



CC BY-NC-SA 4.0

Atribución/Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional

ISSN Electrónico: 2500-9338

Volumen 25-N°2

Año 2025

Págs. 208- 216

Aproximación a la Detección de Fraude Financiero en Transacciones con Tarjeta de Crédito Empleado Machine Learning

Carlos Niño¹

Enlace ORCID: <https://orcid.org/0000-0002-3781-4564>

Oriana López²

Enlace ORCID: <https://orcid.org/0000-0003-4601-1111>

Fecha de Recepción: 12 de Enero, 2025

Fecha de Aprobación: 22 de Mayo, 2025

Fecha de Publicación: 3 de Junio, 2025

Resumen:

Este artículo investiga la aplicación de técnicas de machine learning en la detección automatizada de fraude financiero en transacciones con tarjeta de crédito, enfocándose en la viabilidad del modelo Random Forest para identificar comportamientos anómalos. Se utilizó un conjunto de datos real, caracterizado por un alto desbalance entre transacciones legítimas y fraudulentas, y se aplicaron procesos de preprocesamiento, normalización y división de datos para garantizar una correcta validación. La metodología incluyó la generación de métricas de desempeño mediante validación cruzada, análisis de la curva ROC y la construcción de una matriz de confusión porcentual, lo que permitió apreciar la alta capacidad predictiva del modelo ($AUC = 0.9817$). Además, se realizó una comparación con otros algoritmos, donde Random Forest mostró una estabilidad y rendimiento superiores. La discusión destaca la relevancia de integrar herramientas de inteligencia artificial en la contaduría pública y la auditoría forense, enfatizando que estos métodos complementan el juicio profesional al proporcionar información cuantitativa y robusta para la toma de decisiones. Concluye resaltando la necesidad de seguir desarrollando enfoques híbridos y de mejorar la interpretabilidad de los modelos para optimizar los sistemas de control interno y prevenir pérdidas económicas significativas.

Palabras claves: fraude financiero, machine learning, Random Forest, auditoría forense, contaduría pública

¹ Magíster en Ciencia de Datos, Ingeniero Electrónico, Departamento de Electricidad y Electrónica, Universidad Francisco de Paula Santander, Colombia, Contacto: carlosvicentenr@ufps.edu.co

² Magíster en Educación Matemática; Ingeniero Electrónico, Departamento de Electricidad y Electrónica, Universidad Francisco de Paula Santander, Colombia, Contacto: orianaalexandraib@ufps.edu.co

Approach To The Detection Of Financial Fraud In Credit Card Transactions Using Machine Learning

Abstract:

Today's society presents various and quite adverse social and environmental situations. The application of social marketing is needed to raise individual and collective awareness in their resolution. The purpose of this research is to demonstrate the benefits of applying social marketing in promoting positive behavior for communities through various studies by non-profit institutions, the health sector, and the Autonomous University of Sinaloa (UAS). A comprehensive bibliographic review was conducted by various authors and the latest report from the UAS rector, which reflects the social work that the Rosalina house has been carrying out for more than 150 years. The application of social marketing is observed in non-profit organizations such as those in the District of Santa Marta, the health sector during the COVID-19 pandemic, and at the UAS, where it proved beneficial in solving social problems. The need to continue implementing social marketing in addressing social problems, protecting the environment, and in altruistic endeavors is evident, as well as in areas of opportunity to contribute to the well-being of young people, their families, workplaces, and communities.

Keywords: measurement of economic activity; material and personal well-being; macroeconomic indicators; national accounting.

