

DOI: <https://doi.org/10.56124/allpa.v9i18.0163>

Resiliencia de la seguridad alimentaria ante el fenómeno El Niño 2026 en Ecuador: Análisis de disponibilidad y acceso mediante inteligencia artificial y big data satelital

Food security resilience against El Niño 2026 phenomenon in Ecuador: Analysis of availability and access using artificial intelligence and satellite big data

García-Pumagualle Cristian ¹; Peralta-Saa Lilia Ofir ²; Abdo-Peralta Paula ³;
Rojas-Llangarí Dennys Franklin ⁴

¹ Escuela Superior Politécnica de Chimborazo, ESPOCH. Riobamba, Ecuador.
Correo: alexis.garcia@epoch.edu.ec. ORCID ID: <https://orcid.org/0009-0009-4341-408X>

² Escuela Superior Politécnica de Chimborazo, ESPOCH. Riobamba, Ecuador.
Correo: l_peralta@epoch.edu.ec. ORCID ID: <https://orcid.org/0000-0001-8958-8100>

³ Escuela Superior Politécnica de Chimborazo, ESPOCH. Riobamba, Ecuador.
Correo: paula.abdo@epoch.edu.ec. ORCID ID: <https://orcid.org/0000-0002-9383-9168>

⁴ Escuela Superior Politécnica de Chimborazo, ESPOCH. Riobamba, Ecuador.
Correo: dennys.rojas@epoch.edu.ec. ORCID ID: <https://orcid.org/0009-0001-7775-7621>

Resumen

Este artículo evalúa la resiliencia de la seguridad alimentaria en Ecuador ante el inminente Fenómeno El Niño 2026 utilizando un enfoque de Big Data Satelital e Inteligencia Artificial. Se integraron datos multi-sensor de las misiones NOAA OISST (SST), NASA-USDA SMAP (humedad del suelo) y CHIRPS (precipitación) con microdatos socioeconómicos de la encuesta ENDI 2024. Mediante el uso de Random Forest, se modeló la vulnerabilidad del rendimiento agrícola en cultivos estratégicos (arroz y maíz), alcanzando un R2-Score de 0.9755 y un Kappa de 0.8780. El análisis de Cadenas de Markov proyecta un 85% de probabilidad de un evento extraordinario para el trimestre Enero-Febrero 2027. Los resultados identifican a las provincias de Guayas y Los Ríos como los epicentros de riesgo por anegamiento e interrupción logística, correlacionando con incrementos en la inflación alimentaria y riesgos en la utilización nutricional. Se proponen mecanismos de Acción Anticipatoria, incluyendo transferencias monetarias focalizadas, para mitigar el impacto en la desnutrición crónica infantil.

Palabras clave: el niño 2026; seguridad alimentaria; inteligencia artificial; big data satelital; Ecuador.

Abstract

This article evaluates food security resilience in Ecuador facing the imminent 2026 El Niño phenomenon using a Satellite Big Data and Artificial Intelligence approach. Multi-sensor data from NOAA OISST (SST), NASA-USDA SMAP (soil moisture), and CHIRPS (precipitation) missions were integrated with socioeconomic microdata from the 2024 ENDI survey. Using Random Forest, agricultural yield vulnerability in strategic crops (rice and maize) was modeled, achieving an R2-Score of 0.9755 and a Kappa of 0.8780. Markov Chain analysis projects an 85% probability of an extraordinary event for the January-February 2027 quarter. Results identify Guayas and Los Rios provinces as epicenters of flooding risk and logistical disruption, correlating with increases in food inflation and risks in nutritional utilization. Anticipatory Action mechanisms are proposed, including focused monetary transfers, to mitigate the impact on chronic childhood malnutrition.

Keywords: el niño 2026; food security; artificial intelligence; satellite big data; Ecuador.

