

Artículo Científico

Uso de análisis de datos avanzados para la detección de fraudes financieros

Use of advanced data analytics for financial fraud detection



Casanova-Villalba, César Iván ¹
<https://orcid.org/0000-0001-6840-3891>
cesar.casanova.villalba@utelvt.edu.ec
Universidad Técnica Luis Vargas Torres de
Esmeraldas, Ecuador, Santo Domingo.



Casanova-Villalba, Luis Alberto ²
<https://orcid.org/0009-0009-5229-9378>
luis.alberto.casanova.villalba@utelvt.edu.ec
Universidad Técnica Luis Vargas Torres de
Esmeraldas, Ecuador, Santo Domingo.

Autor de correspondencia ¹



DOI / URL: <https://doi.org/10.55813/gaea/rcym/v2/n3/44>

Resumen: El estudio analiza el uso de técnicas avanzadas de análisis de datos como estrategia central en la detección de fraudes financieros, en un contexto marcado por la creciente complejidad de las transacciones digitales y la sofisticación de los mecanismos ilícitos. Mediante una revisión exploratoria de literatura especializada publicada en bases de datos de alto impacto, se identificaron y compararon métodos de aprendizaje supervisado, no supervisado y enfoques híbridos, evaluando su eficacia, limitaciones y potencial de implementación. Los resultados muestran que los algoritmos supervisados, como las redes neuronales y los bosques aleatorios, ofrecen alta precisión cuando se dispone de datos etiquetados, mientras que las técnicas no supervisadas destacan por su capacidad de identificar fraudes emergentes sin información previa. La investigación concluye que la combinación de ambos enfoques mediante modelos de ensamble constituye una alternativa prometedora, aunque implica desafíos técnicos, operativos y éticos. Se resalta la importancia de articular estas metodologías con infraestructuras robustas y marcos normativos que garanticen transparencia y explicabilidad.

Palabras clave: detección de fraudes; análisis de datos avanzados; aprendizaje automático; transacciones financieras.



Check for updates

Received: 15/Jun/2024
Accepted: 02/Jul/2024
Published: 31/Jul/2024

Cita: Casanova-Villalba, C. I., & Casanova-Villalba, L. A. (2024). Uso de análisis de datos avanzados para la detección de fraudes financieros. *Revista Científica Ciencia Y Método*, 2(3), 1-12. <https://doi.org/10.55813/gaea/rcym/v2/n3/44>

Revista Científica Ciencia y Método (RCyM)
<https://revistacym.com>
revistacym@editorialgrupo-aea.com
info@editorialgrupo-aea.com

© 2024. Este artículo es un documento de acceso abierto distribuido bajo los términos y condiciones de la **Licencia Creative Commons, Atribución-NoComercial 4.0 Internacional**.



Abstract:

The study analyzes the use of advanced data analysis techniques as a central strategy in the detection of financial fraud, in a context marked by the increasing complexity of digital transactions and the sophistication of illicit mechanisms. Through an exploratory review of specialized literature published in high-impact databases, supervised learning methods, unsupervised learning methods and hybrid approaches were identified and compared, evaluating their effectiveness, limitations and implementation potential. The results show that supervised algorithms, such as neural networks and random forests, offer high accuracy when labeled data is available, while unsupervised techniques stand out for their ability to identify emerging frauds without prior information. The research concludes that the combination of both approaches using ensemble models constitutes a promising alternative, although it involves technical, operational and ethical challenges. The importance of articulating these methodologies with robust infrastructures and regulatory frameworks that guarantee transparency and explainability is highlighted.

Keywords: fraud detection; advanced data analytics; machine learning; financial transactions.

1. Introducción

La creciente complejidad de las transacciones financieras y el aumento exponencial de los volúmenes de datos digitales han propiciado que el fraude financiero se consolide como una de las principales amenazas que enfrentan tanto instituciones bancarias como organismos reguladores a nivel mundial. El fraude financiero no solo genera pérdidas económicas significativas, sino que también deteriora la confianza de los inversionistas y del público en general en los sistemas financieros (West & Bhattacharya, 2016). La dificultad inherente a la identificación de patrones fraudulentos se deriva del carácter dinámico y adaptativo de estas prácticas ilícitas, así como de la sofisticación de los mecanismos empleados por los perpetradores, quienes constantemente adoptan tecnologías avanzadas para evadir los controles tradicionales (Ngai et al., 2011). En este contexto, el análisis de datos avanzados se ha convertido en una herramienta esencial para la detección temprana de actividades anómalas que podrían derivar en fraude, permitiendo identificar correlaciones, tendencias y señales que los métodos estadísticos convencionales no son capaces de revelar con la misma precisión (Phua et al., 2010).