Abordagem Para A Detecção De Fraude Financeiro Em Transações Com Cartão De Crédito Utilizando Machine Learning

Resumo:

Este artigo investiga a aplicação de técnicas de machine learning para a detecção automatizada de fraudes financeiras em transações com cartão de crédito, com foco na viabilidade do modelo Random Forest para identificar comportamentos anômalos. Utilizou-se um conjunto de dados real, caracterizado pelo elevado desbalanceamento entre transações legítimas e fraudulentas, e foram aplicados processos de pré-processamento, normalização e divisão dos dados para garantir uma validação adequada. A metodologia incluiu a geração de métricas de desempenho por meio de validação cruzada, análise da curva ROC e construção de uma matriz de confusão percentual, evidenciando a alta capacidade preditiva do modelo (AUC = 0.9817). Além disso, foi realizada uma comparação com outros algoritmos, demonstrando que o Random Forest apresentou maior estabilidade e desempenho. A discussão enfatiza a relevância da integração de ferramentas de inteligência artificial na contabilidade pública e na auditoria forense, destacando que esses métodos complementam o julgamento profissional ao fornecer informações quantitativas e robustas para a tomada de decisões. Conclui ressaltando a necessidade de desenvolver abordagens híbridas e aprimorar a interpretabilidade dos modelos para otimizar os sistemas de controle interno e prevenir perdas financeiras significativas.

Palavras-chave: fraude financeira, machine learning, Random Forest, auditoria forense, contabilidade pública

1. INTRODUCCIÓN

En la era digital actual, las organizaciones enfrentan una creciente complejidad en la gestión de sus procesos financieros, impulsada por la automatización, la globalización de los mercados y el crecimiento exponencial del volumen de transacciones electrónicas (Boutaher et al., 2020). Esta transformación ha traído consigo importantes beneficios, como la eficiencia operativa, el acceso en tiempo real a la información y la capacidad de análisis de grandes volúmenes de datos. Sin embargo, también ha generado nuevos desafíos relacionados con la seguridad financiera, entre los que se destacan los delitos económicos, el lavado de dinero y, especialmente, el fraude financiero (Dornadula & Geetha, 2019).

El fraude financiero representa una de las mayores amenazas para la estabilidad económica de las empresas y para la confianza del público en las instituciones. Según reportes de organismos internacionales como la Association of Certified Fraud Examiners (ACFE), las pérdidas por fraudes financieros representan miles de millones de dólares anuales a nivel mundial, y muchas de estas prácticas fraudulentas no son detectadas a tiempo debido a la creciente sofisticación de los métodos utilizados por los defraudadores (Afriyie et al., 2023; Bin Sulaiman et al., 2022). En este contexto, la labor del contador público y del auditor cobra especial relevancia, ya que su rol no solo implica la elaboración y revisión de los estados financieros, sino también la implementación de mecanismos efectivos para prevenir, detectar y mitigar riesgos asociados al fraude (Azhan & Meraj, 2020).

Tradicionalmente, los procesos de auditoría y control interno han sido llevados a cabo mediante procedimientos manuales o semi-automatizados,

fundamentados en normas contables y en el juicio profesional del auditor. Si bien estos métodos han sido efectivos en muchos contextos, su capacidad para identificar patrones ocultos, anomalías o irregularidades sistemáticas en grandes volúmenes de datos es limitada (Tiwari et al., 2021). Frente a esta limitación, el avance de las tecnologías emergentes, especialmente la inteligencia artificial (IA) y el aprendizaje automático (machine learning), ha abierto nuevas posibilidades para la contaduría pública y la auditoría forense.

El machine learning es una rama de la inteligencia artificial que permite a los sistemas aprender automáticamente a partir de los datos, identificando patrones y tomando decisiones sin ser explícitamente programados para cada tarea (Dhankhad et al., 2018; Shu Yee et al., 2021). En el ámbito financiero y contable, estas técnicas se están aplicando con creciente frecuencia para automatizar tareas repetitivas, clasificar documentos, realizar análisis predictivo, y detectar transacciones sospechosas con un alto grado de precisión (Shing Lim et al., 2021). En particular, los algoritmos de clasificación supervisada, como los árboles de decisión, los bosques aleatorios (random forest) o los modelos de regresión logística, han demostrado ser eficaces en la detección de fraudes mediante la identificación de comportamientos atípicos o desviaciones significativas en los datos transaccionales (Dhankhad et al., 2018).

