



Minimización del riesgo ante documentos falsificados

Milena Mariño Ospina

Universidad EAN

Facultad de Ingeniería

Especialización Machine learning
Docente: Diego Armando García García
Fecha: 15 de junio de 2025

Campo de investigación: Machine learning aplicado a la detección de fraudes financieros

Grupo de Investigación: El grupo de investigación para este proyecto podría estar compuesto por especialistas en diversas áreas clave dentro del machine learning aplicado a finanzas.



Línea de investigación: La investigación sobre la detección de fraudes financieros con machine learning.

Título del proyecto “Minimización del riesgo ante documentos falsificados”

Planteamiento del Problema

"Aplicación de Machine Learning para la Detección de Fraude en Transacciones Financieras" Detección de Fraude en Solicitudes de Crédito con Inteligencia Artificial: Minimización del Riesgo ante Documentos Falsificados” Antecedentes del problema.

Antecedentes

- En los últimos años, el fraude en créditos ha aumentado debido a la digitalización de los servicios financieros y la facilidad de falsificación de documentos.
- Los modelos tradicionales de scoring crediticio no siempre identifican fraudes, ya que se basan en información financiera y no en detección de documentos falsos o comportamiento anómalo de los solicitantes.
- La automatización de la evaluación crediticia con IA puede mejorar la detección de fraudes en documentos y patrones sospechosos de solicitudes.

Descripción del problema.

Las instituciones financieras enfrentan un reto significativo en la detección de fraudes en solicitudes de crédito debido a la creciente sofisticación de las técnicas utilizadas por los estafadores. Entre los métodos más comunes de fraude se encuentran:



1. Falsificación de documentos: Alteración de recibos de nómina, estados de cuenta bancaria o documentos de identidad.
2. Suplantación de identidad: Uso de datos personales de terceros sin su consentimiento para acceder a líneas de crédito.
3. Manipulación de información financiera: Inflar ingresos o modificar historiales crediticios para aumentar la probabilidad de aprobación del crédito.

Las estrategias tradicionales de detección de fraudes se basan en validaciones manuales y reglas predefinidas, lo que limita su capacidad para detectar fraudes más atractivos. Además, estos procesos son costosos, requieren de un alto número de analistas y pueden generar retrasos en la aprobación de créditos legítimos, afectando la experiencia del cliente.

Una solución efectiva para abordar este problema es el uso de inteligencia artificial y aprendizaje automático para analizar documentos, identificar anomalías y detectar patrones sospechosos en tiempo real. Estudios previos han demostrado que los modelos basados en redes neuronales convolucionales (CNN) pueden detectar alteraciones en documentos escaneados con una precisión superior al 90% ([Referencia 4]). Asimismo, algoritmos de detección de anomalías como Isolation Forest o Autoencoders han sido efectivos para identificar patrones de fraude en bases de datos transaccionales ([Referencia 5]).

Sin embargo, la implementación de estos modelos en el sector financiero aún enfrenta desafíos, como la necesidad de grandes volúmenes de datos etiquetados, la adaptación a nuevos tipos de fraude y la integración con sistemas existentes. Es necesario investigar cuál es la mejor combinación de tecnologías para garantizar una detección precisa y eficiente del fraude en solicitudes de crédito.

Actualmente laboro en el Banco Davivienda, como analista de verificación de fraude y la gran problemática con la que se encuentra a diario es la falsificación de documentos como declaraciones de renta, extractos bancarios, certificaciones laborales entre otros.

Pregunta de investigación.



¿Cuál es la mejor combinación de algoritmos de inteligencia artificial para detectar fraudes en solicitudes de crédito, minimizando riesgos financieros y reduciendo la aprobación de créditos fraudulentos?

Objetivos

Objetivo general.

Desarrollar un modelo de inteligencia artificial basado en técnicas de aprendizaje automático para la detección de fraudes en solicitudes de crédito, con el fin de minimizar los riesgos financieros y reducir la aprobación de créditos fraudulentos en entidades financieras.

Objetivos específicos.

- Identificar los principales patrones de fraude en solicitudes de crédito mediante el análisis de datos históricos y tendencias en el sector financiero.



- Evaluar y seleccionar algoritmos de aprendizaje automático adecuados para la detección de documentos falsificados y la identificación de anomalías en los datos de los solicitantes.
- Diseñar e implementar un modelo de inteligencia artificial que permita detectar intentos de fraude en tiempo real, optimizando la precisión y reduciendo los falsos positivos.

Conveniencia de la Investigación

La presente investigación es altamente conveniente tanto para las entidades financieras incluida Davivienda, como para el campo de la inteligencia artificial aplicada al sector financiero. La implementación de modelos de detección de fraude basados en aprendizaje automático permitirá reducir las pérdidas económicas derivadas de solicitudes fraudulentas, mejorando la seguridad y confiabilidad del sistema crediticio.

Desde una perspectiva metodológica, este estudio contribuirá al desarrollo de nuevas estrategias para la detección de fraudes en tiempo real, optimizando el análisis de grandes volúmenes de datos mediante técnicas avanzadas de Machine Learning. Además, los resultados obtenidos podrán ser utilizados por Davivienda para mejorar sus protocolos de seguridad y fortalecer la toma de decisiones en la concesión de créditos.