1. Introducción

El Fenómeno El Niño (ENSO) constituye la principal fuente de variabilidad climática interanual a escala global, con impactos socioeconómicos particularmente agudos en la cuenca del Pacífico Sur. En Ecuador, la recurrencia de eventos extraordinarios como los de 1982-1983 y 1997-1998 ha demostrado la fragilidad de los sistemas productivos nacionales. Bajo el escenario actual de 2026, la convergencia de una anomalía térmica persistente en la Región Niño 1+2 y una vulnerabilidad estructural preexistente plantea un riesgo sistémico para la Seguridad Alimentaria (Albuja Echeverría, 2022; Grace et al., 2012).

La seguridad alimentaria se define multidimensionalmente a través de cuatro pilares: disponibilidad, acceso, utilización y estabilidad. Estudios previos han explorado los impactos hidrológicos del ENSO (Thielen et al., 2023a), pero persiste una brecha en la integración transdisciplinaria que conecte la analítica satelital de alta resolución con indicadores socio-nutricionales como la Desnutrición Crónica Infantil (DCI) (Instituto Nacional de Estadística y Censos (Andrade & Satorre, 2015;


Hansen et al., 1998; INEC, 2024a; WHO, 2019a).

El presente artículo propone un marco de evaluación basado en Inteligencia Artificial y Big Data para cuantificar la resiliencia de la seguridad alimentaria ante El Niño 2026. La tesis central sostiene que la inseguridad alimentaria transitoria en el Litoral ecuatoriano no deriva únicamente de la pérdida de disponibilidad agrícola, sino de una degradación sinérgica del acceso logístico y la calidad del agua segura en comunidades rurales (García & Torres, 2016).

2. Metodología (materiales y métodos)

El marco de trabajo implementado para evaluar la resiliencia de la seguridad alimentaria se describe en el siguiente flujograma (Figura 1), el cual articula la ingesta de datos multi-sensor con el modelado predictivo y la evaluación socioeconómica (Arreguín-Cortés et al., 2016; INEC, 2024b).

Figura 1: Marco Metodológico Transdisciplinario para la Evaluación de la Seguridad Alimentaria ante El Niño 2026



2.1 Adquisición y Procesamiento de Datos (Big Data)

Se implementó un pipeline de ingesta masiva en la nube integrando fuentes multi-sensor: - Precipitación: CHIRPS Daily (0.05° res) para el cálculo de anomalías históricas (1981-2026). - Humedad del Suelo: NASA-USDA SMAP (Soil Moisture Active Passive) para determinar umbrales de saturación. - Vigor Vegetativo: MODIS MOD13Q1 (NDVI) para el monitoreo de biomasa agrícola. - Socioeconomía: Microdatos de la ENDI (2023-2024) y reportes de la Red Vial Estatal del MTOP (2025). Para el análisis prospectivo hacia el evento de

2026, el modelo asume de forma metodológica que las vulnerabilidades estructurales medidas en 2024 (tales como el acceso a agua potable y niveles de pobreza extrema) se mantienen estadísticamente constantes (Ayala Ayala et al., 2023; Jeong et al., 2016).

2.1.1 Agregación Espacial y Resolución del MAUP

Para integrar los datos continuos de grillas satelitales (resolución de ~5.5 km) con los polígonos discretos de la división política administrativa (GAUL Level 2 / Cantonal), se aplicó una técnica de Agregación por Área de Interés (AOI) mediante Reductores de Región (Zonal

Statistics). Para mitigar el Problema de la Unidad de Área Modificable (MAUP), se ponderaron las celdas de cuadrícula por el área de superficie agrícola efectiva dentro de cada cantón, asegurando que las anomalías climáticas reflejen el impacto real sobre las zonas productivas y no sobre áreas urbanas o cuerpos de agua (Barrett, 2010; Khaki & Wang, 2019).

2.2 Modelado Predictivo (Machine Learning)

Se desarrolló un modelo Random Forest (RF) para predecir la pérdida de rendimiento agrícola. El algoritmo se configuró con los siguientes hiperparámetros para asegurar la reproducibilidad: - $n_estimators$: 200 - max_depth : 15 - $random_state$: 42 - $train_test_split$: 70% entrenamiento / 30% validación (BCRP, 2024; Llorente-Isidro et al., 2009).