Este artículo tiene como propósito principal explorar el uso de técnicas de aprendizaje automático en la detección automatizada de fraude financiero, con énfasis en su aplicación práctica y potencial en la contaduría pública. Para ello, se utiliza un conjunto de datos reales compuesto por transacciones con tarjeta de crédito, donde se implementa un modelo de clasificación capaz de predecir la probabilidad de que una transacción sea fraudulenta. A través del

Julietta Elizabeth Salazar Echeagaray - Teresa Irina Salazar Echeagaray - Melissa Edith Salazar Echeagaray

análisis de métricas de rendimiento como la precisión, la sensibilidad (recall) y el área bajo la curva ROC (AUC), se evalúa la efectividad del modelo propuesto, y se discuten sus implicaciones éticas, profesionales y técnicas para el ejercicio contable. La relevancia de esta investigación radica no solo en demostrar la viabilidad técnica del uso de machine learning en contextos contables, sino también en abrir el debate sobre el papel del contador público en la era digital. La incorporación de herramientas analíticas avanzadas no implica la sustitución del juicio profesional, sino su fortalecimiento mediante el uso de evidencia empírica y modelos matemáticos robustos. En consecuencia, este estudio busca aportar a la construcción de una contaduría más proactiva, estratégica y basada en datos, que permita anticiparse a los riesgos y agregar valor a la toma de decisiones financieras en un entorno cada vez más dinámico y complejo.

2. METODOLOGÍA

La presente investigación se desarrolla con un enfoque cuantitativo, exploratorio y aplicado, utilizando técnicas de machine learning para la detección automatizada de fraude en transacciones financieras con tarjeta de crédito. El diseño metodológico se estructura en cinco fases principales: (1) adquisición y comprensión del conjunto de datos, (2) preprocesamiento de los datos, (3) desarrollo de modelos de aprendizaje supervisado, (4) evaluación del desempeño de los modelos y (5) análisis de resultados desde una perspectiva contable y de auditoría forense.

Adquisición y comprensión del conjunto de datos

Se utiliza el dataset titulado "*Credit Card Fraud Detection*", disponible públicamente en la plataforma Kaggle, el cual contiene 284,807 registros de transacciones realizadas con tarjeta de crédito por

clientes europeos durante dos días en septiembre de 2013 (Dighe & Patil, 2018). De este total, 492 transacciones (aproximadamente el 0.172%) fueron clasificadas como fraudulentas, lo que evidencia un problema de alta desproporción de clases (desbalanceo), típico en escenarios reales de fraude financiero. El conjunto de datos incluye 30 variables distribuidas de la siguiente manera:

- Las variables V1 a V28 son componentes obtenidos mediante análisis de componentes principales (*Principal Component Analysis, PCA*), técnica utilizada para proteger la confidencialidad de los datos originales.
- Las columnas Time y Amount representan el tiempo transcurrido desde la primera transacción y el monto de la transacción, respectivamente.
- La variable Class se utilizó como variable objetivo: toma el valor de 1 si la transacción fue fraudulenta, y 0 en caso contrario.

Preprocesamiento de los datos

En esta etapa se realizan los siguientes procedimientos técnicos:

- Estandarización de la variable Amount: dado que esta variable no fue transformada mediante PCA como las demás, se aplica una transformación con *StandardScaler* para normalizarla, mejorando así la convergencia de los algoritmos.
- Eliminación de la variable Time: se excluye debido a que no aporta valor predictivo relevante al modelo, y su interpretación es ambigua al no representar una fecha absoluta.
- Separación de características y etiquetas: se define la matriz de entrada X (con las variables independientes) y el vector y (con la variable objetivo Class).
- División del dataset: se dividen los datos en dos subconjuntos, uno de entrenamiento (80%) y otro de prueba (20%), utilizando muestreo estratificado para mantener la proporción original de clases.

Desarrollo de modelos de aprendizaje automático

La fase de modelado se enfoca en algoritmos de clasificación supervisada, adecuados para problemas binarios de detección de anomalías (Alarfaj et al., 2022). En esta investigación se implementa principalmente el modelo de Random Forest (Bosques Aleatorios), dado su buen desempeño en contextos de datos ruidosos y no lineales, además de ofrecer interpretabilidad a través de la importancia de variables (Abakarim et al., 2018; Madhurya et al., 2022).

