales (nowcasting), que proyectan

resultados en lugares en los que no se dispone de información primaria como son los casos de Martini et al., (2022), Browne et al., (2021) y Deléglise et al., (2022).

Cuadro 2. Resumen de aspectos claves de artículos que aplican machine learning para determinar indicadores de resultado de la seguridad alimentaria

Autores:	Andrée, 2022	Backer y Billing, 2024	Browne et al., 2021	Deléglise et al., 2022;	Foini et al., 2023;	Hertoux et al., 2023	Lentz et al., 2019	Martini et al., 2022	Zhou, 2020
<b>Variables dependientes, a predecir o target</b>									
Antropometría (Wasting y/o Stunting)		X	X						
FCS				X	X	X	X	X	X
FIES	X								
HDDS				X			X		X
rCSI						X	X	X	X
<b>Categorías de variables independientes o predictoras</b>									
Agroclimáticas		X	X	X	X	X	X	X	X
Conflicto		X	X		X	X		X	
Seguridad alimentaria	X				X		X	X	
Económicas	X	X		X	X	X	X	X	X
Datos Geoespaciales		X	X	X	X		X		X
Sociodemográficas	X			X	X		X	X	
<b>Países</b>	144 países	36 países de África	11 países	Burkina Faso	Burkina Faso, Camerún, Mali, Nigeria, Siria, Yemen	Mali, Nigeria, Siria, Yemen	Malawi	78 países	Malawi, Tanzania, Uganda
<b>Escala territorial</b>									
Nacional (NUTS-0)	X		X						
Subnacional; regiones (NUTS-1, NUTS-2)		X	X		X	X			
Subnacional; municipios / clusters comunidades (NUTS 3, NUTS 4)				X			X	X	X
<b>Capacidad de anticipación temporal</b>	1 año	1, 3, 6, 12 meses	Actual	Actual	1 mes	2 meses	1 año	Actual	1 año

Fuente: Elaboración propia.

El segundo grupo de artículos analizado está constituido por aquellos en los que el machine learnig se utiliza para anticipar o validar modelos en los que se determina el porcentaje de acierto en la asignación de la categoría IPC de seguridad alimentaria que le corresponde a una región determinada. En este grupo se incluyen cinco artículos cuyos elementos principales se resumen en el cuadro 3. Todos ellos se

apoyan en las bases de datos y series temporales producidas por análisis CIF en cerca de 40 países en los que la cuestión alimentaria es monitoreada por FEWS NET o por la iniciativa CIF (Cadre Harmonisé en África Occidental) de Naciones Unidas. Es importante recordar no obstante las limitaciones del enfoque CIF debido al grado de subjetividad con que los expertos de los diferentes países llevan a cabo sus análisis y predicciones de la seguridad alimentaria, una carencia que es tanto más acusada cuanto menor es la disponibilidad de información primaria y secundaria. Por tanto, aunque se construyan y evalúen modelos que dispongan de abundante y actualizada información de contexto, el resultado último vendrá limitado por la debilidad de la variable dependiente (categoría CIF) de la que disponemos de registros generados en diferentes regiones y países. En este conjunto de artículos se evalúa el grado de acierto o fracaso a la hora de asignar el cambio de categoría de una región entre dos periodos de tiempo valorados.

Cuadro 3. Resumen de aspectos claves de artículos que aplican machine learning para anticipar o determinar el acierto en la adjudicación de categorías CIF de seguridad alimentaria en regiones de diferentes países

<b>Autores:</b>	<b>Andrée et al., 2020</b>	<b>Busker et al., 2023</b>	<b>Christensen et al., 2021</b>	<b>Krishnamurthy et al., 2020a</b>	<b>Westerfeld et al., 2021</b>
<b>Categorías de variables independientes o predictoras</b>					
Agroclimáticas	X	X	X	X	X
Conflictos	X			X	X
Seguridad alimentaria		X	X	X	
Económicas	X	X	X		X
Medios de vida				X	X
Datos Geoespaciales	X			X	X
Sociodemográficas			X		X
<b>Países</b>	21 países	Somalia, Kenia, Etiopía	21 países	Etiopía, Kenia, Uganda, Somalia, Sudán y Sudán del Sur	Etiopía
<b>Escala territorial</b>					
Nacional					
Subnacional; regiones		X		X	x
Subnacional; municipios / clusters comunidades	X		X		
<b>Capacidad de anticipación temporal</b>	3-4 meses 6-8 meses	12 meses	Actual	Actual	3 meses y 7 meses

Fuente: Elaboración propia.

El tercer grupo de artículos utiliza herramientas de machine learning sobre bases de datos generadas con encuestas de hogar en las que se incluyen diferentes indicadores de resultado de seguridad alimentaria (antropometría, FCS, rCSI, suficiencia per cápita de ingesta calórica) que luego servirán como variable target o dependiente en los modelos construidos y validados, mientras que la participación de otras fuentes de datos sobre el contexto o causas estructurales de la seguridad alimentaria es muy menor o está del todo ausente. En estos trabajos el objetivo no es tanto predecir qué valor probable alcanzará un indicador de seguridad alimentaria en un territorio dado en el futuro, sino establecer cuáles son las variables socio-demográficas, económicas o geográficas de las familias que más inciden en la probabilidad de que un hogar se encuentre en un determinado nivel de inseguridad alimentaria.

Cuadro 4. Resumen de aspectos claves de artículos que aplican machine learning para anticipar o determinar el acierto en la adjudicación de categorías CIF de seguridad alimentaria en regiones de diferentes países

<b>Autores:</b>	<b>Bitew et al., 2021</b>	<b>Gao et al., 2020</b>	<b>Hossain et al., 2019</b>	<b>Meerza et al., 2021</b>	<b>Qasrawi et al., 2023</b>	<b>Villacis et al., 2022</b>
<b>Variables dependiente, predicha o target</b>						
Antropometría (Wasting y/o Stunting)	X					
FCS					X	X
Suficiencia per cápita de ingesta calórica		X	X	X		
rCSI						X
<b>Categorías de variables independientes o predictoras</b>						
Agroclimáticas						X
Múltiples variables obtenidas en encuestas de hogar	X	X	X	X	X	X
<b>Países</b>	Etiopía	Afganistán	Bangladesh	Bangladesh	10 países árabes	Nigeria
<b>Escala territorial</b>						
Nacional						
Subnacional; regiones	X		X			
Subnacional; municipios / clusters comunidades		N/A		N/A	N/A	X
<b>Capacidad de anticipación temporal</b>	Actual	Actual	Actual	Actual	Actual	Actual

Fuente: Elaboración propia.

El análisis realizado por Bitew et al., (2021) en Etiopía permitió por ejemplo cuales eran las características de los niños y sus familias que hacían más probable que un menor de 5 años padeciera desnutrición crónica (stunting), siendo las tres primeras variables con mayor influencia el tiempo que requiere la familia para acceder al agua, el tener una edad mayor de 30 meses o el número de niños menores de 5 años en el hogar. Estos mismos autores encontraron que la probabilidad de que un niño menor de 5 años tuviera desnutrición aguda dependía por orden de importancia de la edad

superior a 30 meses, el índice de pobreza de la familia, el tiempo requerido para acceder a agua y la etnia de la familia.

#### **4.1. Variables independientes o predictores**

La gran ventaja del uso de machine learning en cualquier disciplina es su capacidad para el uso masivo de datos y la obtención a partir de los mismos de patrones o resultados que son de gran interés y que con técnicas estadísticas tradicionales no podrían lograrse, o bien requerirían una importante inversión de tiempo y recursos. Esta ventaja se torna también en su principal debilidad cuando el acceso a datos es limitado, lo que suele ser común en lo referido a la seguridad alimentaria de países en zonas de conflicto o con escasa presencia institucional y por tanto con una reducida capacidad para generar información de manera regular. Por este motivo, los esfuerzos de aplicación de machine learning con el fin de anticipar crisis alimentarias recurren en la medida de lo posible a bases de datos en abierto y que sean actualizadas con una cierta periodicidad. Estas condiciones suelen encontrarse a escala nacional para diferentes variables de potencial interés en los ámbitos económico, sociodemográfico o de conflictos, aunque con un grado de desglose territorial o granulometría que resulta muy diverso. Sin embargo, en lo referido a información agroclimática si se dispone de una gran cantidad de datos con un buen detalle geoespacial, procedentes de fuentes de teledetección puestas mensualmente, o incluso mayor frecuencia, a libre disposición de los usuarios por iniciativa de organismos internacionales y países como EE. UU. o la UE.