Para mitigar el riesgo de que el alto rendimiento del modelo fuera producto de autocorrelación espacial espuria (común en variables agroclimáticas contiguas), se evaluaron los residuales del modelo mediante el cálculo del Índice de Moran global. La ausencia de clustering significativo en los errores

validó la robustez de las predicciones más allá del tradicional k-fold (Breiman, 2001; Mbow et al., 2019).

2.2.1 Definición del Índice de Riesgo (Risk Score)

Para la integración de los resultados en una métrica accionable, se calculó el **Risk Score (RS)** provincial mediante una suma ponderada de variables normalizadas (n): (Cai et al., 2020; MTOP, 2025).

$$RS = (nL_{precip} \times 0.40) + (nH_{suelo} \times 0.30) + (nE_{vial} \times 0.30)$$

Donde L_{precip} representa la precipitación acumulada proyectada, H_{suelo} la anomalía de saturación hídrica y E_{vial} el índice de vulnerabilidad de la infraestructura logística. Adicionalmente, la importancia de las variables se evaluó mediante la disminución de la impureza de Gini y la importancia por permutación, identificando a la humedad del suelo y la anomalía térmica como los predictoras dominantes (Cai et al., 2021; Phalkey et al., 2015).

2.3 Análisis Probabilístico (Cadenas de Markov)

Para la proyección de la ventana crítica, se utilizó una Cadena de Markov de Primer Orden. La matriz de transición estocástica P se definió a partir del análisis de las trayectorias históricas del ENSO en la Región Niño 1+2 durante el periodo 1950-2025: (Campbell et al., 2016; Podestá et al., 1999).


$$P = \begin{pmatrix} 0.75 & 0.20 & 0.05 & 0.00 \\ 0.15 & 0.60 & 0.20 & 0.05 \\ 0.05 & 0.15 & 0.50 & 0.30 \\ 0.00 & 0.05 & 0.10 & 0.85 \end{pmatrix}$$

Donde los estados representan condiciones

$S = \{Neutral, Débil, Moderado, Extraordinario\}$

. Dado un vector de estado inicial en mayo 2026 $\pi_0 = [0.10, 0.40, 0.40, 0.10]$, se calculó la evolución temporal $\pi_t = \pi_0 P^t$. La convergencia hacia el estado estacionario $\pi_\infty = \lim_{t \rightarrow \infty} \pi_t$ revela que la probabilidad de residir en el estado *Extraordinario* alcanza el 85% en el pico del evento (Figura 2) (Carrillo & Parraga-Alava, 2018; Preti et al., 2011).

Figura 2: Ventana de Maduración del Riesgo Climático mediante Cadenas de Markov. La curva refleja la probabilidad acumulada de alcanzar un escenario extraordinario en el pico del evento (enero-febrero).



2.4 Validación Estadística

Se utilizaron métricas de rigor académico para evaluar el desempeño del ensamble predictivo (Tabla 1) (Cashin et al., 2015; Shukla et al., 2019).

Tabla 1: Desempeño del Modelo Random Forest (Predicción de Cultivos)

Métrica	Valor
OAA	0.9433
RMSE	2.1882
MAE	1.6620
R2-Score	0.9755
F1-Score	0.9553
Kappa	0.8780

3. Resultados y discusión

3.1 Análisis Oceánico y Climático:
Cronología de Anomalías Extremas

La evaluación de la Seguridad Alimentaria ante El Niño 2026 requiere una contextualización espacial de la magnitud térmica frente a los eventos análogos de mayor impacto registrados instrumentalmente. Utilizando datos de alta resolución de la misión NOAA OISST V2.1 procesados en Google Earth Engine, se presenta la siguiente cronología comparativa (Ceccarelli et al., 2024; Thielen et al., 2023b).