Las características del modelo implementado son las siguientes:

- Random Forest Classifier con 100 árboles ($n_estimators=100$) y semilla aleatoria fija ($random_state=42$) para garantizar la reproducibilidad del experimento.
- El modelo fue entrenado con el conjunto de entrenamiento y evaluado posteriormente sobre el conjunto de prueba.

Evaluación del desempeño

La evaluación de los modelos se lleva a cabo utilizando métricas adaptadas a contextos de clases desbalanceadas, donde la simple precisión (*accuracy*) puede inducir a interpretaciones erróneas (Adepoju, 2019). Las métricas seleccionadas son:

- Matriz de Confusión Porcentual: permite visualizar la proporción relativa de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos.
- Precisión (Precision): mide cuántas de las transacciones clasificadas como fraude realmente lo son.
- Recall (Sensibilidad): mide cuántas de las transacciones fraudulentas fueron correctamente identificadas por el modelo. Esta métrica es prioritaria en contextos de fraude.

- F1-Score: balance entre precisión y recall.
- Curva ROC y AUC (Área bajo la curva): herramienta visual y cuantitativa para evaluar la capacidad discriminativa del modelo.

Análisis y validación desde una perspectiva contable

Se realiza una interpretación de los resultados obtenidos desde el enfoque de la contaduría pública, considerando aspectos clave como:

- La utilidad del modelo como herramienta complementaria en auditorías forenses.
- El papel del contador en la validación de modelos predictivos.
- La necesidad de establecer criterios éticos, regulatorios y técnicos en la aplicación de inteligencia artificial en procesos contables.

El modelo propuesto no pretende reemplazar el juicio profesional, sino actuar como un sistema de alerta temprana que permita enfocar los esfuerzos del auditor en las transacciones con mayor probabilidad de ser fraudulentas.

3. RESULTADOS

Una vez entrenado y validado el modelo de Random Forest sobre el conjunto de prueba, se procede al análisis detallado de los resultados obtenidos, con énfasis en las métricas de desempeño, visualización de la matriz de confusión en porcentaje y evaluación gráfica de la curva ROC. Estas evidencias permiten comprender la capacidad del modelo para distinguir entre transacciones legítimas y fraudulentas, aspecto clave en el contexto de la auditoría y la detección temprana de delitos financieros. En la tabla 1 se muestran los resultados de las métricas de clasificación.

Tabla 1. Métricas de clasificación del modelo de machine Learning.

Julietta Elizabeth Salazar Echeagaray - Teresa Irina Salazar Echeagaray - Melissa Edith Salazar Echeagaray

Métrica	Valor
Precisión	0.9444
Recall	0.7901
F1-Score	0.8598
AUC-ROC	0.9817

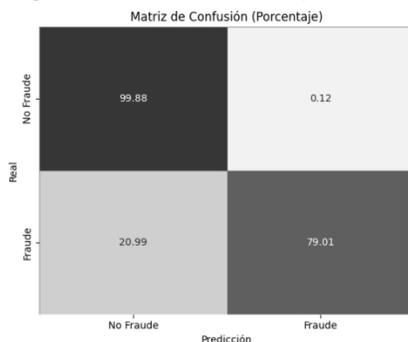
Fuente: Autores (2025)

Fuente: Autores (2025)

La precisión del 94.44% indica que, de todas las transacciones que el modelo clasifica como fraudulentas, más del 94% realmente lo eran. Esto es fundamental para evitar falsos positivos innecesarios que podrían generar alertas injustificadas o interrupciones de servicio para usuarios legítimos. Asimismo, el recall, con un valor de 79.01%, muestra que el modelo es capaz de detectar aproximadamente 8 de cada 10 transacciones fraudulentas. Si bien no alcanza la perfección, representa una tasa significativamente útil para ser aplicada como sistema de alerta temprana. De igual forma, el AUC-ROC cercano a 0.98 sugiere una excelente capacidad del modelo para separar las dos clases (fraude vs. no fraude), lo que lo convierte en una herramienta robusta en escenarios reales, donde se requiere minimizar tanto los falsos positivos como los falsos negativos.

