Ciencia y Educación
(L-ISSN: 2790-8402 E-ISSN: 2707-3378)
Vol. 7 No. 12.1
Edición Especial XII 2026

# MODELO HÍBRIDO DE APRENDIZAJE AUTOMÁTICO Y REGLAS PARA PRIORIZAR RIESGOS EN EL SECTOR AUTOMOTRIZ ECUATORIANO

# HYBRID MACHINE LEARNING AND RULE BASED MODEL FOR RISK PRIORITIZATION IN THE ECUADORIAN AUTOMOTIVE SECTOR

**Autores: [1]José Andrés Zúñiga Cazorla, [2]María Verónica Argudo Sumba y [3]Natalia Elizabeth Tubón Castillo.**
[1]ORCID ID: https://orcid.org/0009-0006-5350-2866
[2]ORCID ID: https://orcid.org/0009-0003-6374-244X
[3]ORCID ID: https://orcid.org/0009-0005-7564-0402
[1]E-mail de contacto: andres.zuniga@unach.edu.ec
[2]E-mail de contacto: maria.argudo@unach.edu.ec
[3]E-mail de contacto: natalia.tubon@unach.edu.ec
Afiliación: [1*2*3*]Universidad Nacional de Chimborazo, (Ecuador).
Artículo recibido: 20 de Octubre del 2026.
Artículo revisado: 22 de Noviembre del 2026.
Artículo aprobado: 22 de Noviembre del 2026.
[1]Ingeniero Mecánico, graduado de la Universidad San Francisco de Quito, (Ecuador). Magíster en Inteligencia Artificial, graduado de la Universidad Internacional de Valencia, (España). Magíster en Mecatrónica y Robótica, graduado de la Escuela Politécnica Nacional (Ecuador).
[2]Ingeniera en Contabilidad y Auditoría, graduada de la Universidad Politécnica Salesiana, (Ecuador).
[3]Estudiante de la carrera de Ciencia de Datos e Inteligencia Artificial, de la Universidad Nacional de Chimborazo, (Ecuador).

## Resumen

La revisión de operaciones comerciales exige relacionar la información económica del cliente con las condiciones de compra y las señales que requieren atención. Este estudio tuvo como objetivo desarrollar y evaluar una metodología híbrida de priorización de riesgos para el sector automotriz ecuatoriano. Se realizó una investigación aplicada, cuantitativa y retrospectiva con datos anonimizados. De 31.280 registros iniciales, se conservaron 30.056 tras excluir valores superiores al percentil 99 en cinco variables financieras. La metodología combinó una matriz de seis factores ponderados con perfiles obtenidos mediante agrupamiento y reglas que establecen puntajes mínimos ante señales críticas. Se identificaron tres perfiles, con un coeficiente de silueta de 0,186 y un índice de estabilidad de 0,983 entre dos inicializaciones. Para aproximar el riesgo base de la matriz, se compararon un predictor de mediana, una regresión regularizada y un modelo de árboles potenciados por gradiente, con separación cronológica de los datos. La matriz asignó 132 registros al nivel alto y 1.038 al muy alto. En los 4.669 registros de prueba, la combinación del predictor y las reglas alcanzó una exactitud del 87,13 % y una concordancia ordinal de 0,934. Estos resultados muestran que la propuesta permite organizar prioridades de revisión y reproducir la clasificación de referencia. La evaluación aporta evidencia de consistencia con la matriz construida; su utilidad para detectar operaciones sospechosas y reducir falsos positivos deberá comprobarse mediante validación independiente con resultados de cumplimiento.

**Palabras clave: Lavado de activos, Aprendizaje automático, Matriz de riesgo, Sector automotriz, Datos anonimizados.**

## Abstract

Reviewing commercial operations requires relating customers' financial information to purchase conditions and signals that warrant further attention. This study aimed to develop and evaluate a hybrid methodology for risk prioritization in the Ecuadorian automotive sector. An applied, quantitative, retrospective study was conducted using anonymized data. Of 31,280 initial records, 30,056 were retained after excluding values above the ninety-ninth percentile in five financial variables. The methodology combined a matrix of six weighted factors with profiles obtained through clustering

and rules that impose minimum scores when critical signals are present. Three profiles were identified, with a silhouette coefficient of 0.186 and a stability index of 0.983 between two initializations. To approximate the matrix's base risk score, a median predictor, regularized regression, and a gradient boosted tree model were compared using chronological data partitions. The matrix assigned 132 records to the high-risk level and 1,038 to the very high-risk level. On the 4,669 test records, the combined predictor and rules achieved 87.13 percent accuracy and ordinal agreement of 0.934. These results indicate that the proposed methodology can organize review priorities and reproduce the reference classification. The evaluation provides evidence of consistency with the constructed matrix; its usefulness for detecting suspicious operations and reducing false positives must be established through independent validation using compliance outcomes.