Tabla 2: Parámetros del Análisis Espectral (Wavelet/Welch)

Parámetro Espectral	Valor
Metodología	Wavelet Transform (Morlet)
Periodo_Dominante	4.75 años

Energia_Oscilacion	-34.93%
Frecuencia_Muestreo	Mensual

3.1.1 Picos Históricos de Referencia (1997 y 2015)

El evento de 1997 representa el umbral máximo de intensidad térmica observado (Figura 3). Durante su pico en noviembre, la anomalía superó los +5.0°C en el núcleo del Pacífico Ecuatorial, con una lengua térmica compacta que impactó directamente la costa de Ecuador. Por su parte, el evento de 2015 (Figura 4) exhibió una mayor dispersión hacia el oeste, aunque con un gradiente térmico severo frente a las costas del Litoral ecuatoriano (Cai et al., 2021; CIAT, 2014; Thielen et al., 2023b; Tirado et al., 2010).

Figura 3: Hito Histórico: Pico de Anomalía SST durante el evento extraordinario de 1997-1998 (noviembre). Se observa la máxima expresión de la lengua térmica en la Región Niño 1+2.





Figura 4: Hito Histórico: Pico de Anomalía SST durante el evento fuerte de 2015-2016 (noviembre). Se evidencia la extensión de la anomalía hacia el Pacífico Central.




3.1.2 Escenario 2026: Estado Actual y Pico Proyectado

A la fecha de redacción de este artículo en mayo de 2026, el monitoreo satelital revela una anomalía activa de +1.28°C con una tendencia de calentamiento

sostenido en la Región Niño 1+2 (Figura 5). Esta configuración espacial de “estadio temprano” sugiere una maduración acelerada del acoplamiento océano-atmósfera (Crane-Droesch, 2018; UNICEF, 2019).


Figura 5: Estado Actual: Monitoreo de la Anomalía SST en mayo 2026. La señal térmica indica una persistencia crítica en el perfil costero sudamericano.



La modelización probabilística y estocástica proyecta que el evento alcanzará su máxima intensidad en el trimestre enero-febrero 2027 (Figura 6). El escenario proyectado muestra un

núcleo térmico agresivo que amenaza la estabilidad de los sistemas agroalimentarios del Litoral (Cusme Macias & Gaibor, 2023; Vicente-Serrano et al., 2016).

Figura 6: Proyección de Pico: Escenario de máxima anomalía térmica esperado para Enero 2027. La intensidad proyectada sitúa a este evento como el tercero más fuerte en el registro histórico.




3.1.3 Comparativa Estadística de Récor ds

La Figura 7 resume cuantitativamente la posición de la anomalía de 2026 frente a

los registros históricos instrumentales, validando la categoría de riesgo extraordinario (Andrian et al., 2024; de la Casa et al., 2021; Vincenzi et al., 2011).

Figura 7: Comparativa de Anomalías Térmicas Máximas (°C) registradas en la Región Niño 1+2. El evento 2026 se perfila como un hito sistémico de alto impacto.




3.2 Disponibilidad y Vulnerabilidad de Cultivos

La intersección de la saturación del suelo (>85% en vertientes andinas) y la

anomalía pluviométrica proyecta una pérdida de rendimiento significativa en cultivos estratégicos (Tabla 3) (Fan et al., 2019; Wheeler & von Braun, 2013).

Figura 8: Mapa Satelital de Saturación de Humedad del Suelo (NASA-USDA SMAP). La saturación crítica en el Litoral es el factor determinante en la pérdida de rendimiento agrícola.



3.2.1 Impacto Agrícola y Riesgo por Anegamiento

Tabla 3: Risk Score Agrícola y Variables Climáticas por Provincia (KDD)

Provincia	Lluvia (mm)	Humedad (%)	MRI Index	Risk Score
Los Rios	1393.20	63.30	0.9000	0.8582
Esmeraldas	1020.20	72.10	2.8000	0.7896
Napo	915.00	73.70	7.3000	0.6320
Guayas	983.70	51.70	0.6000	0.4453
Manabi	915.00	58.60	2.4000	0.4156
Pichincha	663.60	55.80	6.6000	0.2119
El Oro	652.50	52.70	5.7000	0.1994
Azuay	364.50	56.90	8.9000	0.1110
Chimborazo	342.50	57.10	9.1000	0.0736

El arroz y el maíz presentan los mayores niveles de riesgo por anegamiento, mientras que el cacao enfrenta una vulnerabilidad fúngica exacerbada por la

humedad relativa elevada (Ceccarelli et al., 2024; FAO, 2023; WHO, 2019b).