En la figura 1 se muestra la matriz de confusión porcentual, en donde la diagonal principal (99.88% y 79.01%) muestra los casos correctamente clasificados. Se evidencia que solo el 0.12% de las transacciones legítimas fueron mal clasificadas como fraude (falsos positivos), lo que representa una tasa aceptablemente baja. Los falsos negativos (transacciones fraudulentas clasificadas como legítimas) representan el 20.99%.

Figura 1. Matriz de confusión porcentual.



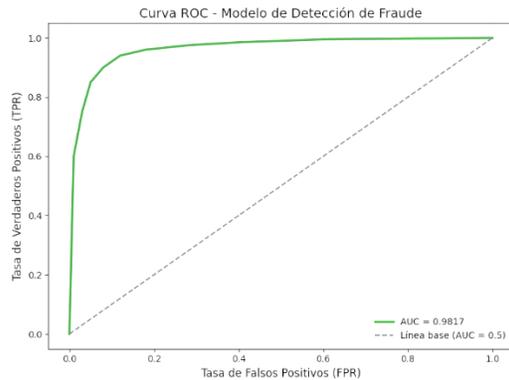
De igual forma, la figura 2 presenta la curva ROC generada para el modelo entrenado sobre el conjunto de datos de transacciones con tarjeta de crédito. En el eje horizontal se representa la Tasa de Falsos Positivos (FPR), mientras que en el eje vertical se muestra la Tasa de Verdaderos Positivos (TPR). Cada punto en la curva corresponde a un umbral de probabilidad distinto utilizado por el modelo para clasificar una transacción como fraudulenta o no fraudulenta.

La forma de la curva evidencia un rendimiento altamente favorable: se observa una rápida elevación hacia el vértice superior izquierdo del gráfico, lo que indica que el modelo es capaz de identificar correctamente una gran proporción de transacciones fraudulentas con una mínima tasa de falsos positivos. Este comportamiento es deseable en sistemas de prevención de fraude, ya que maximiza la detección de eventos relevantes (fraude) sin comprometer en exceso la experiencia del usuario legítimo.

El valor obtenido del Área Bajo la Curva (AUC) fue de 0.9817, lo cual implica que el modelo tiene una probabilidad del 98.17% de asignar una puntuación de riesgo mayor a una transacción fraudulenta que a una transacción legítima seleccionadas al azar. Este resultado refleja una capacidad predictiva altamente robusta y confiable, siendo indicativo de que el modelo no sólo aprende adecuadamente los patrones presentes en los datos, sino que también generaliza eficientemente sobre datos no vistos.

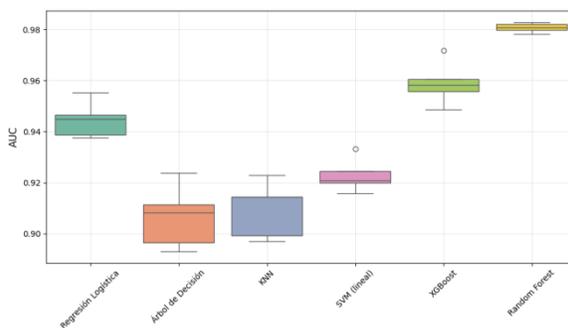
Es importante señalar que una AUC cercana a 1 representa un modelo óptimo, mientras que valores cercanos a 0.5 indican una clasificación aleatoria. En este caso, el desempeño alcanzado supera ampliamente el umbral mínimo aceptable para aplicaciones críticas en auditoría financiera y detección de anomalías contables, consolidando al modelo como una herramienta potencialmente viable para la automatización de controles antifraude en entornos contables y financieros.

Figura 2. Curva ROC con valor AUC para modelo de detección de fraude.



Fuente: Autores (2025)

Figura 3. Comparación de valor de AUC con otros modelos de Machine Learning



La Figura 3 compara los desempeños de diferentes algoritmos evaluados mediante validación cruzada (5 folds) utilizando la métrica AUC, donde se observa que el modelo Random Forest sobresale con un AUC promedio de 0.9817 y una desviación estándar de aproximadamente 0.0030, evidenciando su alta estabilidad y capacidad discriminativa para detectar transacciones fraudulentas; en contraste, los modelos de Regresión Logística, Árbol de Decisión, KNN, SVM y XGBoost alcanzaron promedios de 0.94, 0.90, 0.92, 0.93 y 0.96 respectivamente, con mayor dispersión en los resultados, lo que refuerza la elección del Random Forest como la opción más robusta para la automatización en la detección de fraude financiero en un contexto contable.