Los artículos revisados incluidos en la primera y segunda tipología descritas más arriba utilizan una amplia diversidad de categorías y fuentes de datos. A continuación, se describen las que son más comunes o frecuentes, además de reseñar de forma breve las clasificaciones más comunes usadas.

##### **a) Información agroclimática**

Catorce de los veinte artículos revisados incorporan datos agroclimáticos a sus modelos de predicción o análisis. Los índices más comunes proceden de teledetección como son el índice estandarizado de precipitaciones (ISP por sus siglas en inglés) y el índice de vegetación de diferencia normalizada (NDVI por sus siglas en inglés), identificando anomalías para diferentes periodos de tiempo de entre 3, 6 y 12 meses en el caso de ISP, o periodos de tiempo más corto (de incluso 10 días), en el caso de NDVI.

##### **b) Conflictos**

Datos sobre conflictos son introducidos en los modelos de predicción de nueve de los artículos analizados. La principal fuente de información procede del Armed Conflict Location and Event Data Project (ACLED), y las variables consideradas suelen ser;

víctimas mortales en combate y víctimas mortales de la violencia contra civiles, considerando su evolución en periodos de 3 meses, usando cifras absolutas o bien la variación experimentada entre dos períodos consecutivos de 3 meses (Martini et al., 2022). Otras fuentes de datos complementarias son el Global Terrorism Database (GTD), centrado en ataques terroristas o el Uppsala Conflict Data Program's Georeferenced Event Dataset (UCDP-GED), focalizado en violencia armada organizada (Backer y Billing, 2024).

### **c) Sociodemografía**

Este tipo de información es empleada en ocho de los artículos revisados, sin considerar los incluidos en el grupo III, los cuales están centrados en el análisis de bases de datos procedentes de encuestas de hogar, y que por tanto abarcan una amplia diversidad de variables sociodemográficas. El índice más común empleado es la densidad de población (Backer y Billing, 2024; Martini et al., 2022; Deléglise et al., 2022; Krishnamurthy et al., 2020a; Westerveld et al., 2021; Foini et al., 2023) la cual puede aplicarse a diferentes escalas territoriales, además de mostrar una lenta evolución a lo largo del tiempo. Andréé (2022) utiliza dos índices de tipo demográfico; la tasa media de crecimiento de la población en 3 años y la tasa promedio de mortalidad infantil en el periodo 1995-2015.

### **d) Economía**

En esta categoría se encuentra la mayor diversidad de variables adoptadas en trece de los veinte artículos revisados. La variable más común es el índice de precios de los alimentos medido a partir de distintas fuentes, aunque la más común suele ser la sistematizada por WFP y su Alert for Price Spikes (ALPS) (Busker et al., 2023; Herteux et al., 2023; Martini et al., 2022; Westerveld et al., 2021), así como el monitoreo de precios proporcionado por la iniciativa VAM (Busker et al., 2023; Foini et al., 2023), FAO (Browne et al., 2021; Busker et al., 2023), instituciones de gobierno (Deléglise et al., 2022; Lentz et al., 2019; Zhou, 2020) o iniciativas impulsadas desde la academia como el índice de precios de los alimentos desarrollado por Tuffs University (INDDX) (Christensen et al., 2021).

### **e) Datos geoespaciales**

Esta categoría incluye diferentes tipos de geodatos que proporcionan información asociada a referencias geográficas ubicadas en la superficie de un territorio. Este tipo de datos forma parte de los modelos de predicción en diez de los veinte artículos revisados. Ofrecen la ventaja de estar ampliamente disponibles en fuentes abiertas. Buena parte de ellos tienen un carácter estático, esto es, en la práctica no evolucionan en el tiempo, como tampoco lo hace la topografía o la ubicación de una determinada población. Otros geodatos de interés obtenidos con apoyo de teledetección, pueden cambiar a lo largo del tiempo, como por ejemplo el porcentaje de suelo cubierto por



bosques, la superficie arable o la superficie agrícola de regadío. La información geoespacial combinada con la de tipo agroclimático permite por ejemplo evaluar el impacto de incendios, inundaciones o plagas, como es el caso de plagas de langosta en África del Este considerada por Busker et al., (2023) en su modelo.

#### **f) Datos sobre seguridad alimentaria**

En siete artículos revisados se utilizan datos que podemos agrupar en la categoría de información sobre seguridad alimentaria y que en la práctica está constituida por; i) bases de datos con indicadores de resultado de seguridad alimentaria como FCS o rCSI, procedentes de diagnósticos o encuestas previas (Foini et al., 2023; Martini et al., 2022); ii) serie temporal de la fase de seguridad alimentaria CIF en la que se encuentran las regiones de un determinado país de acuerdo con la asignación de efectuada por FEWS NET (Krishnamurthy et al., 2020a; Lentz et al., 2019); iii) asistencia alimentaria entregada en zonas de preocupación humanitaria (Busker et al., 2023; Christensen et al., 2021).

#### **g) Medios de vida**

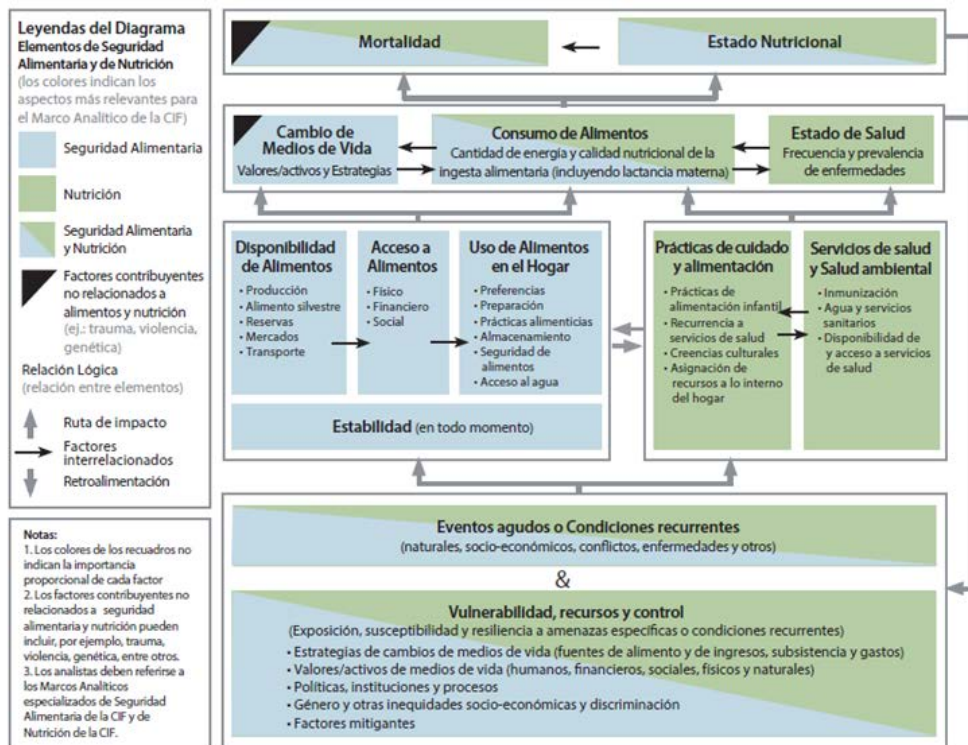
En dos de los trabajos revisados, Krishnamurthy et al., (2020a) y Westerveld et al., (2021), se utiliza también como información secundaria incorporada al sistema la zonificación de medios de vida generada por FEWS NET en los diferentes países en los que esta iniciativa de USAID está presente. Esta zonificación permite identificar cuáles son los cultivos, estacionalidad y actividades económicas más relevantes en cada uno de los territorios en los que puede dividirse un país de acuerdo con criterios socio-económicos, agroclimáticos y alimentarios.