**Keywords: Money laundering, Machine learning, Risk matrix, Automotive sector, Anonymized data.**

**Sumário**

A revisão de operações comerciais exige relacionar as informações econômicas do cliente às condições de compra e aos sinais que requerem atenção. Este estudo teve como objetivo desenvolver e avaliar uma metodologia híbrida de priorização de riscos para o setor automotivo equatoriano. Realizou-se uma pesquisa aplicada, quantitativa e retrospectiva com dados anonimizados. Dos 31.280 registros iniciais, foram mantidos 30.056 após a exclusão de valores superiores ao percentil 99 em cinco variáveis financeiras. A metodologia combinou uma matriz de seis fatores ponderados com perfis obtidos por agrupamento e regras que estabelecem pontuações mínimas diante de sinais críticos. Foram identificados três perfis, com coeficiente de silhueta de 0,186 e índice de estabilidade de 0,983 entre duas inicializações. Para aproximar o risco base da matriz, compararam-se um preditor de mediana, uma regressão regularizada e um modelo de árvores impulsionadas por gradiente, com separação cronológica dos dados. A matriz atribuiu 132 registros ao nível alto e 1.038 ao muito alto. Nos 4.669 registros de teste, a combinação do preditor com as regras alcançou exatidão de 87,13 % e concordância ordinal de 0,934. Esses resultados mostram que a proposta permite organizar prioridades de revisão e reproduzir a classificação de referência. A avaliação fornece evidências de consistência com a matriz construída; sua utilidade para detectar operações suspeitas e reduzir falsos positivos deverá ser comprovada por validação independente com resultados de conformidade.

**Palavras-chave: Lavagem de ativos, Aprendizado de máquina, Matriz de risco, Setor automotivo, Dados anonimizados.**

## Introducción

En la comercialización de vehículos, la revisión del riesgo de lavado de activos requiere examinar la relación entre la capacidad económica declarada por el cliente, el valor del bien y las condiciones de compra. Esta tarea se vuelve compleja cuando los formularios reúnen información financiera heterogénea y señales que tienen significados distintos para el análisis de cumplimiento. Organizar esa información de manera consistente puede ayudar a decidir qué expedientes revisar primero y a explicar los motivos de la prioridad asignada.

Esta necesidad se relaciona con el enfoque basado en riesgo, que propone aplicar medidas de prevención proporcionales a la exposición identificada y conservar información suficiente para conocer al cliente (Financial Action Task Force, 2025). En Ecuador, la Resolución UAFE-DG-2023-0554 estableció disposiciones para los sujetos obligados que comercializan vehículos, incluidos sistemas de prevención con ese enfoque (Unidad de Análisis Financiero y Económico, 2023). Tales disposiciones ofrecen el marco del estudio. Los pesos y umbrales de la propuesta, sin

embargo, corresponden a decisiones de diseño cuya pertinencia debe evaluarse en el contexto de uso. El aprendizaje automático ofrece diversas formas de analizar este tipo de información. La revisión de Hilal et al. (2022) describe técnicas de detección de anomalías y avances en aprendizaje semisupervisado y no supervisado aplicados al fraude financiero. Hernández et al. (2024), al examinar 104 artículos, encontraron una amplia variedad de aplicaciones y una participación limitada de países latinoamericanos. Esta diversidad permite reconocer alternativas metodológicas, pero también exige precisar qué datos utiliza cada modelo y qué resultado pretende estimar. Como muestra la revisión de Ashtiani y Raahemi (2022), centrada en estados financieros, el contexto de aplicación es necesario para interpretar los hallazgos.

En los estudios sobre lavado de activos, la disponibilidad de resultados de investigación condiciona especialmente la evaluación. Jullum et al. (2020) analizaron el papel de las transacciones investigadas y no reportadas en el entrenamiento de modelos, mientras que Jensen e Iosifidis (2023) complementaron la evaluación de alarmas bancarias con revisión experta. En ambos trabajos, las decisiones de investigación o reporte permitieron vincular las predicciones con el proceso de cumplimiento. Cuando una base comercial carece de esa información, el alcance de la evaluación es distinto. La simulación y la transferencia de aprendizaje exploradas por Wang et al. (2025) ofrecen alternativas ante la escasez de datos, aunque la validación en el entorno donde se utilizará la herramienta sigue siendo necesaria. Además de evaluar las predicciones, es necesario comprender cómo se obtiene la prioridad asignada a un expediente. Weber et al. (2024) distinguen entre modelos transparentes y técnicas que explican sus resultados después del entrenamiento; Kute et al. (2024) incorporan explicaciones a un modelo de aprendizaje profundo para transacciones relacionadas con lavado de activos. Esta distinción es pertinente cuando se combinan reglas y aprendizaje automático, pues conocer los pesos de una matriz permite reconstruir su cálculo, pero no explica por completo el comportamiento del predictor que intenta reproducirla.

La interpretación también debe considerar la naturaleza de cada señal. Akartuna et al. (2025) documentan la heterogeneidad de las tipologías y alertas presentes en informes de inteligencia financiera. Una desviación estadística o una coincidencia en una lista puede justificar una revisión, aunque su significado depende de la información adicional disponible. Por ello, una metodología de priorización debe conservar la diferencia entre la señal que activa la revisión y la conclusión alcanzada después de investigar el expediente.

Sobre esta base, el estudio aborda la siguiente pregunta: ¿en qué medida la combinación de perfiles económicos, factores ponderados y reglas críticas permite organizar la revisión de registros comerciales y reproducir su clasificación mediante aprendizaje automático? El objetivo fue desarrollar y evaluar PerceptIA como una metodología de priorización de riesgos para datos anonimizados del sector automotriz ecuatoriano. La propuesta integra una matriz de referencia y un predictor evaluado con registros de un período posterior. Su aporte consiste en documentar esa construcción y determinar cuánto coincide el sistema híbrido con la clasificación definida, dentro de un contexto que todavía carece de resultados independientes de cumplimiento.

