

*Asesorías y Tutorías para la Investigación Científica en la Educación Puig-Salabarria S.C.  
José María Pino Suárez 400-2 esq a Lerdo de Tejada. Toluca, Estado de México. 7223898475  
RFC: ATII120618V12*

**Revista Dilemas Contemporáneos: Educación, Política y Valores.**

<http://www.dilemascontemporaneoseducacionpoliticayvalores.com/>

**Año: XIII Número: 2 Artículo no.:71 Período: 1 de enero del 2026 al 30 de abril del 2026**

**TÍTULO:** Estado del arte: algoritmos de Inteligencia Artificial para la medición de indicadores de pobreza.

**AUTOR:**

1. Dr. Vitervo López Caballero.

**RESUMEN:** El propósito de este trabajo es presentar una revisión del estado del arte sobre los algoritmos más empleados en la medición de la pobreza a nivel global, con el fin de identificar enfoques analíticos vigentes y ofrecer estrategias que contribuyan a abordar este problema complejo y dinámico. La revisión realizada evidencia que los algoritmos con mayor presencia en la literatura reciente son las Redes Neuronales Convolucionales (CNN), Random Forest (RF), Gradient Boosting (incluido XGBoost) y las Redes Neuronales no Convolucionales. Las Redes Neuronales Convolucionales sobresalen por su alta efectividad en el procesamiento y extracción de características visuales, mientras que Random Forest y Gradient Boosting destacan por su versatilidad, capacidad predictiva y robustez en contextos diversos.

**PALABRAS CLAVES:** medición de pobreza, algoritmo para la medición de pobreza, aprendizaje automático.

**TITLE:** State of the Art: Artificial Intelligence Algorithms for Measuring Poverty Indicators

**AUTHOR:**

1. PhD. Vitervo López Caballero.

**ABSTRACT:** The purpose of this work is to present a review of the state of the art regarding the most widely used algorithms for measuring poverty globally, in order to identify current analytical approaches and offer strategies that contribute to addressing this complex and dynamic problem. The review reveals that the algorithms most prevalent in recent literature are Convolutional Neural Networks (CNNs), Random

Forest (RF), Gradient Boosting (including XGBoost), and Non-Convolutional Neural Networks. Convolutional Neural Networks stand out for their high effectiveness in processing and extracting visual features, while Random Forest and Gradient Boosting are notable for their versatility, predictive capacity, and robustness in diverse contexts.

**KEY WORDS:** poverty measurement, poverty measurement algorithm, machine learning.

## INTRODUCCIÓN.

La pobreza constituye un desafío estructural que afecta a millones de personas en todo el mundo. En el marco de la Agenda 2030 para el Desarrollo Sostenible, adoptada por los Estados Miembros de la Organización de las Naciones Unidas (ONU) en el año 2015, el Objetivo de Desarrollo Sostenible 1 (ODS 1) establece la meta de “poner fin a la pobreza en todas sus formas y en todo el mundo” (Naciones Unidas, 2023). Este objetivo ambicioso requiere no sólo de políticas efectivas y recursos adecuados, sino también de herramientas innovadoras para medir, analizar y abordar la pobreza de manera precisa y eficiente (Banco Mundial, 2020).

En ese contexto, la inteligencia artificial (IA) ha emergido como una tecnología transformadora con el potencial de revolucionar la forma en que se comprenden y abordan los desafíos sociales. Los algoritmos de IA, en particular, ofrecen nuevas oportunidades para detectar y medir indicadores de pobreza con una precisión y escala sin precedentes (Jean et al., 2023). Estos avances tecnológicos prometen superar limitaciones tradicionales en la recolección de datos sobre pobreza, que a menudo son costosos, lentos y propensos a errores (Yeh et al., 2022).

El presente artículo tiene como objetivo examinar investigaciones recientes sobre el uso de algoritmos de IA en la detección y medición de indicadores de pobreza. Tradicionalmente, la medición de la pobreza ha dependido de censos y encuestas nacionales, métodos que suelen ser costosos y a menudo carecen de actualización. Los algoritmos de IA permiten analizar grandes volúmenes de datos de fuentes no

convencionales, como imágenes satelitales y datos de redes sociales, lo que contribuye a obtener una imagen más precisa y oportuna de la pobreza en diversas regiones (Blumenstock et al., 2021).