### **5. Propuesta de variables a ser consideradas en modelos de machine learning aplicados en Centroamérica**

A partir de la revisión de literatura efectuada, en esta sección se propone un modelo de predicción de la seguridad alimentaria en territorios centroamericanos (El Salvador, Guatemala, Honduras y Nicaragua), tomando como referencia la conceptualización de la seguridad alimentaria efectuada por la Clasificación Integrada de la Seguridad Alimentaria en Fases (CIF) (IPC, 2019). En la figura 6 se muestra un esquema que resume los diferentes componentes del marco conceptual de la CIF. En los siguientes párrafos se ofrece una breve descripción de sus principales componentes.

La elaboración de modelos de predicción apoyados en machine learning implica la utilización de una amplia diversidad de fuentes de información y datos (variables independientes o predictores) para finalmente ser capaces de establecer cuáles son los valores que alcanzarían las variables targets de interés, a partir de las cuales desencadenar de forma anticipada respuestas humanitarias que contribuyen a prevenir o mitigar el impacto de una crisis.

Figura 6. Marco Conceptual de la CIF.



Fuente: IPC, 2019.

Utilizando de nuevo como referencia el marco propuesto por la CIF (IPC, 2019), encontramos que la categorización en cinco fases de seguridad alimentaria de un territorio viene orientada por valores umbral ya establecidos para distintos indicadores de resultado, tal y como se detalla en el cuadro 6.

### 5.1. Variables targets o dependientes sobre las que generar predicciones

Los modelos de predicción más usuales, de acuerdo con la revisión efectuada en la sección anterior, se centran en la determinación de indicadores de resultado de primer nivel (véase el detalle de estos artículos en el cuadro 2), sobre todo FCS, seguido por rCSI, HDDS, HHS (generados con frecuencia en monitoreos llevados a cabo de manera regular por WFP), suficiencia en el consumo calórico (procedente de encuestas hogar lideradas por Gobiernos nacionales) y en último término FIES (indicador de referencia levantado en diferentes países por FAO).

**Cuadro 6. Propuesta de umbrales para diferentes indicadores e índices estandarizados que expresan resultados primarios y secundarios de seguridad alimentaria con el fin orientar la convergencia de evidencias en análisis CIF.**

Nombre y Descripción de Fase	Fase 1 Ninguna/Mínima	Fase 2 Acentuada	Fase 3 Crisis	Fase 4 Emergencia	Fase 5 Catastrofe/Hambuna
	Los hogares pueden satisfacer necesidades alimentarias y no alimentarias esenciales sin involucrarse en estrategias de apoyo e insostenibles para acceder a alimentos e ingresos.	Los hogares tienen consumo de alimentos mínimamente adecuado, pero no pueden cubrir algunos gastos no alimentarios esenciales sin involucrarse en estrategias de afrontamiento.	Los hogares: - Tienen brechas de consumo de alimentos que se reflejan en Desnutrición Aguda alta o peso de lo usual. o - Son marginalmente capaces de satisfacer sus necesidades alimentarias pero únicamente mediante aplicar activos esenciales de medios de vida o mediante estrategias de afrontamiento de crisis.	Los hogares: - Tienen brechas de consumo de alimentos grandes que se reflejan en Desnutrición Aguda muy alta y exceso de Mortalidad. o - Son capaces de mitigar las brechas de consumo de alimentos pero únicamente mediante estrategias de afrontamiento de emergencia y liquidación de sus activos.	Los hogares tienen una carencia extrema de alimentos y otras necesidades básicas aun después de usar al máximo estrategias de afrontamiento. La inacción, muerte, penuria y Desnutrición Aguda extremadamente crítica son evidentes.  (Para clasificaciones de Hambuna, el área debe presentar valores extremadamente altos de Desnutrición Aguda y Mortalidad.)
Objetivos de Respuesta Prioritaria	Acción requerida para construir resiliencia y para reducción de riesgo de desastres	Acción requerida para reducción de riesgo de desastres y proteger medios de vida	Acción urgente es requerida para:  Proteger medios de vida y reducir brechas de consumo de alimentos	Salvar vidas y medios de vida	Revertir o prevenir muerte generalizada y colapso total de medios de vida
<p><b>Resultados de Primer Nivel</b> se refieren a características del Consumo de Alimentos y Cambios en Medios de Vida. Se incluyen valores críticos para cada indicador, que corresponden lo más cerca posible a la descripción de fase. Aunque los valores críticos se basan en investigación aplicada y se presentan como una referencia mundial, la correlación entre indicadores es usualmente limitada y los resultados deben ser contextualizados. El área es clasificada en la Fase más severa que afecte al menos al 20% de la población.</p>					
Consumo de Alimentos (enfoco en energía de energía)	<p><b>Cantidad: Ingesta de energía adecuada</b></p> <p><b>Ingesta Energía Alimentaria (kcal):</b> Adecuada (promedio 2,350 Kilojulios (kcal) pp/día) y estable</p> <p><b>Kilocalorías (kcal) pp/día) y estable</b></p> <p><b>HDDS:</b> 5 grupos, pero deterioro de igual o mayor que 1 grupo de lo típico</p> <p><b>FCS:</b> Aceptable, pero deterioro de lo típico</p> <p><b>HHS:</b> 1 (leve)</p> <p><b>rCSI:</b> 4-18</p>	<p><b>Cantidad: Mínimamente adecuada</b></p> <p><b>Ingesta Energía Alimentaria:</b> Mínimamente adecuada (promedio 2,100 kcal pp/día)</p> <p><b>HDDS:</b> 3-4 grupos de alimentos</p> <p><b>FCS:</b> límite</p> <p><b>HHS:</b> 2-3 (moderada)</p> <p><b>rCSI:</b> igual o mayor que 19 (características no definidas [CND]) para diferenciar Fase 3, 4 y 5)</p>	<p><b>Cantidad: Moderadamente inadecuada – Déficits Moderados</b></p> <p><b>Ingesta Energía Alimentaria:</b> Brecha alimentaria grande (promedio 2,100 kcal pp/día)</p> <p><b>HDDS:</b> 3-4 grupos de alimentos</p> <p><b>FCS:</b> límite</p> <p><b>HHS:</b> 2-3 (moderada)</p> <p><b>rCSI:</b> igual o mayor que 19 (características no definidas [CND]) para diferenciar Fase 3, 4 y 5)</p>	<p><b>Cantidad: Muy inadecuada – Déficits Grandes</b></p> <p><b>Ingesta Energía Alimentaria:</b> Brecha alimentaria grande (mayor abajo de 2,100 kcal pp/día)</p> <p><b>HDDS:</b> 0-2 grupos (CND) para diferenciar Fase 4 y 5)</p> <p><b>FCS:</b> pobre (CND) para diferenciar Fase 4 y 5)</p> <p><b>HHS:</b> 4 (severa)</p> <p><b>rCSI:</b> igual o mayor que 19 (CND) para diferenciar Fase 3, 4 y 5)</p>	<p><b>Cantidad: Extremadamente inadecuada – Déficits muy grandes</b></p> <p><b>Ingesta Energía Alimentaria:</b> Brecha alimentaria extrema</p> <p><b>HDDS:</b> 0-2 grupos</p> <p><b>FCS:</b> pobre (CND) para diferenciar Fase 4 y 5)</p> <p><b>HHS:</b> 5-6 (severa)</p> <p><b>rCSI:</b> a 19 (CND) para diferenciar Fase 3, 4 y 5)</p>
Enfoque de la Economía del Hogar (HEA, por sus siglas en inglés) <sup>2</sup>	Enfoque de la Economía del Hogar (HEA, por sus siglas en inglés) <sup>2</sup> No hay déficit de protección de medios de vida	HEA: Déficit de protección de medios de vida pequeño o moderado menor que 80%	HEA: Déficit de protección de medios de vida igual o mayor que 80% o déficit de sobrevivencia menor que 20%	HEA: Déficit de sobrevivencia igual o mayor que 20% pero menor que 50%	HEA: Déficit de sobrevivencia igual o mayor que 50%
Escala de Experiencia de Inseguridad Alimentaria <sup>3</sup> (HES 30 días periodo de recordatorio): < 0.58	Escala de Experiencia de Inseguridad Alimentaria <sup>3</sup> (HES 30 días periodo de recordatorio): < 0.58	FIES: Entre 0.58 y 0.36	FIES: < 0.36 (CND para diferenciar entre Fases 3, 4 y 5)	FIES: > 0.36 (CND para diferenciar entre Fases 3, 4 y 5)	FIES: > 0.36 (CND para diferenciar entre Fases 3, 4 y 5)
<p><b>Factores contribuyentes a la Seguridad Alimentaria</b></p> <p>Para factores contribuyentes, se necesita determinar y analizar indicadores específicos y valores críticos para las diferentes fases, de acuerdo con el contexto de medios de vida; sin embargo, a continuación se presentan algunas descripciones generales:</p>					
Disponibilidad, acceso, utilización y estabilidad de alimentos	Adecuadas para satisfacer necesidades de corto plazo de Consumo de Alimentos. Agua segura <sup>4</sup> igual o mayor que 15 litros pp/día	Marginalmente adecuadas para satisfacer necesidades de Consumo de Alimentos. Agua segura es marginalmente igual o mayor que 15 litros pp/día	Inadecuadas para satisfacer necesidades de Consumo de Alimentos. Agua segura mayor que 7.5 hasta 15 litros pp/día	Muy inadecuadas para satisfacer necesidades de Consumo de Alimentos. Agua segura mayor que 3 hasta menos que 7.5 litros pp/día	Extremadamente inadecuadas para satisfacer necesidades de Consumo de Alimentos. Agua segura igual o menor que 3 litros pp/día
Amenazas y vulnerabilidad	No hay efectos o hay efectos mínimos de amenazas y vulnerabilidad en medios de vida y consumo de alimentos.	Los efectos de amenazas y vulnerabilidad en medios de vida perturban medios de vida y consumo de alimentos.	Los efectos de amenazas y vulnerabilidad resultan en pérdida de activos o déficits significativos en consumo de alimentos.	Los efectos de amenazas y vulnerabilidad resultan en pérdidas grandes de activos de medios de vida o déficits extremos en consumo de alimentos.	Los efectos de amenazas y vulnerabilidad resultan en el casi colapso completo de activos de medios de vida o déficits casi totales en consumo de alimentos.
Cambios en Medios de Vida (lactivos y estrategias)	Cambios en Medios de Vida: Estrategias y activos de medios de vida sostenibles	Cambios en Medios de Vida: Estrategias o activos acentuados; capacidad reducida para invertir en medios de vida	Cambios en Medios de Vida: Agotamiento o erosión acelerada de estrategias o activos	Cambios en Medios de Vida: Agotamiento extremo o liquidación de estrategias y activos	Cambios en Medios de Vida: Cerca del colapso completo de estrategias y activos
Estrategias de Afrontamiento de Medios de Vida (LCS, siglas en inglés) <sup>5</sup>	Estrategias de Afrontamiento de Medios de Vida (LCS, siglas en inglés) <sup>5</sup> No se observan estrategias acentuadas, de crisis o de emergencia.	LCS: Las estrategias más severas usadas por hogares en 30 días previos son estrategias acentuadas.	LCS: Las estrategias más severas usadas por hogares en 30 días previos son estrategias de crisis.	LCS: Las estrategias más severas usadas por hogares en 30 días previos son estrategias de emergencia.	LCS: Cerca de agotar la capacidad de afrontamiento.
<p><b>Resultados de segundo nivel</b> se refieren a estimaciones sobre el Estado Nutricional y mortalidad<sup>6</sup> en el área, que son especialmente útiles para identificar fases más severas cuando se espera que las brechas alimentarias impacten la Desnutrición Aguda y Mortalidad. Para los resultados de Desnutrición Aguda y Mortalidad del área, los déficits de Consumo de Alimentos en hogares deben ser un factor explicativo para que la evidencia se use en apoyo de una clasificación.</p>					
Desnutrición Aguda (DA) basada en Puntaje Z de peso para talla (ZPT) <sup>7</sup>	Aceptable: menor que 5%	Alerta: 5-9.9%	Graves: 10-14.9% o mayor que lo usual	Crítica: 15-29.9% o mucho mayor que lo usual	Extremadamente Crítica: igual o mayor que 30%
DA basada en perímetro braquial medio (PBM) <sup>8</sup>	< 5%	< 5%	5-9.9%	10-14.9%	> 15%
Índice de Masa Corporal (IMC) menor que 18.5 <sup>9</sup>	< 5%	5-9.9%	10-19.9%, 1 x superior a la referencia	20-39.9%	> 40%
Mortalidad <sup>6</sup>	Tasa Bruta de Mortalidad (TBM): <sup>10</sup> menor que 0.5/10,000/día	TBM: menor que 0.5/10,000/día	TBM: 0.5-0.99/10,000/día	TBM: 1-1.99/10,000/día o mayor que 2 veces la referencia	TBM: igual o mayor que 2/10,000/día
Tasa de Mortalidad de Menores de 5 Años (TMMS) <sup>11</sup> menor que 1/10,000/día	TMMS: menor que 1/10,000/día	TMMS: menor que 1/10,000/día	TMMS: 1-1.99/10,000/día	TMMS: 2-3.99/10,000/día	TMMS: igual o mayor que 4/10,000/día