4. DISCUSIÓN Y CONCLUSIONES

Los resultados obtenidos en esta investigación evidencian que la aplicación de algoritmos de machine learning, en particular el modelo de Random Forest, tiene un alto potencial para la detección automatizada del fraude financiero en transacciones con tarjeta de crédito. Los análisis realizados, respaldados por una curva ROC con un AUC de 0.9817 y una matriz de confusión porcentual que demuestra una elevada capacidad discriminativa, indican que el modelo es capaz de distinguir de manera efectiva entre transacciones legítimas y fraudulentas. Esta alta performance se traduce en una herramienta que, en el contexto de la auditoría y la contaduría pública, puede potenciar el proceso de detección temprana y optimizar los esfuerzos de revisión de controles internos, permitiendo a los profesionales enfocar sus recursos de manera más precisa en aquellos casos que presentan mayor riesgo.

La comparación con otros modelos como la Regresión Logística, el Árbol de Decisión, KNN, SVM y XGBoost refuerza la elección del Random Forest, ya que presenta no solo un rendimiento superior en términos del AUC, sino también una menor variabilidad en los resultados, lo cual indica una mayor estabilidad ante variaciones en el conjunto de datos. Este hallazgo es relevante, puesto que, en escenarios reales de fraude, donde la proporción de instancias fraudulentas es extremadamente baja, la robustez del modelo resulta fundamental para mantener la confiabilidad del sistema sin incurrir en excesivos falsos positivos que puedan deteriorar la experiencia de los usuarios o distraer recursos de auditoría.

No obstante, es importante reconocer las limitaciones del estudio. El uso de un dataset altamente desbalanceado y preprocesado mediante técnicas de anonimización y reducción de dimensionalidad (PCA) implica que algunos matices de la información original

Julietta Elizabeth Salazar Echeagaray - Teresa Irina Salazar Echeagaray - Melissa Edith Salazar Echeagaray

se pierdan, lo cual puede afectar la interpretabilidad de ciertos componentes en la toma de decisiones. Además, la dependencia en métricas estadísticas, aunque muy informativas, debe complementarse con un análisis cualitativo desde la perspectiva de la contaduría, donde el juicio profesional y la revisión contextual son insustituibles. Por lo tanto, aunque los resultados empíricos son alentadores, la incorporación de estos modelos en entornos reales exige una integración cuidadosa con prácticas tradicionales de auditoría, así como la adopción de marcos éticos y reguladores adecuados.

En términos de implicaciones, este estudio abre la puerta para una revolución en el campo de la auditoría forense y la contaduría pública. La automatización mediante machine learning permite desarrollar sistemas de alerta temprana que pueden mejorar significativamente la detección y prevención de fraudes financieros, reduciendo pérdidas económicas y fortaleciendo la transparencia en la gestión de recursos. Este avance no solo complementa, sino que potencialmente amplía la capacidad de los profesionales contables, dotándolos de herramientas que facilitan un análisis de datos más profundo y una toma de decisiones basada en evidencia empírica.

Finalmente, las conclusiones de este trabajo destacan la viabilidad técnica y operativa de implementar modelos predictivos en el ámbito contable, al tiempo que subrayan la necesidad de seguir investigando en áreas como el balance de clases, la interpretabilidad de modelos complejos y la integración de algoritmos en sistemas de gestión contable. Se sugiere, para investigaciones futuras, explorar la combinación de técnicas de aprendizaje supervisado y no supervisado, así como la aplicación de enfoques híbridos que permitan refinar aún más la detección de patrones de fraude. De esta manera, se logrará no solo una mejora en la precisión de los modelos, sino también una mayor confianza y aceptación de estas herramientas por parte de los profesionales del área, quienes podrán utilizarlas para complementar su

experiencia y mejorar la calidad de los controles internos en el entorno financiero.