## Materiales y métodos

Se realizó una investigación aplicada, de enfoque cuantitativo y diseño observacional retrospectivo, a partir de formularios comerciales de personas naturales de una entidad del sector automotriz ecuatoriano. La unidad de análisis fue cada registro, identificado mediante un código. La base conservada abarcó el período comprendido entre el 4 de enero de 2025 y el 2 de marzo de 2026. Se incluyeron todos los registros disponibles que cumplieron los criterios de depuración, sin muestreo probabilístico. Aunque cada código era único, esta condición no permite asegurar que todos los formularios correspondan a personas diferentes.

La entidad autorizó el uso académico de la información. Antes del análisis se retiraron los identificadores directos, entre ellos nombres, documentos de identidad, identificaciones de vehículos y nombres de terceros, y se sustituyeron por códigos. Para preservar la confidencialidad, el manuscrito presenta resultados agregados y omite el nombre y la marca comercial de la entidad. El procedimiento documentado contempla una clave de correspondencia separada del conjunto analítico; por tanto, la sustitución reversible corresponde técnicamente a seudonimización. Esa clave no se utilizó en el análisis ni se incluye en el manuscrito.

La preparación partió de 31.280 registros y conservó 28 variables después de retirar identificadores y atributos redundantes. Se completaron ocho edades faltantes con el valor de 42 años consignado en el manifiesto de depuración. En el grupo de estudiantes, se ajustaron 27 ingresos al límite de 1.820 dólares, obtenido a partir del tercer cuartil más 1,5 veces el rango intercuartílico y una salvaguarda basada en el percentil 90 del grupo. Este ajuste se aplicó como criterio de preparación de los datos y no como comprobación del ingreso real de cada persona. A continuación, se excluyeron los registros que superaban el percentil 99 en al menos una de cinco variables financieras. Los límites fueron 508.183 dólares para activos, 20.000 para pasivos, 13.000 para ingresos, 1.226,05 para gastos y 47.999 para el valor del vehículo. La edad no intervino en esta exclusión. El procedimiento retiró 1.224 registros únicos, equivalentes al 3,91 % de la base inicial, y dejó 30.056 para el análisis (Tabla 1). Esta delimitación debe tenerse presente al interpretar los resultados, porque los valores extremos también pueden contener información relevante para la revisión de cumplimiento.

***Tabla 1.*** *Trazabilidad de la base analítica.*

| Etapa | Registros |
|---|---|
| Base inicial | 31.280 |
| Ingresos de estudiantes ajustados | 27 |
| Exclusiones por percentil 99 | 1.224 |
| Base final | 30.056 |

Fuente: Elaboración propia.

El desarrollo comenzó con una exploración de anomalías que utilizó seis variables numéricas, siete binarias y tres categóricas. Las variables numéricas se estandarizaron y las categóricas se representaron mediante indicadores. Se evaluó *K-Means* con dos a ocho grupos, semilla 42 y diez inicializaciones; el coeficiente de silueta se calculó sobre una muestra de hasta 8.000 registros (Rousseeuw, 1987). Dentro de cada grupo se aplicaron *Isolation Forest* con 200 árboles y contaminación de 0,05, *Local Outlier Factor* con 20 vecinos y contaminación de 0,05, y *One-Class Support Vector Machine* con núcleo radial, parámetro nu de 0,05 y gamma ajustada a escala. Cuando un grupo superaba las 5.000 observaciones, este último modelo se ajustaba sobre una submuestra de ese tamaño. Para examinar el acuerdo entre detectores se contaron los registros señalados por al menos dos métodos

y los señalados por los tres. Esta exploración sirvió como antecedente del desarrollo posterior. Sus resultados se presentan por separado, ya que los grupos y votos obtenidos no se emplearon como entradas del predictor final ni como etiquetas de lavado de activos. La matriz integral utilizó la segmentación específica que se describe a continuación. La segmentación de la matriz buscó comparar registros con características económicas semejantes. Para ello se combinaron ingreso anual, activos, valor y tipo de vehículo, actividad económica y dos razones: valor del vehículo respecto del ingreso anual y respecto de los activos. El ingreso anual se calculó multiplicando por doce el ingreso mensual registrado.

Las razones se limitaron al percentil 99 antes de aplicar la transformación logarítmica $\log(1 + x)$. Después se utilizó escalamiento robusto y se acotaron las coordenadas numéricas al intervalo de $-5$ a 5. Los pesos fueron 1,25 para ingresos y activos, 1,00 para el valor del vehículo, 1,50 para cada razón y 0,75 para el puntaje de actividad. Los indicadores categóricos de actividad y tipo de vehículo recibieron pesos de 1,10 y 0,30, respectivamente. Estas ponderaciones fueron decisiones de diseño, sin calibración con resultados observados de cumplimiento.

La forma de pago, el canal y la intervención de terceros se reservaron para otros componentes de la matriz. Se ajustó *K-Means* con tres grupos, semilla 42, diez inicializaciones y un máximo de 400 iteraciones. Los centros se estimaron con los registros que tenían información económica y categórica completa; los restantes recibieron una asignación de grupo y el puntaje máximo por información faltante. La elección se examinó frente a soluciones de cuatro a ocho grupos mediante la silueta de una muestra de 10.000 registros. También se compararon las particiones obtenidas con semillas 42 y 99 mediante el índice de Rand ajustado (Hubert y Arabie, 1985). Esta versión no evaluó la solución de dos grupos.Una vez formados los grupos, se calculó la distancia de cada registro a su centro y su posición percentil dentro del segmento. Las posiciones hasta 0,80, 0,90, 0,95 y 0,99 recibieron, respectivamente, puntajes de 1, 2, 3 y 4; las superiores a 0,99 recibieron 5. Así, el componente refleja cuánto se aparta un registro de otros con un perfil semejante. Los nombres de los perfiles se establecieron a partir de las medianas de ingresos y las razones patrimoniales, como descripciones del grupo y no como estimaciones individuales de probabilidad de lavado.