Diversos factores contribuyen a la magnitud y persistencia de este problema. Entre los más relevantes se encuentran el volumen y la variedad de datos financieros, que pueden dificultar la distinción entre operaciones legítimas y fraudulentas, y la presencia de datos desbalanceados, dado que los registros fraudulentos suelen representar un porcentaje muy reducido respecto al total de transacciones (Bahnsen

et al., 2016). Asimismo, la alta velocidad con que se procesan los pagos electrónicos exige métodos de análisis que operen en tiempo real, incrementando la complejidad técnica y computacional de los sistemas antifraude (Dal Pozzolo et al., 2018). Otro factor relevante es la evolución constante de los modus operandi de los defraudadores, quienes emplean técnicas de ingeniería social, suplantación de identidad y manipulación de datos para perpetrar sus delitos (Jurgovsky et al., 2018). Esta convergencia de desafíos técnicos y organizacionales ha motivado un interés creciente en la aplicación de algoritmos de aprendizaje automático, minería de datos y técnicas de inteligencia artificial como alternativas innovadoras para fortalecer las capacidades de detección.

La justificación de esta investigación radica en la necesidad de comprender en profundidad el papel que desempeñan los enfoques de análisis de datos avanzados en el contexto de la prevención y detección de fraudes financieros. Mientras que los métodos tradicionales se han centrado principalmente en reglas predefinidas y métricas contables, los enfoques basados en aprendizaje supervisado y no supervisado permiten identificar patrones complejos y dinámicos en grandes volúmenes de datos, superando limitaciones históricas asociadas a la rigidez de los sistemas basados en reglas (Zareapoor & Seeja, 2015). La pertinencia de este tema se refuerza por la disponibilidad creciente de datos transaccionales y la madurez tecnológica de las soluciones de procesamiento masivo de información, lo que hace viable implementar modelos predictivos a escala organizacional (Roy et al., 2018). Además, la integración de técnicas como redes neuronales profundas, máquinas de soporte vectorial y algoritmos de ensamble ha demostrado una alta precisión en la clasificación de eventos fraudulentos, incrementando la capacidad de respuesta de las entidades financieras ante amenazas emergentes (Whitrow et al., 2009).

La viabilidad de la aplicación de estos métodos se fundamenta en dos elementos centrales: el avance de la infraestructura tecnológica, que permite procesar grandes cantidades de datos en tiempos reducidos, y la disponibilidad de marcos normativos que incentivan a las instituciones a fortalecer sus sistemas de monitoreo y control de riesgos (Bolton & Hand, 2002). Esta combinación crea un escenario propicio para la investigación y la implementación de soluciones basadas en análisis de datos avanzados, contribuyendo a una mayor transparencia, seguridad y eficiencia en los procesos financieros. Asimismo, la adopción de estos enfoques puede derivar en beneficios económicos sustantivos al reducir las pérdidas por fraude y optimizar el uso de recursos en la investigación de alertas (Carcillo et al., 2021).

El presente artículo tiene como objetivo principal examinar críticamente la literatura académica existente sobre el uso de técnicas avanzadas de análisis de datos para la detección de fraudes financieros, identificando los principales métodos empleados, sus ventajas comparativas, limitaciones y oportunidades de investigación futura. Al realizar esta revisión bibliográfica, se busca consolidar un marco comprensivo que permita a investigadores y profesionales del sector financiero comprender el estado del arte en este campo, así como valorar la pertinencia de distintas aproximaciones

metodológicas en función de las características de sus entornos operativos. De esta forma, se pretende aportar al conocimiento científico y a la práctica profesional, orientando el desarrollo de estrategias innovadoras que contribuyan de manera efectiva a la mitigación del riesgo de fraude financiero en escenarios cada vez más complejos y dinámicos (Erazo-Luzuriaga, 2023).