La relevancia de esta investigación se fundamenta en la necesidad urgente de herramientas más sofisticadas para abordar la pobreza en un mundo, siendo este un problema cada vez más complejo y dinámico. La pandemia del 2020 así como otros factores han revertido años de progreso en la reducción de la pobreza global, empujando a millones de personas de vuelta a la pobreza extrema (Merfeld & Morduch, 2023). En este escenario, la capacidad de los algoritmos de IA para procesar grandes volúmenes de datos, identificar patrones complejos y generar datos en tiempo real se vuelve crucial para diseñar intervenciones más efectivas y dirigidas (Steele et al., 2020).

## **DESARROLLO.**

### **Método utilizado.**

Para llevar a cabo la revisión del estado del arte, se analizaron exhaustivamente artículos publicados entre los años 2019 y 2024, que emplean algoritmos de inteligencia artificial para la detección y medición de la pobreza. La metodología adoptó un enfoque sistemático, estructurado en tres etapas principales: identificación, selección y análisis de investigaciones relevantes.

Se realizó una búsqueda en bases de datos académicas como son Web of Science, Scopus, IEEE Xplore y arXiv. Las cadenas de búsqueda utilizadas para la selección de estudios relevantes fueron las siguientes: (Poverty measurement and Deep Learning) or Machine Learning, (Deep Learning and Poverty measurement) or Machine Learning, (Machine Learning and Poverty measurement) or Deep Learning, (Poverty measurement and Machine Learning) or Deep Learning. La búsqueda se restringió a artículos publicados entre los años 2019 y 2024 para asegurar la relevancia y actualidad de los hallazgos; por otro lado, sólo se incluyeron estudios que aplicaran específicamente algoritmos de IA para medir o detectar indicadores de pobreza.

## Resultados.

El análisis comparativo de las investigaciones seleccionadas revela patrones significativos en el uso de algoritmos de inteligencia artificial para la detección y medición de indicadores de pobreza. En la Tabla 1, se presenta un resumen detallado de estos estudios, incluyendo los algoritmos utilizados, las fuentes de datos con las que trabajaron, y los indicadores medidos.

Tabla 1. Extracto de artículos seleccionados.

<b>Artículo</b>	<b>Algoritmos Utilizados</b>	<b>Fuentes de datos</b>	<b>Indicadores medidos</b>
Steele et al. (2020)	Random Forest XGBoost.	Datos de telefonía móvil. Imágenes satelitales.	Índice de riqueza.
Jean et al. (2023)	CNN Transfer Learning.	Imágenes satelitales de alta resolución.	Consumo y activos de los hogares.
Blumenstock et al. (2021)	Redes neuronales SVM	Registros detallados de llamadas (CDR).	Índice de bienestar económico.
Ratledge et al. (2022)	Random Forest Gradient Boosting.	Imágenes satelitales nocturnas. Datos estructurados de encuestas.	Impacto en medios de vida por acceso a electricidad.
Xie et al. (2021)	CNN Ridge Regression.	Imágenes satelitales multispectral.	Consumo per cápita.
Piaggesi et al. (2019)	U-Net ResNet	Imágenes satelitales de muy alta resolución	Índice de privación multidimensional.
Steele et al. (2020)	Random Forest Lasso Neural Networks.	Datos estructurados de encuestas. Indicadores geoespaciales.	Pobreza monetaria. Malnutrición infantil.

<b>Artículo</b>	<b>Algoritmos Utilizados</b>	<b>Fuentes de datos</b>	<b>Indicadores medidos</b>
Fatehkia et al. (2020)	BERT Random Forest.	Datos de redes sociales. Estadísticas oficiales	Índice de desarrollo socioeconómico.
Liu et al. (2020)	Regresión lineal multiple. Random Forest.	Datos ambientales. Datos económicos. Datos sociales.	Elevación y pendiente media. Proporción de tierras cultivables. Impacto de desastres naturales. Acceso a servicios. Proporción de la fuerza laboral.
Zhao et al. (2019)	Random Forest Regression (RFR)	Datos de NTL (Nighttime Lights). Imágenes satelitales. Mapas de carreteras. Datos de cobertura del suelo.	Mean NTL, Min NTL, Max NTL PC1-PC25 Proporción de Urbanidad. Road density Distance to roads.
CIEB (2022)	Random Forest XGBoost	Encuesta de Hogares (EH) de la gestión 2021: Persona, vivienda y equipamiento.	Actividad económica. Composición del hogar. Lugar de residencia. Educación. Gastos del hogar. Infraestructura
Niu et al. (2020)	Random Forest (RF) Redes neuronales convolucionales.	Datos de Puntos de Interés (POI). Imágenes de Landsat. Imágenes de luz nocturna. Datos de alquiler de viviendas. Datos censales.	Provisión de instalaciones y servicios. Composición de la cobertura del suelo. Textura de los edificios. Intensidad de la actividad. Costo de la vivienda.