El perfil transaccional se incorporó a una matriz de seis componentes, todos expresados en una escala de 1 a 5. El riesgo directo reunió información sobre exposición política, coincidencias en listas del cliente o sus vínculos, intervención de terceros, nacionalidad homologada y datos faltantes. La actividad económica y la geografía se valoraron mediante los catálogos de la implementación.

Para el componente geográfico se consideraron residencia, agencia y distancia entre centroides cantonales, con un tratamiento específico para Galápagos. Estos catálogos permitieron asignar puntajes de manera uniforme, aunque su capacidad para distinguir casos relevantes no se contrastó con resultados de investigaciones. Los dos componentes restantes fueron la forma de pago y el canal. El crédito recibió un puntaje de 1, mientras que las compras al contado recibieron 2, 3 o 4 según el perfil y su desviación; se asignó 5 cuando faltaba información crítica o no era posible homologarla. La categoría «contado» describe la condición comercial y no identifica

necesariamente un pago con efectivo físico. El canal se valoró mediante un catálogo de origen comercial que asignaba puntajes mayores a determinados canales remotos y a registros no homologados. La Tabla 2 recoge la ponderación de los seis componentes.

***Tabla 2.*** *Componentes del riesgo base.*

| Componente | Peso |
|---|---|
| Riesgo directo | 25 % |
| Perfil transaccional | 25 % |
| Actividad económica | 20 % |
| Geografía | 15 % |
| Forma de pago contextual | 10 % |
| Canal | 5 % |

Fuente: Elaboración propia.

La suma ponderada produjo el riesgo base, definido en la ecuación (1). Sobre ese resultado se aplicó un puntaje mínimo, denominado piso crítico, para impedir que una señal prioritaria quedara compensada por valores bajos en otros componentes. Se fijaron pisos de 3,5 por vínculo con personas expuestas políticamente, 4 por intervención de terceros y 5 por coincidencias en listas o información crítica faltante. En ausencia de estas señales, el piso fue 1. Cuando concurrían varias, se utilizó el mayor valor. El riesgo final correspondió al máximo entre el riesgo base y el piso, según la ecuación (2). La aplicación de un piso establece prioridad de revisión; la verificación de la señal sigue siendo necesaria.

El riesgo final se redondeó a dos decimales y se clasificó en cinco niveles: Bajo, hasta 1,80; Medio bajo, por encima de 1,80 y hasta 2,60; Medio, por encima de 2,60 y hasta 3,40; Alto, por encima de 3,40 y hasta 4,20; y Muy alto, por encima de 4,20. A estos niveles se asociaron acciones que van desde la debida diligencia estándar hasta el escalamiento al equipo de cumplimiento. Tanto los cortes como los pesos y pisos constituyen criterios iniciales susceptibles de recalibración. El puntaje expresa una prioridad dentro de la metodología y no una probabilidad calibrada. Una vez definida la matriz, se entrenó un predictor para aproximar su riesgo base antes de aplicar los pisos. Se utilizaron dieciocho entradas: once categóricas relacionadas con actividad, residencia, agencia, forma de pago, tipo de vehículo, canal, empresa codificada, país homologado y condición de sujeto obligado; y siete numéricas correspondientes a valor, ingresos, activos, distancia entre residencia y agencia, dos razones de capacidad económica y exención geográfica. Se excluyeron los puntajes derivados, niveles, grupos, percentiles, acciones y reglas dominantes. Las señales de exposición política, listas, terceros y datos faltantes se reservaron para la aplicación posterior de las reglas.

La evaluación se organizó por fechas distintas: el 70 % inicial determinó el corte de entrenamiento y el 85 % el de validación. De este modo, se obtuvieron 20.732 registros de entrenamiento hasta el 22 de octubre de 2025, 4.655 de validación entre el 23 de octubre y el 26 de diciembre de 2025, y 4.669 de prueba posteriores. Como los cortes se definieron sobre fechas, esos porcentajes no equivalen exactamente a la proporción de registros de cada partición.

Las transformaciones del predictor se ajustaron con los datos de entrenamiento correspondientes. La matriz de referencia y los perfiles, en cambio, se habían construido con la base completa, circunstancia que delimita el alcance temporal de la evaluación. Se compararon tres alternativas: un predictor constante basado en la mediana, una regresión Ridge con regularización de 10 y un modelo HistGradientBoostingRegressor. Este último utilizó una tasa de aprendizaje de 0,05, un máximo de 250 iteraciones, 31 hojas, un mínimo de 50 observaciones por hoja, regularización de 1 y semilla 42. La potenciación de árboles sigue el

marco de Friedman (2001) y se implementó con scikit-learn (Pedregosa et al., 2011). Para el modelo de árboles, las categorías faltantes se completaron con la moda y los valores numéricos con la mediana; la codificación ordinal agrupó categorías infrecuentes y limitó su número a 250. La regresión Ridge utilizó indicadores categóricos y estandarización numérica. El modelo se eligió por el menor error absoluto medio en validación. Luego se volvió a ajustar con entrenamiento y validación reunidos y se evaluó sobre la partición de prueba.