2. Materiales y métodos

La metodología empleada en el presente artículo corresponde a un enfoque explorativo de revisión bibliográfica, orientado a recopilar, sistematizar y analizar de manera crítica la producción científica más relevante relacionada con el uso de técnicas avanzadas de análisis de datos para la detección de fraudes financieros. El proceso inició con la definición clara de los criterios de inclusión y exclusión de fuentes, priorizando estudios publicados en revistas académicas indexadas en bases de datos de alto impacto, tales como Scopus y Web of Science, con el propósito de garantizar la calidad, pertinencia y confiabilidad de la información recopilada.

Se realizó una búsqueda exhaustiva de literatura en dichas bases de datos, utilizando combinaciones de términos clave en inglés y español que incluyeron “financial fraud detection”, “advanced data analytics”, “machine learning”, “data mining” y “artificial intelligence”, entre otros. Para delimitar el corpus documental, se seleccionaron trabajos publicados principalmente en los últimos quince años, con la finalidad de reflejar los avances metodológicos más recientes, sin descartar contribuciones seminales que hayan establecido marcos conceptuales o modelos de referencia relevantes.

La recopilación inicial de publicaciones produjo un conjunto amplio de artículos, los cuales fueron sometidos a un proceso de depuración basado en la lectura de títulos, resúmenes y palabras clave, descartando aquellos que no abordaran directamente la aplicación de técnicas analíticas avanzadas en el contexto de fraudes financieros o que presentaran un enfoque exclusivamente técnico sin relación con escenarios de aplicación práctica. Posteriormente, se efectuó una lectura detallada de los textos completos seleccionados, extrayendo información pertinente sobre los enfoques metodológicos empleados, los algoritmos propuestos, los indicadores de desempeño reportados, los desafíos identificados y las recomendaciones formuladas por los autores.

Para organizar y sintetizar la información recopilada, se elaboraron matrices de análisis que permitieron clasificar los artículos según criterios temáticos y metodológicos, identificando patrones recurrentes y vacíos de conocimiento en la literatura revisada. La integración de esta información facilitó la construcción de una perspectiva crítica y comparativa que orienta la discusión de resultados y la identificación de tendencias emergentes en la investigación del campo.

Finalmente, se cuidó que todo el proceso de búsqueda, selección y análisis de fuentes se realizara con rigor académico y transparencia, procurando la trazabilidad de las decisiones metodológicas y el resguardo de la integridad intelectual de los autores consultados. Esta metodología permite ofrecer una visión estructurada y fundamentada del estado actual del conocimiento sobre el uso de análisis de datos avanzados en la detección de fraudes financieros, y proporciona un punto de partida sólido para investigaciones futuras que profundicen en el desarrollo, validación y aplicación de modelos innovadores en este ámbito.

3. Resultados

3.1. Principales enfoques de análisis de datos avanzados en la detección de fraudes financieros

3.1.1. Aplicación de algoritmos de aprendizaje supervisado

La aplicación de algoritmos de aprendizaje supervisado constituye una de las aproximaciones más ampliamente difundidas en la detección de fraudes financieros, debido a su potencial para modelar relaciones complejas entre variables predictoras y etiquetas de clase predefinidas (Almeida-Blacio, 2024). Estos algoritmos utilizan conjuntos de datos históricos etiquetados, en los que se clasifica cada transacción como legítima o fraudulenta. Modelos como las máquinas de soporte vectorial, los árboles de decisión, los bosques aleatorios, las redes neuronales artificiales y los métodos basados en regresión logística han mostrado resultados destacados en términos de precisión y sensibilidad (West & Bhattacharya, 2016). Cada uno de estos modelos presenta ventajas particulares en aspectos como interpretabilidad, capacidad de manejo de datos no estructurados y eficiencia computacional. Por ejemplo, los árboles de decisión y los bosques aleatorios se utilizan frecuentemente por su robustez frente a valores atípicos y su capacidad para manejar atributos mixtos (Bahnsen et al., 2016).

En estudios recientes, las redes neuronales profundas han cobrado relevancia gracias a su eficacia en la detección de patrones no lineales de alta complejidad (Roy et al., 2018). Estas arquitecturas, basadas en capas jerárquicas de procesamiento, permiten modelar interacciones de gran volumen y complejidad que suelen pasar desapercibidas para los clasificadores tradicionales. Además, Dal Pozzolo et al. (2018) destacaron que la calibración de probabilidades combinada con submuestreo de clases mayoritarias mejora notablemente el rendimiento de los modelos supervisados en entornos con alta desproporción de clases. No obstante, uno de los retos recurrentes radica en la necesidad de contar con datos etiquetados de calidad, cuya obtención puede ser costosa y limitar la aplicabilidad de estos enfoques en contextos donde la información disponible es incompleta o sesgada (Whitrow et al., 2009).