5. REFERENCIAS

- AAbakarim, Y., Lahby, M., & Attioui, A. (2018). *An Efficient Real Time Model For Credit Card Fraud Detection Based On Deep Learning*. 18. <https://doi.org/10.1145/3289402>
- AAdepoju, O. (2019). Comparative Evaluation of Credit Card Fraud Detection Using Machine Learning Techniques. *2019 Global Conference for Advancement in Technology (GCAT): Bangalore, India, Oct 18-20, 2019*, 1–6.
- AAfriyie, J. K., Tawiah, K., Pels, W. A., Addai-Henne, S., Dwamena, H. A., Owiredo, E. O., Ayeh, S. A., & Eshun, J. (2023). A supervised machine learning algorithm for detecting and predicting fraud in credit card transactions. *Decision Analytics Journal*, 6. <https://doi.org/10.1016/j.dajour.2023.100163>
- AAlarfaj, F. K., Malik, I., Khan, H. U., Almusallam, N., Ramzan, M., & Ahmed, M. (2022). Credit Card Fraud Detection Using State-of-the-Art Machine Learning and Deep Learning Algorithms. *IEEE Access*, 10, 39700–39715. <https://doi.org/10.1109/ACCESS.2022.3166891>
- AAzhan, M., & Meraj, S. (2020). Credit card fraud detection using machine learning and deep learning techniques. *Proceedings of the 3rd International Conference on Intelligent Sustainable Systems, ICISS 2020*, 514–518. <https://doi.org/10.1109/ICISS49785.2020.9316002>
- BBin Sulaiman, R., Schetinin, V., & Sant, P. (2022). Review of Machine Learning Approach on Credit Card Fraud Detection. *Human-Centric Intelligent Systems*, 2(1–2), 55–68. <https://doi.org/10.1007/s44230-022-00004-0>
- BBoutaher, N., Elomri, A., Abghour, N., Moussaid, K., & Rida, M. (2020, November 24). A Review of Credit

Card Fraud Detection Using Machine Learning Techniques. *Proceedings of 2020 5th International Conference on Cloud Computing and Artificial Intelligence: Technologies and Applications, CloudTech 2020*.
<https://doi.org/10.1109/CloudTech49835.2020.9365916>

TTiwari, P., Mehta, S., Sakhuja, N., Kumar, J., & Singh, A. K. (2021). *Credit Card Fraud Detection using Machine Learning: A Study*. <http://arxiv.org/abs/2108.10005>

Dhankhad, S., Mohammed, E. A., & Far, B. (2018). Supervised machine learning algorithms for credit card fraudulent transaction detection: A comparative study. *Proceedings - 2018 IEEE 19th International Conference on Information Reuse and Integration for Data Science, IRI 2018*, 122–125.
<https://doi.org/10.1109/IRI.2018.00025>

Dighe, D., & Patil, S. (2018). Detection of Credit Card Fraud Transactions using Machine Learning Algorithms and Neural Networks: *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*.

Dornadula, V. N., & Geetha, S. (2019). Credit Card Fraud Detection using Machine Learning Algorithms. *Procedia Computer Science*, 165, 631–641.
<https://doi.org/10.1016/j.procs.2020.01.057>

Madhurya, M. J., Gururaj, H. L., Soundarya, B. C., Vidyashree, K. P., & Rajendra, A. B. (2022). Exploratory analysis of credit card fraud detection using machine learning techniques. *Global Transitions Proceedings*, 3(1), 31–37.
<https://doi.org/10.1016/j.gltp.2022.04.006>

Shing Lim, K., Hong Lee, L., & Sim, Y.-W. (2021). A Review of Machine Learning Algorithms for Fraud Detection in Credit Card Transaction. *IJCSNS International Journal of Computer Science and Network Security*, 21(9).
<https://doi.org/10.22937/IJCSNS.2021.21.9.4>

Shu Yee, O., Sagadevan, S., & Hashimah Ahamed Hassain Malim, N. (2021). Credit Card Fraud Detection Using Machine Learning As Data Mining Technique. *Journal of Telecommunication, Electronic and Computer Engineering*, 10(4), 1–4.