Fuente: IPC, 2019

Otro grupo de artículos se centran en la predicción de indicadores de segundo nivel relacionados con el estado nutricional, lo que implica mediciones antropométricas (desnutrición aguda y crónica), algo que solo está al alcance de encuestas de salud y hogar lideradas por los Gobiernos, o esfuerzos ligados a encuestas nutricionales SMART aplicadas por diferentes tipos de actores gubernamentales, agencias de Naciones Unidas u ONGs. En el contexto centroamericano las bases de datos más completas y con series temporales más extensas corresponden a WFP y su labor de monitoreo periódico en países de la región, de manera que las variables a predecir deberían encontrarse entre las priorizadas en sus levantamientos de información, como son FCS, HDDS, rCSI o HHS. Los valores que generen los modelos de predicción para los diferentes municipios de un país serían un insumo de gran interés para las mesas de análisis CIF llevadas a cabo cada tres meses en países como Guatemala u Honduras. El modelo por tanto no llegaría a asignar a territorios categorías CIF, pero sí estará en condición de aportar evidencias en lugares de los que normalmente se carece, además de un mayor rigor en el proceso.

## **5.2. Variables independientes con las que establecer perfiles de vulnerabilidad**

La vulnerabilidad en el contexto de la inseguridad alimentaria se refiere a la susceptibilidad de la población de diferentes territorios a experimentar dificultades para acceder a alimentos adecuados y nutritivos de manera constante y suficiente. Esta vulnerabilidad, estrechamente vinculada con la geografía en la que se asienta la población, puede ser causada por una amplia variedad de factores que incluyen: económicos, sociopolíticos, climáticos y medioambientales, carencias educativas, uso inadecuado de técnicas agrícolas, barreras comerciales, la propia localización geográfica y aislamiento, etc. La vulnerabilidad de los habitantes de un territorio en buena medida tiene un carácter estructural o estático, y que evoluciona lentamente en el tiempo, es crucial para poder avanzar en la superación de los problemas de fondo que limitan las condiciones de vida y alimentación de más de la mitad de la población centroamericana. La idea de perfiles de vulnerabilidad se encuentra también en la delimitación de zonas de medios de vida llevada a cabo por iniciativa de FEWS NET en los países en los que opera, incluidos los centroamericanos, aunque no se hayan actualizado desde hace más de una década. El conocimiento de los medios de vida se relaciona de forma estrecha con la estacionalidad en la disponibilidad y acceso a alimentos (Devereux et al., 2012), de manera que en cada perfil de vulnerabilidad encontramos pautas que se repiten a lo largo de los años, definiendo así periodos en los que la seguridad alimentaria mejora y otros en los que se deteriora.