3.1.2. Uso de técnicas de aprendizaje no supervisado y detección de anomalías

El uso de técnicas de aprendizaje no supervisado y métodos de detección de anomalías se ha consolidado como una alternativa complementaria y, en muchos casos, imprescindible cuando no se dispone de etiquetas confiables. Estas técnicas parten del supuesto de que las transacciones fraudulentas suelen manifestarse como desviaciones significativas respecto a los patrones de comportamiento normal (Bolton & Hand, 2002). Entre los métodos más representativos se encuentran el clustering (k-means, DBSCAN), la estimación de densidad, los algoritmos de aislamiento de bosques y las máquinas de soporte vectorial de una clase (One-Class SVM).

Carcillo et al. (2021) evidenciaron que estos métodos son eficaces para identificar patrones atípicos asociados a modalidades de fraude emergente, es decir, esquemas no contemplados en los registros históricos. Un atributo distintivo de estos enfoques es su flexibilidad para adaptarse a cambios conceptuales en la naturaleza del fraude, contribuyendo a reducir los riesgos derivados de la dependencia de datos etiquetados (Ngai et al., 2011). En particular, los métodos de aislamiento forestal han mostrado un desempeño competitivo por su capacidad para detectar outliers en entornos de alta dimensionalidad y con datos ruidosos. Sin embargo, su implementación conlleva retos relacionados con la determinación de umbrales de decisión y la calibración de la sensibilidad de los modelos, dado que la ausencia de etiquetas puede conducir a elevadas tasas de falsos positivos si no se acompaña de procesos rigurosos de validación y supervisión humana (Phua et al., 2010).

3.1.3. Integración de enfoques híbridos y modelos de ensamble

La integración de enfoques híbridos y modelos de ensamble se ha posicionado como una de las tendencias más prometedoras en la investigación aplicada a la detección de fraudes financieros. Estos enfoques combinan de manera estratégica los métodos supervisados y no supervisados, aprovechando las fortalezas de ambos paradigmas en esquemas de procesamiento que pueden ser secuenciales, donde la detección preliminar de anomalías antecede a la clasificación supervisada, o paralelos, en los que las transacciones se evalúan de manera simultánea en múltiples modelos (Jurgovsky et al., 2018).

Whitrow et al. (2009) introdujeron un enfoque que integra la agregación de transacciones con aprendizaje supervisado, logrando mejoras sustanciales en la sensibilidad y especificidad de los modelos. De igual forma, los modelos de ensamble, como el bagging, boosting y stacking, combinan las predicciones de varios clasificadores base con el fin de incrementar la estabilidad y reducir la varianza del sistema (West & Bhattacharya, 2016). La literatura especializada señala que la adopción de modelos de ensamble mitiga los sesgos inherentes a los clasificadores individuales y contribuye a una mejor capacidad de generalización en escenarios con alta variabilidad (Bahnsen et al., 2016).

Además, la convergencia de estos enfoques con tecnologías emergentes como el aprendizaje profundo y la computación distribuida en la nube facilita el desarrollo de sistemas de detección en tiempo real, capaces de procesar grandes volúmenes de transacciones con latencia mínima (Roy et al., 2018). Si bien la aplicación de modelos híbridos y de ensamble implica desafíos considerables, como el incremento en la complejidad computacional y la necesidad de infraestructuras robustas, su potencial para elevar los niveles de precisión y resiliencia frente a fraudes sofisticados los convierte en una alternativa estratégica de creciente adopción (Guitérrez-Portela et al., 2019).