3.3 Acceso Logístico y Utilización Nutricional

El análisis geoespacial identifica a Manabí y Los Ríos como las provincias con mayor fragilidad en la infraestructura vial de "última milla". La vía E-25 presenta nodos críticos en riesgo de aislamiento, lo que correlaciona con un incremento proyectado del 53% en la inflación alimentaria (BCRP, 2024; Fernández et al., 2021; WMO, 2026).


En el pilar de utilización, la prevalencia de desnutrición crónica infantil (DCI) en zonas rurales (22.1%) se ve amenazada por la contaminación de fuentes hídricas con *E. coli* tras las inundaciones, consolidando una trampa de vulnerabilidad socio-climática (Fukuda et al., 2013; INEC, 2024b).

3.4 Desempeño del Modelo de IA

La robustez de las proyecciones se sustenta en las métricas del modelo Random Forest validado mediante una partición estratificada (70/30) y ponderación de clases para mitigar el desbalance de datos (Figura 8). El alto rendimiento métrico con un R^2 -Score de 0.9755 se respalda por una rigurosa validación cruzada (k-fold), asegurando que el modelo captura generalizaciones físicas subyacentes y no incurre en sobreajuste (overfitting) (Gelagay et al., 2025).

La Figura 9 detalla la contribución relativa de cada variable predictora. La saturación de humedad del suelo (SMAP) emerge como el factor crítico (42%), seguida de la anomalía térmica en la Región 1+2 (28%), validando la importancia del acoplamiento biofísico (Godfray et al., 2010).

Figura 9: Importancia de Características (Feature Importance) del modelo Random Forest. La humedad del suelo y la anomalía SST explican el 70% de la varianza en la pérdida de rendimiento proyectada



4. Conclusiones

La resiliencia de la seguridad alimentaria en Ecuador bajo el cambio climático depende de la capacidad del Estado para integrar la ciencia de datos en la política pública. En el marco del modelo de "Acción Anticipatoria" promovido globalmente por entidades como la FAO, este estudio provee una hoja de ruta fundamentada.

Se recomienda enfáticamente utilizar los mapas de riesgo aquí presentados para focalizar y ejecutar transferencias monetarias de emergencia mediante bonos anticipados dirigidas a mujeres gestantes en las provincias de Guayas y Los Ríos, antes de que se materialicen las inundaciones proyectadas para 2026.

No obstante, la implementación efectiva de estas medidas enfrenta barreras institucionales críticas que deben ser abordadas: la fragmentación de los registros administrativos de beneficiarios, las dificultades logísticas de bancarización en zonas rurales aisladas del Litoral y la necesidad de una gobernanza ágil que permita liberar fondos públicos bajo criterios de alerta temprana y no solo de desastre consumado. Priorizar estas intervenciones previsoras, junto con el

aseguramiento logístico en el corredor de la vía E-25, mitigará eficazmente la inseguridad alimentaria transitoria y blindará el desarrollo nutricional de la población más vulnerable.

El uso de Inteligencia Artificial y Big Data Satelital ha demostrado ser una herramienta indispensable para la gobernanza climática, permitiendo una transición de una gestión reactiva a una gestión proactiva y resiliente de los sistemas agroalimentarios nacionales.

Bibliografía

- Albuja Echeverría, W. S. (2022). Determinantes Socioeconómicos de La Desnutrición Crónica En Ecuador. *Revista de Economía*.
- Andrade, J. F., & Satorre, E. H. (2015). Environmental Determinants of Annual Grain Yield. *Field Crops Research*.
<https://doi.org/10.1016/j.fcr.2015.03.008>
- Andrian, L., Álvarez, C. M., & Chávez, A. (2024). *Efectos del fenómeno El Niño en la Región Andina: Una aproximación empírica*.
<https://doi.org/10.18235/0005512>
- Arreguín-Cortés, F. I., López-Pérez, M., & Marengo-Mogollón, H. (2016). Las Inundaciones En Un Marco de Incertidumbre Climática.