La predicción del riesgo base se acotó entre 1 y 5 y se combinó con el piso crítico mediante la ecuación (3), obteniendo el resultado híbrido. Para evaluar la aproximación numérica se calcularon error absoluto medio, raíz del error cuadrático medio y coeficiente de determinación. La clasificación se examinó mediante exactitud, exactitud balanceada, F1 macro, kappa con ponderación cuadrática y sensibilidad por nivel. Todas estas medidas se calcularon respecto de la matriz propuesta, que actuó como referencia metodológica.

La revisión de resultados se apoyó en los manifiestos de depuración, catálogos, asignaciones de perfiles, componentes de riesgo y predicciones de prueba conservados en la implementación. Se comprobaron los conteos agregados y se recalcularon las métricas de clasificación a partir de las predicciones almacenadas. Esta verificación permitió examinar la consistencia interna de los valores presentados. Para repetir el entrenamiento completo será necesario conservar también las versiones del entorno original y los insumos utilizados en cada etapa, pues la lista de dependencias por sí sola no documenta todo ese entorno.

## Resultados y discusión

La exploración inicial favoreció la solución de dos grupos, que obtuvo la mayor silueta del rango evaluado, con 0,21565. *Isolation Forest* señaló 1.502 registros, *Local Outlier Factor* señaló 1.503 y *One-Class Support Vector Machine* señaló 1.627. El acuerdo de al menos dos detectores reunió 842 registros, equivalentes al 2,80 % de la base, mientras que los tres coincidieron en 101, equivalentes al 0,34 %. Estos conteos deben leerse teniendo en cuenta que los dos primeros métodos utilizaron una contaminación fijada en 5 %. El consenso redujo el conjunto de registros señalados, aunque sin resultados de revisión no es posible determinar cuánto de esa reducción corresponde a falsos positivos.

La segmentación específica de la matriz integral produjo tres perfiles con 12.307, 8.250 y 9.499 registros. Como muestra la Tabla 3, el primero presentó las medianas más altas de ingreso anual y activos, con 30.000 y 60.000 dólares. El segundo registró medianas de 12.000 y 20.000 dólares, y el tercero de 18.000 y 5.000 dólares, respectivamente. Esta distribución muestra diferencias en la relación entre ingresos y patrimonio que aportan contexto a la valoración del vehículo. Las cifras resumen cada grupo; las razones calculadas para registros individuales no pueden recuperarse dividiendo directamente esas medianas.

La solución de tres grupos alcanzó una silueta de 0,186034, frente a valores de 0,145441 a 0,179311 en las soluciones de cuatro a ocho grupos. El índice de Rand ajustado entre las dos inicializaciones fue de 0,983421. Los tamaños de los grupos oscilaron entre el 27,45 % y el 40,95 % de la base. En conjunto, estos resultados indican que la partición fue estable bajo las dos

semillas evaluadas, aunque hubo solapamiento entre perfiles. Esa separación moderada aconseja utilizar los grupos como referencias de comparación económica, evitando tratarlos como categorías nítidas de personas.

***Tabla 3.*** *Perfiles de la matriz integral.*

| Indicador | Perfil 1 | Perfil 2 | Perfil 3 |
|---|---|---|---|
| Registros | 12.307 | 8.250 | 9.499 |
| Porcentaje | 40,95 | 27,45 | 31,60 |
| Ingreso anual mediano | 30.000 | 12.000 | 18.000 |
| Activos medianos | 60.000 | 20.000 | 5.000 |
| Vehículo mediano | 21.599 | 21.999 | 16.499 |

Fuente: Elaboración propia.

Al integrar los perfiles con los demás componentes y las reglas, la matriz asignó 14.820 registros al nivel Bajo, 12.593 al Medio bajo, 1.473 al Medio, 132 al Alto y 1.038 al Muy alto. La distribución se presenta en la Tabla 4. Los dos niveles superiores reunieron 1.170 registros, equivalentes al 3,89 % de la base depurada, que constituyen el grupo de mayor prioridad según los criterios adoptados. Su clasificación orienta la revisión del expediente y no establece que la operación tenga un origen ilícito.

***Tabla 4.*** *Distribución del riesgo integral.*

| Nivel | Registros | Porcentaje |
|---|---|---|
| Bajo | 14.820 | 49,31 |
| Medio bajo | 12.593 | 41,90 |
| Medio | 1.473 | 4,90 |
| Alto | 132 | 0,44 |
| Muy alto | 1.038 | 3,45 |
| Total | 30.056 | 100,00 |

Fuente: Elaboración propia.

La geografía fue la razón dominante en 20.935 registros, seguida de la actividad económica en 4.816 y del perfil transaccional en 3.083. Entre las reglas críticas, prevalecieron las coincidencias en listas en 1.026 registros, la exposición política en 80, la intervención de terceros en 17 y los datos críticos faltantes en 12. Cada registro recibió una sola razón dominante de acuerdo con la precedencia de las reglas, por lo que estos conteos no representan todas las señales presentes. La frecuencia del componente geográfico destaca la necesidad de revisar su catálogo y ponderación antes de utilizar la matriz en un proceso operativo. *HistGradientBoosting* obtuvo el menor error absoluto medio en validación, con 0,1014, frente a 0,1817 de *Ridge* y 0,3132 del predictor de mediana. En prueba, el error absoluto medio fue de 0,1178, la raíz del error cuadrático medio de 0,2464 y el coeficiente de determinación de 0,6695 (Tabla 5). La reducción relativa del error absoluto medio respecto del predictor constante fue del 62,90 %. El modelo de árboles logró, por tanto, una aproximación más cercana al puntaje de la matriz que los comparadores evaluados.