4. Discusión

La evidencia analizada en el presente estudio confirma que la evolución de los métodos de análisis de datos avanzados en la detección de fraudes financieros ha seguido un itinerario caracterizado por la creciente sofisticación técnica y la necesidad de responder a entornos cada vez más complejos y dinámicos. El aprendizaje supervisado se ha consolidado como el punto de partida más recurrente en los sistemas antifraude, principalmente por su capacidad para asimilar patrones históricos de transacciones etiquetadas y su potencial para alcanzar métricas de precisión que superan ampliamente los umbrales obtenidos mediante reglas estáticas o auditorías tradicionales (Ngai et al., 2011). Este enfoque, materializado en algoritmos como los árboles de decisión, los bosques aleatorios, las máquinas de soporte vectorial y las redes neuronales profundas, ha permitido incrementar la sensibilidad y especificidad en la identificación de operaciones fraudulentas, como se evidencia en los experimentos reportados por Roy et al. (2018), donde las arquitecturas neuronales profundas alcanzaron niveles de rendimiento superiores a los obtenidos con modelos lineales.

No obstante, la dependencia de datos etiquetados de alta calidad supone una limitación estructural que compromete la sostenibilidad de estos modelos a largo plazo. En contextos reales, la obtención de etiquetas precisas implica costos significativos de supervisión humana y puede verse afectada por errores de clasificación y sesgos cognitivos de los analistas (Whitrow et al., 2009). Asimismo, Dal Pozzolo et al. (2018) demostraron que el desequilibrio de clases es un reto persistente que conduce al sobreajuste del modelo en la clase mayoritaria y a la degradación progresiva de la capacidad predictiva. Este fenómeno, conocido como el problema de la clase minoritaria, requiere la aplicación de estrategias específicas, tales como la calibración de probabilidades y el submuestreo controlado, con el fin de restituir el balance y optimizar los umbrales de decisión. Estas prácticas, aunque eficaces, pueden derivar en la pérdida de información relevante y en la reducción de la capacidad generalizadora del modelo (Bahnsen et al., 2016).

Por otro lado, la revisión corrobora que el aprendizaje no supervisado y los métodos de detección de anomalías representan una respuesta metodológica idónea frente a

la escasez de etiquetas. El principio subyacente en este enfoque radica en la identificación de patrones atípicos que divergen de los comportamientos normales, asumiendo que las transacciones fraudulentas constituyen desviaciones significativas en el espacio de características (Bolton & Hand, 2002). En esta línea, Carcillo et al. (2021) pusieron de manifiesto la eficacia de técnicas como el aislamiento forestal y las máquinas de vectores de soporte de una clase para descubrir fraudes emergentes que no habían sido previamente caracterizados. Esta capacidad para adaptarse a dinámicas nuevas es especialmente pertinente ante la evolución continua de los *modus operandi* de los defraudadores, quienes implementan estrategias de disimulación y manipulación de datos para evadir los sistemas de control (West & Bhattacharya, 2016).

Sin embargo, el aprendizaje no supervisado conlleva desafíos críticos relacionados con la interpretación de las salidas del modelo y la determinación de umbrales que permitan diferenciar con fiabilidad entre una anomalía legítima y un fraude consumado (Ngai et al., 2011). La sensibilidad excesiva puede conducir a un volumen elevado de falsos positivos, lo que incrementa los costos de investigación y puede erosionar la confianza en los sistemas de monitoreo (Phua et al., 2010). Este dilema resalta la necesidad de diseñar procesos de validación rigurosos que combinen la automatización con la supervisión experta, a fin de refinar la calidad de las predicciones y reducir el impacto de alertas incorrectas.

El enfoque híbrido y la integración de modelos de ensamble representan un punto de inflexión metodológico que conjuga lo mejor de ambos paradigmas, articulando la capacidad de aprendizaje supervisado con la flexibilidad adaptativa del no supervisado. La investigación contemporánea evidencia que estos modelos permiten disminuir la varianza y mitigar los sesgos propios de los clasificadores individuales, ofreciendo soluciones más robustas en escenarios de alta incertidumbre y variabilidad (Jurgovsky et al., 2018). Whitrow et al. (2009) proporcionaron evidencia empírica del impacto positivo de la agregación transaccional combinada con aprendizaje supervisado en la mejora de la sensibilidad y la reducción de las tasas de error. Asimismo, los ensambles basados en técnicas de boosting y bagging han demostrado capacidad para elevar métricas como el área bajo la curva ROC y el F1-score, optimizando la eficacia del sistema de detección (West & Bhattacharya, 2016).