<b>Artículo</b>	<b>Algoritmos Utilizados</b>	<b>Fuentes de datos</b>	<b>Indicadores medidos</b>
Okiabera (2020)	Random Forest.	Encuesta Demográfica y de Salud de Kenia (KDHS) de 2014.	Índice de riqueza. Nivel de educación. Número de miembros del hogar. Tipo de residencia Región.
Ravallion (2020)	Programación lineal (LP). Método simplex.	Precios del ICP (Índice de Precios al Consumidor). Datos de consumo Estudios previos. Datos del World Bank.	Línea de pobreza. Paridad del poder adquisitivo (PPP). Consumo real por persona. Diversidad en la dieta.
Mariati et al. (2019)	Modelo de regresión no paramétrica. Estimador de Fourier. Validación Cruzada Generalizada (GCV). Mínimos Cuadrados Penalizados.	Índice de Desarrollo Humano. Tasa de desempleo.	Índice de Desarrollo Humano (IDH). Tasa de Desempleo Abierto. Tasa de Participación Escolar. Producto Interno Bruto Regional.
Merfeld & Morduch (2023)	Lasso (Least Absolute Shrinkage and Selection Operator).	Datos del “Village Dynamics in South Asia (VDSA)”.	Ingreso mensual (y anual). Gastos mensuales. Tamaño del hogar. Líneas de pobreza rurales. Datos demográficos.
Wu & Tan (2019)	ResNet-50 Feature Pyramid Networks (FPN) Regresión ridge.	Imágenes de Landsat 8. Imágenes de índices espectrales. Datos de luz nocturna. Datos de encuestas económicas.	Producto Interno Bruto per cápita (PCGDP). Ventas minoristas totales de bienes de consumo (TRSCG).

<b>Artículo</b>	<b>Algoritmos Utilizados</b>	<b>Fuentes de datos</b>	<b>Indicadores medidos</b>
			Ingresos del presupuesto financiero público general (GPFBR).
Wu & Tan (2019)	ResNet50 Regresión ridge	Imágenes de Landsat 8. Datos de luz nocturna. Datos de encuestas económicas.	Producto Interno Bruto (PIB). Ventas Minoristas Totales de Bienes de Consumo (TRSCG).
Piaggesi et al. (2019)	ResNet5 VGGF	Imágenes satelitales de DigitalGlobe	Indicadores socioeconómicos
Farooq et al. (2024)	ResNet (Residual Networks) YOLO (YouOnly Look Once) Random Forest Bayes Naïve Classifier	Planet.com Sentinel-2 Google Earth Engine. Métodos de Clustering.	Densidad de áreas construidas. Condición del sistema vial. Cantidad de áreas verdes. Características del uso del suelo. Datos censales y encuestas de hogares.

Derivado del análisis de la Tabla 1, los algoritmos más frecuentes se destacan en la Figura 1, indicando que el RandomForest y las ResNet son de los algoritmos más utilizados en el contexto de la medición de pobreza. Adicional a ello, los resultados del análisis de los estudios seleccionados sugieren que los enfoques más efectivos para la detección y medición de indicadores de pobreza involucran la combinación de múltiples fuentes de datos, el uso de técnicas avanzadas de Deep Learning (especialmente CNN para datos de imágenes), y la aplicación de métodos de ensemble Learning; sin embargo, la elección del algoritmo depende en gran medida de la fuente de datos y de los indicadores de pobreza que se deseen medir.