***Tabla 5.*** *Error absoluto medio por modelo.*

| Modelo | Validación | Prueba |
|---|---|---|
| Mediana | 0,3132 | 0,3175 |
| Ridge | 0,1817 | 0,1888 |
| HistGradientBoosting | 0,1014 | 0,1178 |

Fuente: Elaboración propia.

Al transformar la predicción del riesgo base en niveles, el modelo de árboles alcanzó una exactitud del 81,30 % y un *F1 macro* de 0,4607. La incorporación de los pisos críticos elevó la exactitud del sistema híbrido al 87,13 %, con exactitud balanceada del 88,71 %, *F1 macro* de 0,8912 y kappa cuadrática de 0,9339. La diferencia entre ambas evaluaciones muestra que una parte sustancial de la concordancia final proviene de las reglas. Por ello, el resultado conjunto debe interpretarse considerando tanto el predictor como el mecanismo que impone los puntajes mínimos.

La Tabla 6 permite examinar ese resultado por nivel en los 4.669 registros de prueba. De los 22 registros de nivel Alto, 19 fueron clasificados correctamente. En Muy alto se clasificaron correctamente los 267 registros, todos sujetos a un piso de 5. El 100 % de sensibilidad de esta categoría se explica así por una regla compartida

entre el sistema y su referencia, y no permite inferir sensibilidad perfecta ante casos de lavado de activos. La Figura 1 muestra cómo se distribuyeron los desacuerdos entre los demás niveles.

***Tabla 6.*** *Sensibilidad del sistema híbrido en prueba.*

| Nivel | Registros | Sensibilidad |
|---|---|---|
| Bajo | 2.353 | 78,37 % |
| Medio bajo | 1.845 | 96,96 % |
| Medio | 182 | 81,87 % |
| Alto | 22 | 86,36 % |
| Muy alto | 267 | 100,00 % |

Fuente: Elaboración propia.

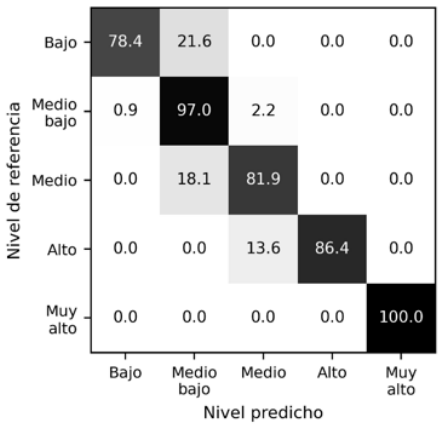



***Figura 1.*** *Matriz de confusión normalizada por nivel de referencia.*

Fuente: Elaboración propia.

En total hubo 601 desacuerdos: 509 registros de nivel Bajo se clasificaron como Medio bajo; 16 de Medio bajo, como Bajo; 40 de Medio bajo, como Medio; 33 de Medio, como Medio bajo; y tres de Alto, como Medio. Todos correspondieron a categorías contiguas. La proximidad de estos errores a los cortes de clasificación sugiere revisar el comportamiento de los expedientes cercanos a cada umbral antes de utilizar las predicciones para asignar acciones de cumplimiento. Los resultados muestran que es posible organizar la información comercial mediante seis componentes cuyo aporte al puntaje puede reconstruirse y aproximar después ese puntaje con un modelo predictivo. La valoración contextual del pago al contado ilustra el propósito de la propuesta: su prioridad depende de la capacidad económica y del perfil, además de la condición de pago registrada. Los grupos aportan ese contexto de comparación, mientras que las reglas mantienen la prioridad de señales que requieren una revisión específica.

El alcance de esta evaluación difiere del de Jullum et al. (2020) y Jensen e Iosifidis (2023), que utilizaron información de investigación o revisión experta vinculada al proceso antilavado. En PerceptIA, la referencia se construyó con la misma información comercial de origen. En consecuencia, la exactitud expresa cuánto reproduce el sistema los criterios de la matriz. Esta diferencia impide comparar el valor obtenido como una tasa de detección de delitos o utilizarlo para afirmar una reducción de falsos positivos frente a sistemas tradicionales.

La separación entre matriz, predictor y reglas también permite precisar qué parte del resultado puede explicarse directamente. Es posible identificar el componente que aporta al puntaje y la señal que establece un piso, pero la interpretación individual del modelo de árboles requiere un análisis adicional. La revisión de Weber et al. (2024) y la aplicación de Kute et al. (2024) ofrecen referencias para desarrollar ese análisis. Su utilidad deberá evaluarse con los equipos de cumplimiento, observando si las explicaciones facilitan la revisión y se comprenden de manera consistente. Dentro de la literatura revisada, la aplicación a registros del sector automotriz ecuatoriano aporta un caso de estudio con procedimientos de preparación y

evaluación documentados. Este contexto resulta pertinente ante la participación latinoamericana limitada que describen Hernandez et al. (2024). La contribución reside en la integración metodológica y su examen en una base comercial concreta. Su traslado a otras entidades requiere revisar la correspondencia entre variables, catálogos y prácticas de revisión, así como comprobar la pertinencia de los pesos y umbrales.