Sin embargo, el despliegue de estos modelos exige infraestructuras tecnológicas avanzadas que garanticen la disponibilidad de potencia de cómputo suficiente y una arquitectura de almacenamiento capaz de gestionar grandes volúmenes de datos en tiempo real (Roy et al., 2018). A ello se suman los desafíos relativos a la interpretabilidad, dado que la combinación de múltiples algoritmos opaca la comprensión intuitiva de las decisiones y puede dificultar la trazabilidad exigida por los marcos regulatorios (Ngai et al., 2011). La literatura revisada enfatiza que la explicabilidad de los sistemas de detección es un requisito creciente en el ámbito financiero, en virtud de la necesidad de demostrar la legitimidad y equidad de los procesos decisionales ante auditorías y organismos supervisores.

Un aspecto emergente que adquiere protagonismo en la discusión contemporánea es la convergencia entre estos enfoques analíticos y las capacidades del aprendizaje profundo, las arquitecturas en la nube y los sistemas distribuidos. Esta sinergia tecnológica facilita la creación de sistemas antifraude escalables, con capacidad de procesamiento masivo y latencia mínima, configurando un ecosistema de prevención proactiva que supera las limitaciones de los sistemas reactivos tradicionales (Carcillo et al., 2021). No obstante, este paradigma también genera retos éticos y operativos vinculados a la privacidad de los datos, la protección frente a ataques adversariales y el diseño de políticas de gobernanza que garanticen el uso responsable de la inteligencia artificial (Roy et al., 2018).

La integración de estos hallazgos permite inferir que el futuro de la detección de fraudes financieros no descansa exclusivamente en la sofisticación técnica de los algoritmos, sino en su articulación con prácticas organizacionales maduras y marcos regulatorios que promuevan la transparencia, la auditabilidad y la equidad. La adopción de estrategias híbridas y de ensamble se configura como la vía más prometedora para incrementar la eficacia predictiva y adaptativa de los sistemas antifraude, siempre que se acompañe de inversiones sostenidas en infraestructura tecnológica, formación de talento especializado y desarrollo de protocolos éticos que aseguren la integridad y la protección de los datos procesados (Almeida Blacio, 2024).

En síntesis, la presente revisión bibliográfica evidencia que el progreso en este campo es el resultado de una intersección entre avances algorítmicos, innovación tecnológica y un enfoque estratégico orientado a consolidar entornos financieros más seguros, resilientes y confiables. Este proceso demanda la superación de retos metodológicos persistentes, así como la apertura de líneas de investigación que profundicen en la interpretabilidad, la escalabilidad y la sostenibilidad de las soluciones analíticas aplicadas a la detección de fraudes financieros.

5. Conclusiones

A partir del análisis exhaustivo realizado en este estudio, se puede sostener que la educación ambiental en el nivel secundario constituye un eje fundamental para la consolidación de una ciudadanía crítica, consciente de las implicaciones sociales, éticas y ecológicas de sus decisiones. Las estrategias pedagógicas activas, tales como los proyectos vinculados con problemáticas ambientales locales, las experiencias al aire libre y el uso de recursos digitales interactivos, han demostrado un potencial considerable para estimular la comprensión profunda de los fenómenos ambientales y la adopción de conductas responsables que trasciendan el ámbito escolar.

La evidencia revisada pone de manifiesto que la participación activa de los estudiantes es un factor insoslayable en el proceso educativo, pues propicia no solo la apropiación significativa de los contenidos, sino también la internalización de valores y actitudes

que favorecen el compromiso con la protección del entorno. Esta participación activa permite que el estudiantado experimente un rol protagónico en la identificación de problemas, la toma de decisiones y la implementación de soluciones, consolidando así un sentido de autoeficacia ambiental que resulta esencial para la sostenibilidad de los aprendizajes.

Por otra parte, la formación especializada del profesorado emerge como un requisito esencial para garantizar la pertinencia, coherencia y efectividad de las propuestas educativas. La complejidad de los desafíos ambientales contemporáneos exige docentes que, además de poseer un conocimiento disciplinar riguroso, cuenten con habilidades pedagógicas para diseñar experiencias participativas, contextualizadas y culturalmente sensibles. La capacitación continua y el acceso a redes de intercambio profesional se perfilan, por tanto, como condiciones imprescindibles para el fortalecimiento de la educación ambiental.