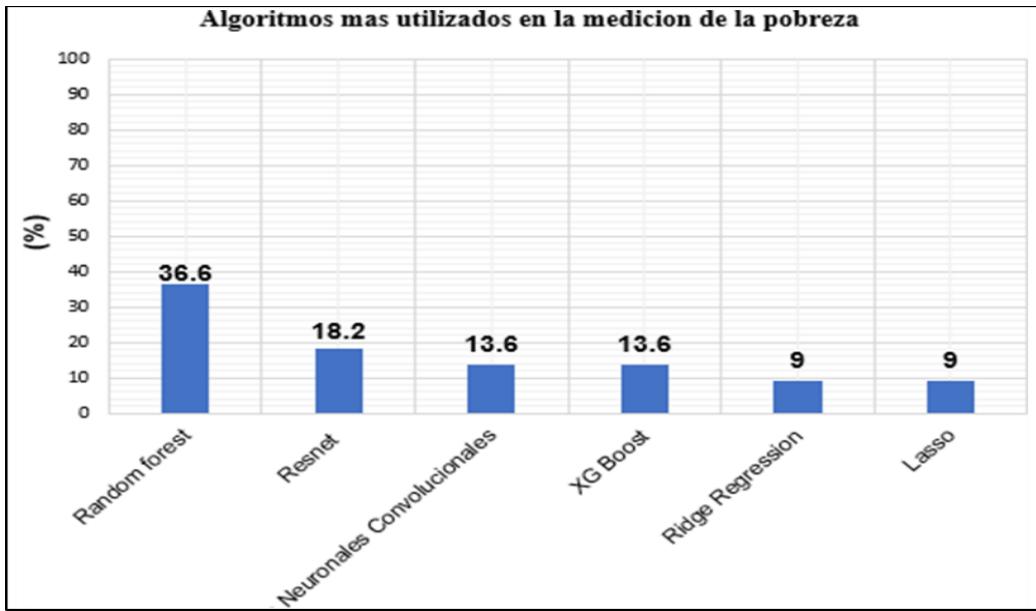


Figura 1. Algoritmos más frecuentes según los estudios seleccionados.

## Discusión.

Los hallazgos descritos en la sección de resultados resaltan el creciente uso de algoritmos de inteligencia artificial para la detección y medición de la pobreza, integrando diversas fuentes de datos no convencionales como imágenes satelitales, datos socioeconómicos, datos de redes sociales, y metadatos de telefonía móvil. Los resultados comparativos sugieren que el uso de redes neuronales convolucionales y técnicas de Deep Learning tienden a ser más efectivos en la predicción de indicadores de pobreza.

La investigación de algoritmos de inteligencia artificial, aplicada a la pobreza, tiene un impacto significativo en la precisión y el tiempo de obtención de resultados en áreas donde los datos tradicionales (como censos o encuestas) no son suficientes (Sohnesen et al., 2023); por ejemplo, las imágenes satelitales han permitido estimar indicadores económicos con un alto grado de exactitud en regiones rurales y remotas, mientras que los datos de redes sociales ofrecen información en tiempo real para áreas urbanas (Li et al., 2022). Estos avances ofrecen una mayor granularidad y frecuencia en la recopilación de datos, lo cual es crucial para diseñar políticas de intervención más específicas.

Los estudios no siempre detallan de manera explícita las limitaciones de los datos, lo cual podría influir en la fiabilidad de los resultados; la dependencia excesiva de imágenes satelitales puede no capturar adecuadamente las dinámicas de pobreza en regiones cubiertas por vegetación densa o áreas urbanas densamente pobladas (Niu et al., 2020).

En ese contexto, se destaca la necesidad de combinar diferentes fuentes de datos para mejorar la precisión y confiabilidad de los modelos de Inteligencia Artificial (Fatehkia et al., 2020). Investigaciones futuras podrían enfocarse en:

a) Estandarización de métricas.

La falta de estándares en las métricas de evaluación hace difícil comparar estudios. Sería útil adoptar un enfoque estandarizado para medir la efectividad y precisión de los modelos, lo que permitiría un análisis más riguroso (Njuguna & McSharry, 2020).

b) Mitigación de sesgos en los datos.

Dado que los datos utilizados para la medición de pobreza pueden estar sesgados, debido al difícil acceso en ciertas áreas, es importante que los estudios futuros aborden estos sesgos a través de la incorporación de datos complementarios o el ajuste en los modelos (Li et al., 2022).

c) Aplicaciones en tiempo real.

El avance en el procesamiento de datos, junto con el acceso a fuentes de información en tiempo real, permite implementar algoritmos de Inteligencia Artificial para monitorear la pobreza de manera más frecuente. Esta capacidad ofrece a los gobiernos la posibilidad de reaccionar más rápidamente ante crisis económicas o desastres naturales que pueden intensificar la pobreza (CIEB, 2022).

d) El uso de algoritmos de Inteligencia Artificial para detectar y medir la pobreza tiene un enorme potencial para cambiar los enfoques tradicionales de análisis económico y social.

Esta investigación indica, que en el futuro será posible diseñar modelos más específicos y efectivos en la lucha contra la pobreza (Mahabir et al., 2023).