En la determinación de zonas de vulnerabilidad a ser aplicadas posteriormente en un modelo de predicción de seguridad alimentaria se propone aplicar herramientas de machine learning, como ya ha desarrollado para Centroamérica por Abarca-Álvarez et al., (2022), y que combina una amplia diversidad de datos procedentes de fuentes de información secundaria, con el mayor nivel de detalle espacial disponible (escala municipal).

Cuadro 7. Propuesta de variables independientes con las que elaborar perfiles de vulnerabilidad alimentaria que deberán actualizarse anualmente

Categoría	Variable Independiente asociada a perfil de vulnerabilidad	Alcance geográfico
Agroclimático	Índice de Aridez	Municipio
Agroclimático	Índice de Riesgo Climático Global (IRC) - Germanwatch	Nacional
Conflicto	Índice de estabilidad política y ausencia de violencia/terrorismo	Nacional
Desastres	INFORM Risk Index	Nacional
Economía	GDP per capita	Nacional
Economía	Porcentaje de población en pobreza extrema / Evolución anual del porcentaje de población en pobreza extrema	Departamento
Economía	Porcentaje de población en pobreza monetaria / Evolución anual del porcentaje de población en pobreza monetaria	Departamento
Economía	Porcentaje de población en edad laboral que está desempleada / Evolución de la población desempleada	Departamento
Economía	Porcentaje de población en edad laboral que está subempleada / Evolución de la población subempleada	Departamento
Economía	Porcentaje del GDP destinado a protección social	Nacional
Economía	Prevalencia de la inseguridad alimentaria moderada o grave en la población total (FAO)	Nacional
Economía	Porcentaje de población en situación Fase 3 de la CIF (FSIN)	Nacional
Economía	Porcentaje de población en situación Fase 4 de la CIF (FSIN)	Nacional
Economía	Número de turistas internacionales recibidos en el país	Nacional
Geoespacial	Distancia a los mercados	Municipio
Geoespacial	Distancia a los hospitales	Municipio
Geoespacial	Distancia a las Escuelas	Municipio
Geoespacial	Acceso a Agua	Municipio
Geoespacial	Densidad de Km carretera asfaltada / Km <sup>2</sup> superficie	Municipio
Geoespacial	Topografía / Pendiente	Municipio
Geoespacial	Topografía / Altitud promedio	Municipio
Geoespacial	Intensidad de las luces por la noche.	Municipio
Medios de Vida	Distribución de fuentes de alimentos en porcentajes	Zona de medios de vida
Medios de Vida	Distribución de fuentes de fuentes de ingresos	Zona de medios de vida
Medios de Vida	Principales estrategias de respuesta.	Zona de medios de vida
Medios de Vida	Porcentaje de posesión de ganado (cerdos, gallinas, vacas)	Zona de medios de vida
Medios de Vida	Hectáreas de posesión de la tierra.	Zona de medios de vida
Medios de Vida	Tamaño promedio de los hogares pobre, medio y acomodado.	Zona de medios de vida
Medios de Vida	Precio del salario mínimo urbano y rural	Nacional
Medios de Vida	Precio del jornal de café / Evolución del jornal en comparación con el año previo	Nacional / Zona de medios de vida
Medios de Vida	Cantidad de jornales cosecha café / Evolución de la cantidad de jornales en comparación con el año previo	Nacional / Zona de medios de vida

Categoría	Variable Independiente asociada a perfil de vulnerabilidad	Alcance geográfico
Medios de Vida	Precio del jornal de corte de caña / Evolución del jornal en comparación con el año previo	Nacional / Zona de medios de vida
Medios de Vida	Cantidad de jornales de caña de azúcar / Evolución de la cantidad de jornales en comparación con el año previo	Nacional / Zona de medios de vida
Medios de Vida	Precio del jornal de cardamomo (GT) / Evolución del jornal en comparación con el año previo	Nacional / Zona de medios de vida
Medios de Vida	Cantidad de jornales de cardamomo (GT) / Evolución de la cantidad de jornales en comparación con el año previo	Nacional / Zona de medios de vida
Medios de Vida	Porcentaje de hogares que reciben remesas en el departamento	Departamento
Medios de Vida	Porcentaje de mujeres como jefas de hogar / Evolución en el porcentaje de mujeres jefas de hogar	Departamento
Medios de Vida	Porcentaje de población que recibe atención de redes de protección social y/o proyectos de asistencia alimentaria	Departamento
Medios de Vida	Perfiles de hogar en función de FIES y conformados con la BBDD de GWP 2014-2019	Nacional
Salud	Porcentaje de hogares con facilidades limitadas para el lavado de manos de jabón y agua / Evolución de hogares con facilidades para lavado de manos	Departamento
Salud	Porcentaje de hogares que utilizan fuentes de agua mejorada / Evolución del porcentaje de hogares con acceso a fuentes mejoradas	Departamento
Seguridad Alimentaria	Porcentaje de población menor de cinco años con desnutrición crónica / Evolución de la desnutrición crónica	Departamento
Seguridad Alimentaria	FIES (2014-2019) procedente de GWP	Nacional
Sociodemografía	Densidad de Población	Municipio
Sociodemografía	Población Total	Municipio
Sociodemografía	Índice de Desarrollo Humano (IDH)	Nacional
Sociodemografía	Tasa de migración neta por cada 1000 habitantes población	Nacional
Sociodemografía	Tasa de mortalidad infantil de menores de 5 años	Nacional
Sociodemografía	Esperanza de vida al nacer	Nacional
Sociodemografía	Porcentaje anual de crecimiento de la población	Nacional
Sociodemografía	Tasa de mortalidad neonatal	Nacional
Sociodemografía	Porcentaje de niños cubiertos por programas de protección social	Nacional
Sociopolítico	Índice de percepción de la corrupción (TI)	Nacional
Sociopolítico	Índice de democracia global (The Economist)	Nacional

Fuente: Elaboración propia.

Es importante destacar que los perfiles de vulnerabilidad pueden asociarse a territorios, o bien referirse a grupos de población específicos en los que el aspecto geográfico sea tan solo una variable más, como el nivel educativo de los perfiles de hogar, o sus ingresos económicos. En este trabajo nos focalizamos en los perfiles que tienen un vínculo geográfico y que por tanto ayuda a identificar (mapping) qué

lugares podrían requerir una asistencia específica, frente a los que se centran en establecer conjuntos de población con grados de vulnerabilidad similares que les pudiera hacer elegibles de un determinado apoyo (targeting). La diferenciación entre mapping y targeting viene explicada en Browne et al., (2021).

En el cuadro 7 se ofrece una propuesta de variables que pueden contribuir a la determinación de perfiles de vulnerabilidad alimentaria. El análisis de vulnerabilidad y la correspondiente determinación de perfiles municipales de seguridad alimentaria se deberá actualizar cada año, estableciendo así una vulnerabilidad alimentaria basal, sobre la que se añadirán de forma periódica variables independientes predictoras vinculadas con diferentes amenazas con impacto potencial en la seguridad alimentaria (véase al respecto el siguiente apartado).

### **5.3. Variables independientes o predictoras vinculadas a amenazas, perturbaciones o crisis**

Además de por cuestiones de tipo estructural con escasa variación a lo largo del tiempo, el deterioro o mejora de la seguridad alimentaria de la población de un territorio determinado, o del conjunto de un país está condicionado por una serie de factores que pueden experimentar cambios súbitos (golpe de estado o crisis política que interrumpe la actividad económica, desastre de origen natural como terremoto o huracán) o graduales (sequías, plagas en cultivos clave, inflación). A continuación, se recopilan una serie de variables independientes organizadas en siete categorías que permiten monitorear amenazas y transformaciones clave en diferentes ámbitos que inciden en la seguridad alimentaria. Se trata de variables que pueden experimentar cambios en corto y medio plazo, por ejemplo, las relacionadas con aspectos agroclimáticos, y de las que disponemos de registros cada diez días o mensuales procedentes de fuentes abiertas apoyadas en teledetección. Este tipo de variables agroclimáticas son también las que ofrecen una mayor granulometría, permitiendo llevar a cabo análisis a escala municipal o incluso inferior. En las variables utilizadas con fines predictivos lo más relevante no son tanto los valores absolutos que estas adquieren, sino el cambio o evolución en comparación con periodos previos. La diferencia puede establecerse entre meses, trimestres o en relación con los promedios dados por las series históricas disponibles. A efectos prácticos, y considerando la carga de trabajo que conlleva, se propone que la labor de actualización del modelo a efectos de elaborar predicciones de variables dependientes o targets de seguridad alimentaria se actualice trimestralmente, tomando en consideración los cambios producidos durante ese periodo. Un importante desafío es vincular la evolución de estas variables predictoras con el mes en concreto en que inciden, considerando el periodo de Hambre Estacional (Alpizar et al., 2020).