- Tecnología y Ciencias Del Agua*, 7(5), 5–13.
- Ayala Ayala, M., Lane, M., & Montúfar, R. (2023). Motivations to Adopt Agroecology in Northern Andes of ECUADOR. *Ecuadorian J. S.T.E.A.M*, 3.
- Barrett, C. B. (2010). Measuring Food Insecurity. *Science*, 327(5967), 825–828.
<https://doi.org/10.1126/science.1182768>
- BCRP. (2024). *Reporte de Inflación Marzo 2024: Impactos de El Niño En La Región Andina*.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32.
<https://doi.org/10.1023/A:1010933404324>
- Cai, W., McPhaden, M. J., Grimm, A. M., Rodrigues, R. R., Taschetto, A. S., Garreaud, R. D., Dewitte, B., Puel, G., & Vera, C. (2020). Climate impacts of the El Niño–Southern Oscillation on South America. *Nature Reviews Earth & Environment*, 1(4), 215–231.
<https://doi.org/10.1038/s43017-020-0040-3>
- Cai, W., Santoso, A., Collins, M., Dewitte, B., Karamperidou, C., Kug, J.-S., Lengaigne, M., McPhaden, M. J., Stuecker, M. F., Taschetto, A. S., Timmermann, A., Wu, L., Yeh, S.-W., Wang, G., Ng, B., Jia, F., & Yang, Y. (2021). Changing El Niño–Southern Oscillation in a warming climate. *Nature Climate Change*, 11(6), 488–500.
<https://doi.org/10.1038/s41558-021-01131-5>
- Campbell, B. M., Vermeulen, S. J., Aggarwal, P. K., Corner-Dolloff, C., Girvetz, E., Loboguerrero, A. M., Ramirez-Villegas, J., Rosenstock, T. S., Sebastian, L., Thornton, P. K., & Wollenberg, E. (2016). Agriculture and Food Systems to 2050: Global Challenges and Mitigation Opportunities. *Global Food Security*, 11, 39–43.
<https://doi.org/10.1016/j.gfs.2016.05.001>
- Carrillo, J. M., & Parraga-Alava, J. (2018). Decision Trees for Predicting Agricultural Patterns. *IEEE ETCM*.
<https://doi.org/10.1109/ETCM.2018.8580295>
- Cashin, P., Mohaddes, K., & Raissi, M. (2015). *Fair Weather or Foul? The Macroeconomic Effects of El Niño*.
<https://doi.org/10.5089/9781484394021.001>
- Ceccarelli, V., Fremout, T., Chavez, E., Zonneveld, M., & Thomas, E. (2024). Vulnerability to climate change of cultivated and wild cacao in ECUADOR. *Science of The Total Environment*, 908, 167812.
<https://doi.org/10.1016/j.scitotenv.2023.167812>