## CONCLUSIONES.

El artículo analiza el uso de algoritmos de Aprendizaje Automático, Aprendizaje Profundo y diversas fuentes de datos en el mapeo de la pobreza. En general, se destaca que los modelos más avanzados, como las redes neuronales profundas y el aprendizaje transferido, suelen ofrecer una alta precisión ( $R^2 > 0.85$ ); sin embargo, métodos más simples, como las regresiones lineales, tienden a ser menos efectivos.

Las fuentes de datos también son decisivas; las imágenes satelitales de alta resolución y los datos de telefonía móvil son especialmente útiles para medir aspectos económicos y sociales, mientras que las encuestas y datos ambientales aportan información sobre los factores determinantes de la pobreza; además, los estudios incluyen distintos indicadores, como índices de riqueza y privación multidimensional, sugiriendo un enfoque integral que abarque varios aspectos del bienestar.

A pesar del potencial del uso de la inteligencia artificial para el mapeo preciso de la pobreza, se observa una falta de uniformidad en las métricas de efectividad, dificultando la comparación entre estudios y resaltando la necesidad de estandarizar la evaluación. De este estudio se tiene, que los algoritmos de aprendizaje automático, en combinación con diversas fuentes de datos y enfoques metodológicos, ofrecen un gran potencial en la formulación de políticas, aunque es clave mejorar la transparencia y estandarización en sus métricas de efectividad.

## REFERENCIAS BIBLIOGRÁFICAS.

1. Ayush, K., Uzkent, B., Burke, M., Lobell, D., & Ermon, S. (2021). Generating interpretable poverty maps using object detection in satellite images. In Proceedings of the IEEE/CVF International Conference on Computer Vision (pp. 15072- 15081).
2. Banco Mundial (2020). Poverty and Shared Prosperity 2020: Reversals of Fortune. World Bank Publications.
3. Blumenstock, J., Cadamuro, G., & On, R. (2021). Predicting poverty and wealth from mobile phone metadata. Science, 371(6535), 1073-1077.
4. CIEB (2022). Clasificación de la pobreza en Bolivia, utilizando Random Forest y XGBoost. Cuadernos de Investigación Económica Boliviana, 5(1), 1-25.

5. Fatehkia, M., Tingzon, I., Orden, A., Sy, S., Sekara, V., Garcia-Herranz, M., & Weber, I. (2020). Mapping socioeconomic indicators using social media advertising data. *EPJ Data Science*, 9(1), 1-15.
6. Farooq, H. U., Nazar, M. J., Faisal, A., & Hanif, M. S. (2024). Using Satellite Imagery To Map Poverty Struck Areas of Pakistan Using Neural Networks.
7. Gram-Hansen, B., Helber, P., Varatharajan, I., Azam, F., Coca-Castro, A., Kopackova, V., & Bilbao, P. (2022). Mapping informal settlements in developing countries using machine learning and low resolution multi-spectral data. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 36, No. 11, pp. 12307-12315).
8. Hallegatte, S., Rozenberg, J., & Vogt-Schilb, A. (2018). Climate change and socioeconomic impacts. In The Oxford Handbook of the Economics of Central Banking. Oxford University Press.
9. Head, A., Manguin, M., Tran, N., & Blumenstock, J. E. (2021). Can Human Development Be Measured with Satellite Imagery? In Proceedings of the Ninth International Conference on Learning Representations.
10. Jean, N., Morales, J., Gao, J., Lee, K., & Burke, M. (2023). Bridging the gap: Using deep learning to estimate poverty across countries. *Nature Communications*, 14(1), 1-10.
11. Knippenberg, E., Jensen, N., & Constas, M. (2021). Quantifying household resilience with high frequency data: Temporal dynamics and methodological options. *World Development*, 140, 105369.
12. Li, X., Zhou, Y., Chen, W., & Cai, Y. (2022). Mapping urban poverty using multi-source geospatial big data: A random forest approach. *International Journal of Applied Earth Observation and Geoinformation*, 114, 103027.
13. Liu, M., Hu, S., Ge, Y., Heuvelink, G. B., Ren, Z., & Huang, X. (2020). Using multiple linear regression and random forests to identify spatial poverty determinants in rural China. *Spatial Statistics*, 42, 100461.
14. Mahabir, R., Agouris, P., Stefanidis, A., Croitoru, A., & Crooks, A. T. (2023). Detecting and mapping slums using open data: a case study in Kenya. *International Journal of Digital Earth*, 16(1), 1-27.
15. Mariati, N. P. A. M., Budiantara, I. N., & Ratnasari, V. (2019, December). Modeling poverty percentages in the Papua Islands using Fourier series in nonparametric regression multivariable. In *Journal of Physics: Conference Series* (Vol. 1397, No. 1, p. 012071). IOP Publishing.
16. Merfeld, J. D., & Morduch, J. (2023). Poverty at higher frequency. KDI School of Public Policy & Management Paper No. DP23-03.