Cuadro 8. Propuesta de variables independientes con las que monitorear factores clave asociados con amenazas, perturbaciones o crisis que impactan en la seguridad alimentaria

<b>Categoría</b>	<b>Variable Independiente Predictora</b>	<b>Periodicidad</b>	<b>Alcance geográfico</b>
Agroclimático	Total de lluvia en milímetros (CHIRPS)	Mensual / Trimestral	Municipio
Agroclimático	Lluvia en la decadal (CHIRPS)	Mensual / Trimestral	Municipio
Agroclimático	Anomalía de Lluvia en la decadal (CHIRPS)	Mensual / Trimestral	Municipio
Agroclimático	Temperatura máxima decadal	Mensual / Trimestral	Municipio
Agroclimático	Temperatura mínima decadal.	Mensual / Trimestral	Municipio
Agroclimático	Anomalía Temperatura decadal comparada con la media histórica	Mensual / Trimestral	Municipio
Agroclimático	Anomalía mensual en la evapotranspiración	Mensual / Trimestral	Municipio
Agroclimático	Índice de vegetación de diferencia normalizada (NDVI) durante una ventana temporal de 12 meses.	Mensual / Trimestral	Municipio
Agroclimático	Balance hídrico (WRSI)	Mensual / Trimestral	Municipio
Agroclimático	Índice de Precipitación Normalizada (SPI)	Mensual / Trimestral	Municipio
Agroclimático	Structure Insensitive Pigment Index (SIPI)	Mensual / Trimestral	Municipio
Agroclimático	Índice de Vegetación Normalizado por Diferencia (NDVI)	Mensual / Trimestral	Municipio
Agroclimático	Índice de Vegetación Mejorado (EVI)	Mensual / Trimestral	Municipio
Agroclimático	Índice de Estrés Agrícola (ASI)	Mensual / Trimestral	Municipio
Agroclimático	Atmospherically Resistant Vegetation Index (ARVI)	Mensual / Trimestral	Municipio
Conflicto	Víctimas mortales de hechos violentos (ACLED)	Trimestral	Municipio
Desastres	Víctimas mortales provocadas por desastres (EM-DAT)	Trimestral	Municipio
Desastres	Daños en USD provocados por desastres (EM-DAT)	Trimestral	Municipio
Economía	Precios de productos básicos al por mayor o menor a nivel de departamento donde haya disponibilidad del dato. (FEWSNET con fuente SIMAS)	Trimestral	Departamento
Economía	Evolución trimestral del precio de los combustibles a nivel nacional (FEWS NET)	Trimestral	Nacional



<b>Categoría</b>	<b>Variable Independiente Predictora</b>	<b>Periodicidad</b>	<b>Alcance geográfico</b>
Economía	Índice de precios al consumo (IPC) de los alimentos / Evolución del IPC alimentos del trimestre en comparación con el anterior	Trimestral	Nacional
Economía	Índice de precios al consumo (IPC) total / Evolución del IPC del trimestre en comparación con el anterior	Trimestral	Nacional
Economía	Evolución trimestral del GDP del país (Banco Central de cada país)	Trimestral	Nacional
Economía	Evolución trimestral en el precio de canasta básica urbana y rural	Trimestral	Nacional
Economía	Evolución trimestral del tipo de cambio frente al USD (Bancos Centrales)	Trimestral	Nacional
Economía	Porcentaje de crecimiento de turistas internacionales que llegan al país	Trimestral	Nacional
Medios de Vida	Precio internacional y nacional del café / Evolución trimestral del precio internacional del café	Trimestral	Nacional / Zona de medios de vida
Medios de Vida	Precio internacional del azúcar / Evolución trimestral del precio internacional del azúcar	Trimestral	Nacional / Zona de medios de vida
Medios de Vida	Precio internacional del cardamomo (GT) y nacional/ Evolución trimestral del precio internacional y nacional del cardamomo	Trimestral	Nacional / Zona de medios de vida
Medios de Vida	Evolución nacional de las remesas a nivel nacional en comparación con el trimestre previo (Bancos Centrales, CEPAL, CABI)	Trimestral	Nacional / Departamento
Seguridad Alimentaria	Food Insecurity Experience Scale (FIES) estimada en encuestas de hogar	Trimestral / Semestral	Departamento
Seguridad Alimentaria	FCS estimada en encuestas de hogar	Trimestral / Semestral	Departamento
Seguridad Alimentaria	rCSI estimada en encuestas de hogar	Trimestral / Semestral	Departamento
Seguridad Alimentaria	HDSS estimada en encuestas de hogar	Trimestral / Semestral	Departamento
Seguridad Alimentaria	HHS estimada en encuestas de hogar	Trimestral / Semestral	Departamento
Seguridad Alimentaria	Hambre Estacional (influencia del mes en la atenuación o agravamiento de perturbaciones que afectan la seguridad alimentaria)	Trimestral	Departamento
Seguridad Alimentaria	Fase CIF asignada por FEWSNET y/o PROGRESAN-SICA	Trimestral	Departamento
Sociodemografía	Tasa de migrantes del país aprehendidos en la frontera sur de EEUU	Trimestral	Nacional

Fuente: Elaboración propia.

El resultado de los modelos de predicción con el uso de este conjunto de variables de vulnerabilidad y predictoras, se focalizará en una primera etapa en predicción contemporánea de variables de resultado de seguridad alimentaria (FCS, rCSI, HHS, HDDS) con la mayor desagregación posible; departamental de partida y municipal como objetivo. En la medida en que se accede a mayor cantidad y diversidad de datos a lo largo del tiempo se podrá acometer predicción de la actualidad (nowcasting). El propósito último de este desarrollo es la generación de predicciones a tres meses vista (forecasting).

## 6. Conclusiones y recomendaciones

Este artículo ofrece una revisión sobre los últimos avances y ejemplos surgidos en la aplicación de machine learning con el fin de aumentar el conocimiento disponible sobre cuáles son las características de los grupos de población que enfrentan mayores carencias alimentarias, los factores que pueden agravar o acelerar el deterioro de su situación, así como la delimitación de los territorios en los que sus habitantes pueden verse más afectados por cambios en diferentes ámbitos como el agroclimático, el económico, el sociopolítico o la incidencia de desastres y conflictos, entre otros. Dado el carácter complejo y multidimensional de la inseguridad alimentaria, la construcción de modelos de predicción apoyados en machine learning requiere del acceso regular a una gran cantidad de datos y fuentes de información, tantas como variables se incorporen al modelo. Este es el primer desafío de este tipo de herramientas, y es también un interés compartido entre instituciones públicas, agencias de cooperación internacional y ONGs. Poder alinear reto e interés comunes debería ser una prioridad para todos los actores involucrados en el monitoreo y prevención de posibles crisis alimentarias; cada uno de ellos de forma individual solo puede vislumbrar unas escasas teselas de un mosaico mucho más amplio y variado. La coordinación y puesta en común de datos es fundamental en el seguimiento de las variables targets o independientes a las que luego se suman las variables predictoras de diferente tipo que proceden de numerosas fuentes secundarias. Compartir datos es posible cuando existen criterios homólogos en los cálculos muestrales y procesos de levantamiento de información en campo, existe una estandarización en el uso de indicadores e índices y se emplean los mismos criterios de análisis y reporte.

En los procesos de estandarización y en la capacidad de generar información primaria tienen un liderazgo natural las dos agencias de Naciones Unidas de referencia; WFP y FAO. En el caso centroamericano ambas son las entidades que garantizan una generación de información primaria, y en especial de variables targets (FCS, HHS, HDDS, rCSI, FIES, antropometría), más estable en el tiempo y con mayor representatividad territorial.