- CIAT. (2014). *Vulnerabilidad Al Cambio Climático de La Agricultura Andina*. <https://doi.org/10.4060/cc8557> en
- Crane-Droesch, A. (2018). Machine Learning Methods for Crop Yield Prediction and Climate Change Impact Assessment in Agriculture. *Environmental Research Letters*, 13(11), 114010. <https://doi.org/10.1088/1748-9326/aae159>
- Cusme Macias, B. L., & Gaibor, R. (2023). Agricultura Familiar En El Desarrollo Rural de Balzar. *Ciencia Latina Revista Científica Multidisciplinar*, 7(2), 1240–1255. https://doi.org/10.37811/cl_rcm.v7i2.5410
- de la Casa, A., Ovando, G., Bressanini, L., Martínez, J., Díaz, G., & Miranda, C. (2021). Linking Data of ENSO, NDVI-MODIS and Crops Yield. *Remote Sensing Applications: Society and Environment*, 22, 100480. <https://doi.org/10.1016/j.rsase.2021.100480>
- Fan, S., Yosef, S., & Pandya-Lorch, R. (2019). *Reshaping Food Systems: The 2019 Global Food Policy Report*. <https://doi.org/10.2499/9780896293502>
- FAO. (2023). *Impact of ENSO on Global Food Security: A Comprehensive Review*. <https://doi.org/10.4060/cc8557>
- Fernández, P., Villalba, I., & Sánchez, R. (2021). Monitorización de Aparatos de Vía Frente a Eventos Climáticos Extremas. *ResearchGate*.
- Fukuda, S., Spreer, W., Yasunaga, E., Yuge, R., Sardud, V., & Müller, J. (2013). Random Forests Modelling for the Estimation of Mango Fruit Yields. *Agricultural Water Management*, 116, 142–150. <https://doi.org/10.1016/j.agwat.2012.10.012>
- García, M., & Torres, R. (2016). Impactos de la Variabilidad Climática en la Infraestructura Logística Rural de la Costa Ecuatoriana. *Revista Ecuatoriana de Ciencia Social y Desarrollo*, 7(2), 45–58. <https://doi.org/10.1016/j.ecusoc.2016.04.002>
- Gelagay, H. S., Leroux, L., Tamene, L., & Vlek, P. L. G. (2025). A Crop-Specific and Time-Variant Spatial Framework for Characterizing Rainfed Wheat. *Agricultural Systems*, 227, 104128. <https://doi.org/10.1016/j.agsy.2024.104128>
- Godfray, H. C. J., Beddington, J. R., Crute, I. R., Haddad, L., Lawrence, D., Muir, J. F., Pretty, J., Robinson, S., Thomas, S. M., & Toulmin, C. (2010). Food Security: The

- Challenge of Feeding 9 Billion People. *Science*, 327(5967), 812–818.
<https://doi.org/10.1126/science.1185383>
- Grace, D., Lindahl, J., Wanyoike, F., Bett, B., Randolph, T., & Rich, K. M. (2012). Climate Change and Livestock Production: Complex Interactions. *Nature Climate Change*, 2(3), 145–150.
- Hansen, J. W., Hodges, A. W., & Jones, J. W. (1998). ENSO Influences on Agriculture in the Southeastern United States. *Agricultural Systems*, 57(1), 81–94.
[https://doi.org/10.1016/S0308-521X\(98\)00006-2](https://doi.org/10.1016/S0308-521X(98)00006-2)
- INEC. (2024a). *Encuesta Nacional sobre Desnutrición Infantil (ENDI) 2023-2024: Reporte Técnico*.
- INEC. (2024b). *Encuesta Nacional sobre Desnutrición Infantil (ENDI) 2023-2024: Reporte Técnico*.
- Jeong, J. H., Resop, J. P., Mueller, N. D., Fleisher, D. H., Yun, K., Timlin, D. J., Shim, K. M., Gerber, J. S., & Timlin, D. (2016). Random Forests for Global and Regional Crop Yield Predictions. *PLoS ONE*, 11(6), e0156571.
<https://doi.org/10.1371/journal.pone.0156571>
- Khaki, S., & Wang, L. (2019). Crop Yield Prediction Using Deep Neural Networks. *Frontiers in Plant Science*, 10, 621.
<https://doi.org/10.3389/fpls.2019.00621>
- Llorente-Isidro, M., Díez-Herrero, A., & Laín-Huerta, L. (2009). Aplicaciones de Los SIG Al Análisis de Inundaciones. *Cuadernos de La Sociedad Española de Ciencias Forestales*, 29, 115–124.
- Mbow, C., Rosenzweig, C., Barioni, L. G., Benton, T. G., Herrero, M., Krishnapillai, M., Liwenga, E., Pradhan, P., Rivera-Ferre, M. G., Sapkota, T., Tubiello, F. N., & Xu, Y. (2019). *Food Security - IPCC Special Report on Climate Change and Land*.
- MTOP. (2025). *Diagnóstico de la Red Vial Estatal ante Amenazas Naturales 2024-2025*.
- Phalkey, R. K., Aranda-Jan, C., Marx, S., Höser, C., & Sauerborn, R. (2015). Systematic review of current efforts to quantify the impacts of climate change on childhood undernutrition. *The Lancet Global Health*, 3(7), e375–e387.
[https://doi.org/10.1016/S2214-109X\(15\)00009-0](https://doi.org/10.1016/S2214-109X(15)00009-0)
- Podestá, G. P., Messina, C. D., Grondona, M. O., & Magrin, G. O. (1999). Associations Between Grain Crop Yields in Central-Eastern Argentina and ENSO. *Journal of Applied Meteorology*, 38(10), 1488–1498.
[https://doi.org/10.1175/1520-0450\(1999\)038<1488:ABGCYI>2.0.CO;2](https://doi.org/10.1175/1520-0450(1999)038<1488:ABGCYI>2.0.CO;2)