Asimismo, la vinculación de los contenidos con la vida cotidiana y el entorno cercano del estudiantado constituye un criterio decisivo de eficacia, al facilitar la comprensión de la relación directa entre las prácticas individuales y los procesos globales de degradación ambiental. Este anclaje en experiencias personales incrementa la motivación intrínseca y contribuye a reducir la percepción de distancia que frecuentemente limita la disposición a actuar. Al contextualizar los aprendizajes, se estimula la reflexión crítica y se promueve la construcción de hábitos sostenibles que pueden consolidarse a largo plazo.

El estudio permite afirmar que la eficacia de la educación ambiental no radica en la implementación aislada de actividades innovadoras, sino en la integración sistemática y planificada de múltiples dimensiones pedagógicas. La combinación de metodologías activas, formación docente especializada y contextualización de los contenidos permite generar entornos educativos en los que el conocimiento, la afectividad y la acción se articulan de manera coherente. Este enfoque integral resulta indispensable para atender la complejidad de los problemas ambientales y fomentar un compromiso genuino con su resolución.

Finalmente, es posible concluir que la consolidación de la educación ambiental como una herramienta transformadora requiere el respaldo de políticas públicas orientadas a la innovación curricular, la dotación de recursos materiales y la promoción de alianzas entre las instituciones educativas, las comunidades locales y los diferentes actores sociales. Solo a través de un compromiso colectivo que trascienda las fronteras de la escuela será posible avanzar en la construcción de sociedades más justas, equitativas y ambientalmente sostenibles. La educación ambiental, en este sentido, no debe concebirse como un complemento marginal del currículo, sino como un componente estratégico que aporte a la formación integral de los estudiantes y a la respuesta colectiva frente a los desafíos que configuran la crisis ecológica contemporánea.

CONFLICTO DE INTERESES

“Los autores declaran no tener ningún conflicto de intereses”.

Referencias Bibliográficas

- Albán-Molina, F. E., Salguero-Salguero, M. M., & Aimacaña-Chancusig, E. F. (2024). Modelo de finanzas personales para el manejo adecuado de ahorros de emprendimientos del GADP de Cotopaxi. *Journal of Economic and Social Science Research*, 4(1), 19–32. <https://doi.org/10.55813/gaea/jessr/v4/n1/83>
- Almeida Blacio, J. H. (2024). El Rol de la Auditoría Forense en la Detección de Fraudes Corporativos. *Revista Científica Zambos*, 3(2), 74-96. <https://doi.org/10.69484/rcz/v3/n2/18>
- Almeida-Blacio, J. H. (2024). Aplicación de Big Data y Técnicas Avanzadas en el Uso de Tecnología dentro de la Auditoría. *Horizon Nexus Journal*, 3(1), 55-68. <https://doi.org/10.70881/hnj/v3/n1/49>
- Almenaba-Guerrero, Y. F., & Herrera-Sánchez, M. J. (2022). Diversidad e Inclusión en el Lugar de Trabajo: Prácticas en Ecuador Liderazgo y Cultura Organizacional. *Revista Científica Zambos*, 1(1), 69-85. <https://doi.org/10.69484/rcz/v1/n1/22>
- Bahnsen, A. C., Aouada, D., Stojanovic, A., & Ottersten, B. (2016). Feature engineering strategies for credit card fraud detection. *Expert Systems with Applications*, 51, 134–142. <https://doi.org/10.1016/j.eswa.2015.12.030>
- Bolton, R. J., & Hand, D. J. (2002). Statistical fraud detection: A review. *Statistical Science*, 17(3), 235–255. <https://doi.org/10.1214/ss/1042727940>
- Caicedo-Aldaz, J. C., Urgiles-Solorzano, A. S., & Moreira-Santamaria, M. J. (2022). Análisis del impacto económico de la reducción de precios del sector cacaoero, La Concordia 2019-2021. *Journal of Economic and Social Science Research*, 2(1), 1–17. <https://doi.org/10.55813/gaea/jessr/v2/n1/43>
- Carcillo, F., Le Borgne, Y.-A., Caelen, O., Bontempi, G., & Sebban, M. (2021). Combining unsupervised and supervised learning in credit card fraud detection. *Information Sciences*, 557, 317–331.
- Dal Pozzolo, A., Caelen, O., Johnson, R. A., & Bontempi, G. (2018). Calibrating probability with undersampling for unbalanced classification. *2015 IEEE Symposium Series on Computational Intelligence*, 159–166. <https://doi.org/10.1109/SSCI.2015.33>
- Erazo-Luzuriaga, A. F. (2023). Uso de la minería de datos para la prevención de fraudes en el sector financiero. *Horizon Nexus Journal*, 1(1), 63-76. <https://doi.org/10.70881/hnj/v1/n1/13>
- Guitérrez-Portela, F., Moreno-Hernández, J., Echeverry, B., & Jaramillo, A. (2019). USO DE LOS SISTEMAS INTELIGENTES PARA LA DETECCIÓN DE FRAUDES FINANCIEROS. *Revista Sinergia*, (6), 6-30. Recuperado a partir de <http://sinergia.colmayor.edu.co/ojs/index.php/Revistasinergia/article/view/83>