Esta labor de consenso e intercambio de información es el paso previo antes de comenzar la construcción de modelos de predicción que deben partir de objetivos concretos, ya sea focalizados en la mejor caracterización de grupos de población en riesgo o en situación de crisis alimentaria (targeting) o en la identificación de las

zonas en las que el deterioro de la inseguridad alimentaria alcanza un mayor grado (mapping). En el primer caso, las variables independientes o predictoras de tipo socioeconómico y demográfico adquieren mayor importancia. Cuando la prioridad es delimitar cuáles son los territorios en peor situación, las variables predictoras con un componente geográfico o geoespacial son esenciales.

De acuerdo con la revisión de literatura efectuada es conveniente construir los modelos de predicción tomando en cuenta las condiciones de vulnerabilidad estructurales, una parte de las cuales tienen una lenta evolución con el pasar de los años, mientras que otras permanecen inalteradas, como las referidas a la topografía. En el cuadro 7 se efectúa una propuesta de variables independientes con las que elaborar perfiles de vulnerabilidad a la inseguridad alimentaria que deberán actualizarse anualmente. Para este tipo de análisis de contexto pueden usarse herramientas como los Self-organizing Map (SOM), en una línea de trabajo ya avanzada para territorios centroamericanos por Abarca-Álvarez et al., 2022. La actualización de los perfiles de vulnerabilidad debería ir acompañada por una publicación anual específica en la que se analicen los cambios producidos, la evolución experimentada por grupos de población y territorios incluidos en los perfiles obtenidos por los análisis, así como una valoración de las posibles causas en las transformaciones acontecidas en los perfiles.

La predicción de potenciales crisis alimentarias es posible en la medida en que se monitorean con alta periodicidad variables predictoras que reflejan cambios a corto y medio plazo, perturbaciones o crisis en las dimensiones fundamentales y factores que pueden incidir en la seguridad alimentaria de grupos de población o de los habitantes de zonas geográficas a diferente escala. En el cuadro 8 se ofrece un conjunto de variables independientes o predictoras agrupadas en siete categorías, entre las que destacan por el mayor número de variables predictoras o independientes que aportan las de tipo agroclimático, económico y de seguridad alimentaria. Entre estas últimas también se incluyen variables de resultado de seguridad alimentaria procedentes de levantamientos de información y análisis previos. La conformación del modelo de predicción implicará un trabajo de homogeneización de datos para poder trabajar con ellos de una forma coherente, empleando para cada tipología de ellos las herramientas de machine learning más adecuadas. Sobre esta base se deben probar diferentes algoritmos y comprobar cuál de ellos proporciona una mayor precisión en sus predicciones, tomando por tanto sus resultados como referencia.

Se recomienda realizar una actualización mensual de las variables predictoras que ofrecen registros con al menos esa periodicidad (por ejemplo buena parte de las agroclimáticas y algunas de las económicas), sin embargo, dada la carga de trabajo que conlleva, se considera más adecuado efectuar un ejercicio trimestral de predicción en el que se utilizan las variables predictoras procedentes de diferentes fuentes, y más en concreto, las anomalías de distinto grado producidas durante el trimestre son identificadas al compararse los valores medidos con el promedio de su propia serie temporal.

La disponibilidad de suficientes datos, tanto actuales como del pasado, marcarán el resultado y capacidad predictiva del modelo aplicado; en escenarios con menor

disponibilidad de información se podrá optar a la realización de predicciones contemporáneas o actuales de variables targets en territorios de los que no disponemos de suficiente información primaria; cuando la disponibilidad de datos es mayor se pueden plantear predicciones de corto y medio plazo (1-3 meses) con un enfoque por tanto de nowcasting. En los supuestos en los que se cuenta con una amplia diversidad de datos de calidad y con la suficiente extensión temporal, se pueden plantear predicciones de largo plazo o forecasting (6-12 meses), siendo conscientes que sería más bien un avance de tendencia, dada la diversidad de cambios que pueden producirse durante un año en aspectos que inciden en la seguridad alimentaria.

Los ejercicios trimestrales de actualización de los insumos que requiere el modelo de predicción a través del uso de distintos algoritmos de machine learning deben acompañarse con la realización de informes trimestrales en los que se compartan los valores medidos más relevantes, se identifiquen tendencias y se comuniquen con diferente capacidad de anticipación los resultados de predicción enfocados en grupos de población o territorios. Por último, estos informes trimestrales, que serían el producto que llegase a las instituciones nacionales y locales, además de a la comunidad humanitaria, deben incorporar recomendaciones derivadas de los análisis de predicción para focalizar atención y recursos en áreas geográficas o colectivos concretos, y de este modo, evitar o mitigar de forma mucho más eficiente posibles crisis alimentarias. Esta información debe de tener una divulgación especial en las mesas técnicas de pronóstico de la seguridad alimentaria según criterios CIF, como un apoyo a la toma de decisiones de los expertos, no como una sustitución del imprescindible aporte y valoración de los especialistas.

## 7. Referencias bibliográficas

- Abarca-Álvarez, F. J., Méndez, C., Torres-Parejo, U., & García-Arias, M. A. (2022). Mejora de la toma de decisiones en la asistencia humanitaria mediante el uso de metodologías del campo de la Inteligencia Artificial. In *La transversalidad de la investigación en comunicación* (pp. 587-609). Dykinson.
- Alpizar, F., Saborío-Rodríguez, M., Martínez-Rodríguez, M. R., Viguera, B., Vignola, R., Capitán, T., & Harvey, C. A. (2020). Determinants of food insecurity among smallholder farmer households in Central America: recurrent versus extreme weather-driven events. *Regional Environmental Change*, 20, 1-16.
- Andrée, B. P. J. (2022). Machine Learning Guided Outlook of Global Food Insecurity Consistent with Macroeconomic Forecasts. *World Bank Policy Research Working Papers*.
- Andrée, B. P. J., Chamorro, A., Kraay, A., Spencer, P., & Wang, D. (2020). Predicting food crises. *World Bank Policy Research Working Paper* 9412.
- Aurino, E. (2014). Selecting a core set of indicators for monitoring global food security: A methodological proposal. *FAO food and nutrition series*.
- Backer, D., & Billing, T. (2021). Validating famine early warning systems network projections of food security in Africa, 2009–2020. *Global Food Security*, 29, 100510.

- Backer, D., & Billing, T. (2024). Forecasting the prevalence of child acute malnutrition using environmental and conflict conditions as leading indicators. *World Development*, 176, 106484.
- Berry, E. M., Dernini, S., Burlingame, B., Meybeck, A., & Conforti, P. (2015). Food security and sustainability: can one exist without the other?. *Public health nutrition*, 18(13), 2293-2302.
- Bitew, F. H., Sparks, C. S., & Nyarko, S. H. (2022). Machine learning algorithms for predicting undernutrition among under-five children in Ethiopia. *Public health nutrition*, 25(2), 269-280.
- Browne, C., Matteson, D. S., McBride, L., Hu, L., Liu, Y., Sun, Y., ... & Barrett, C. B. (2021). Multivariate random forest prediction of poverty and malnutrition prevalence. *PloS one*, 16(9), e0255519.
- Busker, T. S., van den Hurk, B., de Moel, H., van den Homberg, M., van Straaten, C., Odongo, R. A., & Aerts, J. C. (2023). Predicting Food-Security Crises in the Horn of Africa Using Machine Learning. *Authorea Preprints*.
- Christensen, C., Wagner, T., & Langhals, B. (2021). Year-independent prediction of food insecurity using classical and neural network machine learning methods. *Ai*, 2(2), 244-260.
- Deléglise, H., Interdonato, R., Bégué, A., d'Hôtel, E. M., Teisseire, M., & Roche, M. (2022). Food security prediction from heterogeneous data combining machine and deep learning methods. *Expert Systems with Applications*, 190, 116189.
- Devereux, S., Sabates-Wheeler, R., & Longhurst, R. (Eds.). (2012). *Seasonality, rural livelihoods and development*. New York, NY, USA:: Earthscan.
- El Naqa, I., & Murphy, M. J. (2015). What is machine learning? (pp. 3-11). Springer International Publishing.
- FAO, FIDA, OMS, PMA y UNICEF. (2023). *El estado de la seguridad alimentaria y la nutrición en el mundo 2023. Urbanización, transformación de los sistemas agroalimentarios y dietas saludables a lo largo del continuo rural-urbano*. Roma, FAO. <https://doi.org/10.4060/cc3017es>
- FAO (1996). *Rome Declaration on Food Security and World Food Summit Plan of Action*. Rome: FAO.
- FAO (2009). *Declaration of the World Food Summit on Food Security*. Rome: FAO.
- Foini, P., Tizzoni, M., Martini, G., Paolotti, D., & Omodei, E. (2023). On the forecastability of food insecurity. *Scientific Reports*, 13(1), 2793.
- Frankenberger, T. R., & Verduijn, R. (2011). *Integrated Food Security Phase Classification (IPC); End of Project Evaluation*. Rome: FAO. [https://www.ipcinfo.org/fileadmin/user\\_upload/ipcinfo/docs/1\\_IPC\\_Glob\\_Proj\\_Eval\\_04\\_1\\_1\\_Report.pdf](https://www.ipcinfo.org/fileadmin/user_upload/ipcinfo/docs/1_IPC_Glob_Proj_Eval_04_1_1_Report.pdf)
- FSIN & Global Network Against Food Crises (2021). *Global Report on Food Crises 2021*. Rome. <https://www.fsinplatform.org/global-report-food-crises-2021>
- FSIN & Global Network Against Food Crises. (2023). *Global Report on Food Crises 2023*. Rome. <https://www.fsinplatform.org/global-report-food-crises-2023>