La principal limitación es la ausencia de resultados independientes de revisión, investigación o reporte que permitan evaluar la utilidad de las prioridades asignadas. Por ello, el estudio no estimó la precisión para identificar operaciones sospechosas, la tasa de falsos positivos, las omisiones de casos relevantes ni el tiempo ahorrado en auditoría. Una validación posterior deberá incluir expedientes priorizados y una muestra de los no priorizados. Esta cobertura es necesaria para detectar posibles omisiones y evitar que la evaluación se limite a las alertas emitidas por el propio sistema.

Las decisiones de depuración también condicionan los hallazgos. La exclusión del 3,91 % de los registros y el ajuste de ingresos de estudiantes pueden modificar patrones relevantes para cumplimiento. Conviene comparar alternativas que conserven los valores extremos, como la transformación logarítmica o el escalamiento robusto, y establecer una revisión separada de los registros excluidos. A ello se añade que la información financiera fue declarada y puede contener errores de captura o de unidad. La existencia de códigos únicos tampoco descarta varios formularios de una misma persona. La separación cronológica se aplicó al entrenamiento y la prueba del predictor, pero los perfiles, la depuración, los percentiles y las etiquetas se habían construido sobre la base completa. Así, la evaluación mide la reproducción de una referencia fijada retrospectivamente en registros posteriores. No equivale a una prueba prospectiva del proceso completo. Además, el catálogo de riesgo de países documenta una fecha de junio de 2026, posterior al período de los formularios. Para una evaluación prospectiva será necesario reconstruir cada etapa con información disponible hasta el corte correspondiente y emplear las versiones históricas de los catálogos. Otra limitación se relaciona con la dependencia entre componentes.

El riesgo directo participa en la suma ponderada y sus señales críticas vuelven a intervenir como pisos; la forma de pago, a su vez, depende del perfil. Estas relaciones son parte del diseño, pero sus efectos deben examinarse mediante análisis de sensibilidad de pesos y umbrales. También se requiere evaluar posibles sesgos por actividad o nacionalidad y revisar coincidencias debidas a homónimos. Tanto la clasificación geográfica como la exposición política deben conservar su significado como insumos de diligencia, sin convertirse en atribuciones de conducta ilícita.

Por último, la estabilidad de la segmentación se comprobó con dos semillas, sin múltiples remuestreos ni validación externa. El nivel Alto reunió solo 22 registros de prueba, lo que limita la precisión de su sensibilidad estimada. La concordancia final está influida por reglas compartidas con la matriz de referencia, como se observó en Muy alto. Tampoco se evaluaron el uso del simulador en un flujo de trabajo real, la comprensión de sus explicaciones ni su efecto sobre las decisiones del equipo de cumplimiento. Estos aspectos delimitan la evidencia disponible para una eventual aplicación operativa.

## Conclusiones

La integración de perfiles económicos, factores ponderados y reglas críticas permitió establecer prioridades de revisión trazables para los registros analizados del sector automotriz ecuatoriano. El aporte de la metodología consiste en relacionar la información comercial y conservar el motivo de la prioridad asignada a cada expediente. El modelo de árboles aproximó el riesgo base con menor error que los comparadores evaluados. Las reglas críticas aportaron una parte importante de la concordancia con la clasificación final, por lo que el desempeño corresponde al sistema híbrido y debe interpretarse considerando ambos componentes.

La evidencia obtenida respalda una prueba de concepto para organizar la revisión y reproducir una matriz de referencia. Su utilidad para identificar operaciones sospechosas o mejorar la eficiencia del trabajo deberá establecerse mediante validación prospectiva con resultados independientes de cumplimiento. Esa evaluación requiere conservar la información extrema relevante y revisar los catálogos, pesos y umbrales antes de su adopción operativa.

## Referencias bibliográficas

Akartuna, E., Johnson, S., & Thornton, A. (2025). Motivating a standardised approach to financial intelligence: A typological scoping review of money laundering methods and trends. Journal of Experimental Criminology, 21, 1367–1413. https://doi.org/10.1007/s11292-024-09623-y

Ashtiani, M., & Raahemi, B. (2022). Intelligent fraud detection in financial statements using machine learning and data mining: A systematic literature review. IEEE Access, 10, 72504–72525. https://doi.org/10.1109/ACCESS.2021.3096799

Financial Action Task Force. (2025). International standards on combating money laundering and the financing of terrorism & proliferation: The FATF recommendations (actualización de octubre de 2025). https://www.fatf-gafi.org/content/dam/fatf-gafi/recommendations/FATF%20Recommendations%202012.pdf.coredownload.inline.pdf

Friedman, J. (2001). Greedy function approximation: A gradient boosting machine. The Annals of Statistics, 29(5), 1189–1232. https://doi.org/10.1214/aos/1013203451

Hernandez, L., Bustamante, L., Gutierrez, F., Moreno, J., & Rodríguez, M. (2024). Financial fraud detection through the application of machine learning techniques: A literature review. Humanities and Social Sciences Communications, 11, artículo 1130. https://doi.org/10.1057/s41599-024-03606-0

Hilal, W., Gadsden, S., & Yawney, J. (2022). Financial fraud: A review of anomaly detection techniques and recent advances. Expert Systems with Applications, 193, artículo 116429. https://doi.org/10.1016/j.eswa.2021.116429