17. Naciones Unidas (2023). Sustainable Development Goals Report 2023. United Nations Publications.
18. Njuguna, C., & McSharry, P. (2020). Constructing spatiotemporal poverty indices from big data. *Journal of Business Research*, 131, 606-615.
19. Niu, T., Chen, Y., & Yuan, Y. (2020). Measuring urban poverty using multi-source data and a random forest algorithm: A case study in Guangzhou. *Sustainable Cities and Society*, 54, 102014.
20. Okiabera, J. O. (2020). Using random forest (RF) to identify key determinants of poverty in Kenya (Doctoral dissertation, University of Nairobi).
21. Piaggesi, S., Gauvin, L., Tizzoni, M., Cattuto, C., Adler, N., Verhulst, S., ... & Panisson, A. (2019). Predicting city poverty using satellite imagery. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (pp. 90-96).
22. Ratledge, N., Cadamuro, G., De la Fuente, A., Castillo, M. G., & Foster, V. (2022). Using satellite imagery and machine learning to estimate the livelihood impact of electricity access. *Nature Communications*, 13(1), 1-12.
23. Ravallion, M. (2020). On measuring global poverty. *Annual Review of Economics*, 12(1), 167-188.
24. Steele, J. E., Sundsøy, P. R., Pezzulo, C., Alegana, V. A., Bird, T. J., Blumenstock, J., ... & Bengtsson, L. (2020). Mapping poverty using mobile phone and satellite data. *Journal of The Royal Society Interface*, 14(127), 20160690.
25. Sohnesen, T. P., Ambel, A. A., Fisker, P., Malmgren-Hansen, D., & Asher, S. (2023). Estimating poverty in data-scarce environments: A new approach combining satellite images and machine learning. *World Development*, 161, 106076.
26. Tingzon, I., Orden, A., Go, K., Sy, S., Sekara, V., Weber, I., ... & Fatehkia, M. (2021). Mapping poverty in the Philippines using machine learning, satellite imagery, and crowd-sourced geospatial information. In Proceedings of the International AAAI Conference on Web and Social Media (Vol. 15, pp. 892- 903).
27. Wu, P., & Tan, Y. (2019). Estimation of poverty based on remote sensing image and convolutional neural network.
28. Wu, P., & Tan, Y. (2019, November). Estimation of economic indicators using residual neural network ResNet50. In 2019 International conference on data mining workshops (ICDMW) (pp. 206-209). IEEE.

29. Xie, M., Jean, N., Burke, M., Lobell, D., & Ermon, S. (2021). Transfer learning from deep features for remote sensing and poverty mapping. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 30, No. 1).
30. Yeh, C., Perez, A., Driscoll, A., Azzari, G., Tang, Z., Lobell, D., ... & Burke, M. (2022). Using publicly available satellite imagery and deep learning to understand economic well-being in Africa. *Nature Communications*, 11(1), 1-11.
31. Zhao, X., Yu, B., Liu, Y., Chen, Z., Li, Q., Wang, C., & Wu, J. (2019). Estimation of poverty using random forest regression with multi-source data: A case study in Bangladesh. *Remote Sensing*, 11(4), 375.
32. Zhao, X., Yu, B., Liu, Y., Chen, Z., Li, Q., Wang, C., & Wu, J. (2022). Estimation of poverty in rural areas of the conterminous United States using Landsat imagery and machine learning methods. *Remote Sensing of Environment*, 252, 112159.

#### DATOS DEL AUTOR.

**1. Vitervo López Caballero.** Doctor en Ciencias Computaciones con la especialidad de Ingeniería de Software por el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET). Actualmente se desempeña como profesor-investigador de tiempo completo en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET). Correo electrónico: [vitervo.lc@cenidet.tecnm.mx](mailto:vitervo.lc@cenidet.tecnm.mx) ORCID: <https://orcid.org/0000-0002-1942-9558>

**RECIBIDO:** 26 de octubre del 2025.

**APROBADO:** 21 de noviembre del 2025.