- FSIN & Global Network Against Food Crises. (2024). Global Report on Food Crises 2024. Rome.
- <https://www.fsinplatform.org/report/global-report-food-crises-2024/>
- Gao, C., Fei, C. J., McCarl, B. A., & Leatham, D. J. (2020). Identifying Vulnerable households using machine learning. *Sustainability*, 12(15), 6002.
- Herteux, J., R  th, C., Baha, A., Martini, G., & Piovani, D. (2023). Forecasting Trends in Food Security: a Reservoir Computing Approach. arXiv preprint arXiv:2312.00626.
- Hoddinott, J. (1999). Choosing outcome indicators of household food security. International Food Policy Research Institute.
- Hossain, M., Mullally, C., & Asadullah, M. N. (2019). Alternatives to calorie-based indicators of food security: An application of machine learning methods. *Food policy*, 84, 77-91.
- IPC Global Partners. (2019). The Integrated Food Security Phase Classification Technical Manual Version 3.0. Rome: FAO. [https://www.ipcinfo.org/fileadmin/user\\_upload/ipcinfo/docs/IPC\\_Technical\\_Manual\\_3\\_Final.pdf](https://www.ipcinfo.org/fileadmin/user_upload/ipcinfo/docs/IPC_Technical_Manual_3_Final.pdf)
- Jones, A. D., Ngunjiri, F. M., Pelto, G., & Young, S. L. (2013). What are we assessing when we measure food security? A compendium and review of current metrics. *Advances in nutrition*, 4(5), 481-505.
- Kaut, J., Bakker, E., van Uffelen, G. J., Crujssen, F., & Malkowsky, C. (2022). From insight to foresight: using data to improve food and nutrition outcomes in protracted food crises in the Horn of Africa (No. WCDI-22-217). Wageningen Centre for Development Innovation.
- Krishnamurthy, P. K., Choularton, R. J., & Kareiva, P. (2020a). Dealing with uncertainty in famine predictions: How complex events affect food security early warning skill in the Greater Horn of Africa. *Global Food Security*, 26, 100374.
- Krishnamurthy R, P. K., Fisher, J. B., Schimel, D. S., & Kareiva, P. M. (2020b). Applying tipping point theory to remote sensing science to improve early warning drought signals for food security. *Earth's Future*, 8(3), e2019EF001456.
- Laney, D., and L. Kart. 2012. Emerging Role of the Data Scientist and the Art of Data Science. Report G00227058. Stamford, CT: Gartner, Inc. <https://www.gartner.com/en/documents/1955615>
- Lentz, E. C., Michelson, H., Baylis, K., & Zhou, Y. (2019). A data-driven approach improves food insecurity crisis prediction. *World Development*, 122, 399-409.
- Martini, G., Bracci, A., Riches, L., Jaiswal, S., Corea, M., Rivers, J., ... & Omodei, E. (2022). Machine learning can guide food security efforts when primary data are not available. *Nature Food*, 3(9), 716-728.
- Meerza, S. I. A., Meerza, S. I. A., & Ahamed, A. (2021). Food insecurity through machine learning lens: identifying vulnerable households. Selected Paper prepared for presentation at the 2021 Agricultural & Applied Economics Association Annual Meeting, Austin, TX, August 1 - August 6. [https://ageconsearch.umn.edu/nanna/record/314072/files/Abstracts\\_21\\_06\\_15\\_22\\_32\\_25\\_65\\_\\_173\\_216\\_85\\_243\\_0.pdf?withWatermark=0&withMetadata=0&version=1&registerDownload=1](https://ageconsearch.umn.edu/nanna/record/314072/files/Abstracts_21_06_15_22_32_25_65__173_216_85_243_0.pdf?withWatermark=0&withMetadata=0&version=1&registerDownload=1)

- Murdoch, W. J., Singh, C., Kumbier, K., Abbasi-Asl, R., & Yu, B. (2019). Definitions, methods, and applications in interpretable machine learning. *Proceedings of the National Academy of Sciences*, 116(44), 22071-22080.
- Norberg, J. (2017). *Progress: Ten reasons to look forward to the future*. Simon and Schuster.
- Oakford, S. (2019). Deaths before data. *Significance*, 16(1), 29-31.
- Qasrawi, R., Hoteit, M., Tayyem, R., Bookari, K., Al Sabbah, H., Kamel, I., ... & Al-Halawa, D. A. (2023). Machine learning techniques for the identification of risk factors associated with food insecurity among adults in Arab countries during the COVID-19 pandemic. *BMC public health*, 23(1), 1805.
- Sotelo Pérez I., Sotelo Pérez, M. y Sotelo Navalpotro J. A. (2023). Análisis geográfico regional de la “huella hídrica” española: Bases para la planificación turística. *Cuadernos de turismo*, ISSN 1139-7861, Nº. 51 (Ejemplar dedicado a: Enero - Junio), págs. 349-383
- Sotelo Pérez I. y Sotelo Navalpotro J. A. (2022). Aspectos científicos del estudio del Medio Ambiente, en el contexto del Espacio Geográfico, desde el ámbito del Estado Constitucional de Derecho y el Estado Jurisprudencial de Derecho. *Observatorio Medioambiental*, 25, 65-90.
- UNISDR (United Nations International Strategy for Disaster Reduction). 2017. Report of the open-ended intergovernmental expert working group on indicators and terminology relating to disaster risk reduction. Geneva: UNISDR. [https://www.preventionweb.net/files/50683\\_oiewgreportenglish.pdf](https://www.preventionweb.net/files/50683_oiewgreportenglish.pdf).
- Uskov, V. L., Bakken, J. P., Shah, A., Krock, T., Uskov, A., Syamala, J., & Rachakonda, R. (2019). Smart learning analytics: conceptual modeling and agile engineering. In *Smart Education and e-Learning 2018 5* (pp. 3-16). Springer International Publishing.
- Villacis, A., Badruddoza, S., Mayorga, J., & Mishra, A. K. (2022). Using machine learning to test the consistency of food insecurity measures. Selected Paper prepared for presentation at the 2021 Agricultural & Applied Economics Association Annual Meeting, Austin, TX, August 1 – August
- Westerveld, J. J., van den Homberg, M. J., Nobre, G. G., van den Berg, D. L., Teklesadik, A. D., & Stuit, S. M. (2021). Forecasting transitions in the state of food security with machine learning using transferable features. *Science of the Total Environment*, 786, 147366.
- Zhou, Y. (2020). Three essays on machine learning and food security. Doctoral dissertation, University of Illinois at Urbana-Champaign..