Hubert, L., & Arabie, P. (1985). Comparing partitions. Journal of Classification, 2, 193–218. https://doi.org/10.1007/BF01908075

Jensen, R., & Iosifidis, A. (2023). Qualifying and raising anti-money laundering alarms with deep learning. Expert Systems with Applications, 214, artículo 119037. https://doi.org/10.1016/j.eswa.2022.119037

Jullum, M., Løland, A., Huseby, R., Ånonsen, G., & Lorentzen, J. (2020). Detecting money laundering transactions with machine learning. Journal of Money Laundering Control, 23(1), 173–186. https://doi.org/10.1108/JMLC-07-2019-0055

Kute, D., Pradhan, B., Shukla, N., & Alamri, A. (2024). Explainable deep learning model for predicting money laundering transactions. International Journal on Smart Sensing and Intelligent Systems, 17(1). https://doi.org/10.2478/ijssis-2024-0027

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, O., Prettenhofer, P., Weiss, R., Dubourg, V.,

Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. Journal of Machine Learning Research, 12, 2825–2830. https://jmlr.org/papers/v12/pedregosa11a.html

Rousseeuw, P. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. Journal of Computational and Applied Mathematics, 20, 53–65. https://doi.org/10.1016/0377-0427(87)90125-7

Unidad de Análisis Financiero y Económico. (2023). Resolución No. UAFE-DG-2023-0554. https://www.uafe.gob.ec/wp-content/uploads/downloads/2023/09/RESOLUCION_0554.pdf

Wang, Q., Tsai, W., Shi, T., Tang, W., & Du, B. (2025). Hide and seek in transaction networks: A multi-agent framework for simulating and detecting money laundering activities. Complex & Intelligent Systems, 11, artículo 271. https://doi.org/10.1007/s40747-025-01913-w

Weber, P., Carl, K., & Hinz, O. (2024). Applications of explainable artificial intelligence in finance—A systematic review of finance, information systems, and computer science literature. Management Review Quarterly, 74, 867–907. https://doi.org/10.1007/s11301-023-00320-0

**Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © José Andrés Zúñiga Cazorla, María Verónica Argudo Sumba y Natalia Elizabeth Tubón Castillo.**

**Declaraciones éticas y editoriales del artículo**

**Contribución de los autores (Taxonomía CRediT)**

José Andrés Zúñiga Cazorla: conceptualización de la investigación, diseño metodológico, desarrollo del proceso investigativo, análisis formal de los datos, redacción del borrador original del manuscrito, revisión crítica del contenido científico y supervisión general del estudio.

María Verónica Argudo Sumba: curación y organización de los datos, participación en la recolección de información, validación de los resultados obtenidos y elaboración de representaciones gráficas y visualización de los datos.

Natalia Elizabeth Tubón Castillo: provisión de recursos académicos y materiales para el desarrollo del estudio, apoyo en la administración del proyecto investigativo y revisión editorial del manuscrito antes de su publicación.

**Declaración de conflicto de intereses**

Los autores declaran que no existe conflicto de intereses en relación con la investigación presentada, la autoría del manuscrito ni la publicación del presente artículo.

**Declaración de financiamiento**

La presente investigación no recibió financiamiento específico de agencias públicas, comerciales o de organizaciones sin fines de lucro. En caso de existir financiamiento institucional o externo, este deberá ser declarado explícitamente por los autores en esta sección.

**Declaración del editor**

El editor responsable certifica que el proceso editorial del presente artículo se desarrolló conforme a los principios de integridad científica, transparencia y buenas prácticas editoriales. El manuscrito fue sometido a un proceso de evaluación mediante revisión por pares doble ciego, garantizando la confidencialidad de la identidad de los autores y revisores durante todo el proceso de dictamen académico. Asimismo, el editor declara que el artículo cumple con los criterios científicos, metodológicos y éticos establecidos por la revista.

**Declaración de los revisores**

Los revisores externos que participaron en la evaluación del presente manuscrito declaran haber realizado el proceso de revisión de manera objetiva, independiente y confidencial. Asimismo, manifiestan que no mantienen conflictos de interés con los autores ni con la investigación evaluada, y que sus observaciones y recomendaciones se fundamentan exclusivamente en criterios científicos, metodológicos y académicos.

**Declaración ética de la investigación**

Los autores declaran que la investigación se desarrolló respetando los principios éticos de la investigación científica, garantizando la confidencialidad de los datos y el respeto a los participantes del estudio. En los casos en que la investigación involucre seres humanos, los procedimientos deben ajustarse a los principios éticos establecidos en la Declaración de Helsinki y a las normativas institucionales correspondientes.

**Declaración sobre el uso de inteligencia artificial**

Los autores declaran que el uso de herramientas de inteligencia artificial, en caso de haberse utilizado durante el proceso de investigación o redacción del manuscrito, se realizó únicamente como apoyo técnico para mejorar la claridad del lenguaje o el análisis de información, manteniendo siempre la responsabilidad intelectual sobre el contenido del artículo. Las herramientas de inteligencia artificial no fueron utilizadas como autoras del manuscrito ni sustituyen la responsabilidad académica de los investigadores.

**Disponibilidad de datos**

Los datos que respaldan los resultados de esta investigación estarán disponibles previa solicitud razonable al autor de correspondencia, respetando las normas éticas y de confidencialidad establecidas por la investigación.