- Herrera-Sánchez, M. J., Casanova-Villalba, C. I., & Ruiz-López, S. E. (2023). Adaptación de las normativas de auditoría frente a los avances tecnológicos emergentes. *Revista Científica Ciencia Y Método*, 1(3), 1-15. <https://doi.org/10.55813/gaea/rcym/v1/n3/16>
- Herrera-Sánchez, M. J., Navarrete-Zambrano, C. M., Núñez-Liberio, R. V., & López-Pérez, P. J. (2023). Elementos de un sistema de costeo para la producción de Sacha Inchi. *Journal of Economic and Social Science Research*, 3(1), 1–16. <https://doi.org/10.55813/gaea/jessr/v3/n1/58>
- Hurtado-Guevara, R. F., & Casanova-Villalba, C. I. (2022). La Auditoría Forense como Herramienta para la Detección de Fraudes Financieros en Ecuador. *Revista Científica Zambos*, 1(1), 33-50. <https://doi.org/10.69484/rcz/v1/n1/52>
- Jurgovsky, J., Granitzer, M., Ziegler, K., Calabretto, S., Portier, P.-E., He-Guelton, L., & Caelen, O. (2018). Sequence classification for credit-card fraud detection. *Expert Systems with Applications*, 100, 234–245. <https://doi.org/10.1016/j.eswa.2018.01.037>
- López-Pérez, P. J., Casanova-Villalba, C. I., & Muñoz-Intriago, K. R. . (2022). La Evolución de la Contabilidad Ambiental en Empresas Ecuatorianas. *Revista Científica Zambos*, 1(3), 44-59. <https://doi.org/10.69484/rcz/v1/n3/32>
- Navarrete Zambrano, C. M., & Herrera-Sánchez, M. J. (2023). Impacto de la Contabilidad Ambiental en las Empresas del Sector Minero en Ecuador. *Revista Científica Zambos*, 2(2), 37-49. <https://doi.org/10.69484/rcz/v2/n2/42>
- Ngai, E. W. T., Hu, Y., Wong, Y. H., Chen, Y., & Sun, X. (2011). The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. *Decision Support Systems*, 50(3), 559–569. <https://doi.org/10.1016/j.dss.2010.08.006>
- Phua, C., Lee, V., Smith, K., & Gayler, R. (2010). A comprehensive survey of data mining-based fraud detection research. *arXiv preprint arXiv:1009.6119*. <https://doi.org/10.48550/arXiv.1009.6119>
- Preciado Ramírez, J. D., & Bravo Bravo, I. F. (2021). Keynes y la crisis financiera de 1929, panorama de la Gran Depresión. *Journal of Economic and Social Science Research*, 1(1), 38–48. <https://doi.org/10.55813/gaea/jessr/v1/n1/19>
- Roy, A., Sun, J., Mahoney, W., AlZain, M. A., & Kantardzic, M. (2018). Deep learning detecting fraud in credit card transactions. *Proceedings of the 2018 IEEE International Conference on Big Data*, 1846–1855.
- West, J., & Bhattacharya, M. (2016). Intelligent financial fraud detection: A comprehensive review. *Computers & Security*, 57, 47–66. <https://doi.org/10.1016/j.cose.2015.09.005>
- Whitrow, C., Hand, D. J., Juszczak, P., Weston, D., & Adams, N. M. (2009). Transaction aggregation as a strategy for credit card fraud detection. *Data Mining and Knowledge Discovery*, 18(1), 30–55. <https://doi.org/10.1007/s10618-008-0116-z>