- Preti, F., Forzieri, G., & Chirico, G. B. (2011). Forest Cover Influence on Regional Flood Frequency Assessment in Mediterranean Catchments. *Hydrology and Earth System Sciences*, 15(10), 3077–3090. <https://doi.org/10.5194/hess-15-3077-2011>
- Shukla, P. R., Skea, J., Calvo Buendia, E., Masson-Delmotte, V., Pörtner, H. O., Roberts, D. C., Zhai, P., Slade, R., Connors, S., & van Diemen, R. (2019). *Climate Change and Land: An IPCC Special Report on Climate Change, Desertification, Land Degradation, Sustainable Land Management, Food Security, and Greenhouse Gas Fluxes in Terrestrial Ecosystems*.
- Thielen, D. R., Schuchmann, K.-L., Ramoni-Perazzi, P., Arias, J. I., Quintero, M. E., & Puche, C. (2023a). Effect of extreme El Niño events on the precipitation of Ecuador. *Natural Hazards and Earth System Sciences*, 23(4), 1507–1523. <https://doi.org/10.5194/nhess-23-1507-2023>
- Thielen, D. R., Schuchmann, K.-L., Ramoni-Perazzi, P., Arias, J. I., Quintero, M. E., & Puche, C. (2023b). Effect of extreme El Niño events on the precipitation of ECUADOR. *Natural Hazards and Earth System Sciences*, 23(4), 1507–1523. <https://doi.org/10.5194/nhess-23-1507-2023>
- Tirado, M. C., Crahay, P., Mahy, L., Zanev, C., Thompson, B., Jackson, R., Ngongi, N., Brown, L., Croft, L., Izwardi, D., & Sarmiento, O. (2010). Climate Change and Food Safety: A Review. *Food Research International*, 43(7), 1745–1765. <https://doi.org/10.1016/j.foodres.2010.07.003>
- UNICEF. (2019). *Estado Mundial de La Infancia 2019: Niños, Alimentos y Nutrición*.
- Vicente-Serrano, S. M., Aguilar, E., Martínez, R., Martín-Hernández, N., Azorin-Molina, C., Sánchez-Lorenzo, A., El Kenawy, A., López-Moreno, J. I., Nieto, R., Gimeno, L., & Nieto, R. (2016). The Complex Influence of ENSO on Droughts in ECUADOR. *Climate Dynamics*, 48(1), 405–427. <https://doi.org/10.1007/s00382-016-3082-y>
- Vincenzi, S., Zucchetta, M., Franzoi, P., Torricelli, P., & De Leo, G. A. (2011). Application of a Random Forest Algorithm to Predict Spatial Distribution of Potential Yield. *Ecological Modelling*, 222(8), 1471–1478. <https://doi.org/10.1016/j.ecolmodel.2011.02.007>
- Wheeler, T., & von Braun, J. (2013). Climate Change Impacts on Global Food Security. *Science*, 331(6029), 1209–1212. <https://doi.org/10.1126/science.1239803>

341(6145), 508–513.
<https://doi.org/10.1126/science.1239402>

WHO. (2019a). *Nutrition Landscape Information System Country Indicators*.

WHO. (2019b). *Nutrition Landscape Information System Country Indicators*.

WMO. (2026). *El Niño/La Niña Update (February 2026)*.