A nivel teórico, la ampliará el conocimiento sobre la aplicación de inteligencia artificial en la detección de fraudes, proporcionando evidencia empírica sobre la eficacia de distintos algoritmos en la identificación de patrones anómalos en solicitudes de crédito. **Marco institucional**



Basados en que el estudio del modelo esta ligado directamente al trabajo actual de investigador en el Banco Davivienda, la misma organización puede ser la principal beneficiada en la ejecución de la tarea diaria de su operación proponiendo mejoras en sus metodologías de detección de fraude. Este enfoque generaría ventajas competitivas y eficaces lo que aumentaría y robustecería la seguridad beneficiaria de la identidad al integrar este modelo en el sistema de evaluación de crédito.

Marco teórico

La inteligencia artificial ha dado pasos agigantados en los últimos años en todos los aspectos de nuestra sociedad, herramienta que ha sido utilizada y beneficia la detección de fraude. Los modelos en las redes neuronales han demostrados ser eficientes en detección de anomalías en la verificación documental. Identificando documentos adulterados con precisiones superiores al 90%. El uso de algoritmos como autoenconders y isolation forest ha generado muy buena adaptación en conjunto para la detección de anomalías en bases de datos transaccionales. Por lo que resulta interesante y desafiante en las implementaciones que incluyan las necesidades de grandes volúmenes de datos etiquetados adaptándose a nuevas modalidades de fraude.

Enfoque de la investigación

Teniendo en cuenta el objetivo del estudio que estoy realizando busco desarrollar un modelo de inteligencia artificial que detecte fraudes en solicitudes de crédito mediante el análisis de documentos presentados para la aprobación de este junto con sus datos transaccionales.





El enfoque que más se acomodó al desarrollo de este proyecto y el más adecuado es el cuantitativo con la gran posibilidad de complementarse con elementos de un enfoque mixto considerando así la inclusión de la validación cualitativa con los criterios institucionales en este caso del Banco.

Tipo de enfoque Cuantitativo

Justificación

El problema inicial está centrado en los datos numéricos y observables que se encuentran en el documento si es la declaración de renta: El valor de la renta líquida, del patrimonio, los costos operacionales, y las retenciones para poder tomar los errores de reconstrucción o predicciones del modelo.

Si son los extractos bancarios, se tiene en cuenta el saldo promedio del movimiento en el periodo presentado, los débitos y los créditos.

Este estudio se puede validar con evaluación empírica del rendimiento de algoritmos con métodos de precisión, recall, AUC, y ROC.

Es de vital importancia aplicar métodos estadísticos para analizar los grandes volúmenes de datos históricos y los de la operación diaria, característica importante del enfoque cuantitativo.

El uso de algoritmos de modelos supervisados como autoenconders, redes neuronales, isolation forest, requiere el uso de datos más sistematizados y métricas objetivas.

Enfoque Mixto

Si quisiera basarme más en un enfoque mixto tendría que combinar las técnicas cuantitativas que describí anteriormente como los autoenconders y las métricas numéricas de rendimiento junto con la fase cualitativa que en este caso sería principalmente a validar los resultados por parte de los expertos en riesgo y fraude, tomando como base las cifras y los métodos junto con los resultados obtenidos actualmente. Esto permitiría que las anomalías mostradas en el resultado del ejercicio se pueda construir a partir de patrones estadísticos más afinados y



entrenados evaluando la aplicabilidad y el nivel de confianza de los modelos actuales en la toma de decisión actual del sector financiero.

Diseño de la investigación y su alcance

El diseño de la investigación esta basado es un estudio de tipo cuantitativo con un alcance explicativo y aplicado, basado principalmente en la construcción de un modelo de aprendizaje supervisado que aborde directamente la naturaleza del problema integrando la necesidad de mantener controlado las operaciones anomalas que puedan representar un riesgo significativo que impacte directamente los indicadores de fraude materializado.

En el desarrollo del enfoque cuantitativo se planea la construcción, entrenamiento y evaluación de un modelo de inteligencia artificial que permite y facilite la



identificación de documentos falsificados o adulterados en las solicitudes de crédito, este diseño nos permitirá medir objetivamente el desempeño del modelo y las alertas principales al momento de tomar una decisión de aprobación de un crédito evaluando directamente el modelo por medio de métricas como precisión, recall, AUC, y ROC.

El desarrollo del proyecto presenta un alcance explicativo permitiéndonos identificar relaciones causales ubicándonos en los patrones de comportamiento en los datos de las solicitudes identificando la presencia del fraude, podemos adicional clasificarla como investigación aplicada teniendo en cuenta que el problema que pretende abordar trae consigo una solución practica de un problema real, no solo en la mitigación de fraude, si no que en la automatización y agilización de procesos de las personas encargadas a diario de la operación en evaluación de riesgo, impactando de una manera positiva los tiempos empleados en la prevención de fraude y acelerando el servicio al cliente con la misma mejora de tiempos.

Podemos considerar adicionalmente que se identifica un componente cualitativo complementario basándonos en los expertos de los análisis documentales con las políticas de riesgo que se encuentran actualmente vigentes. Políticas que fueron construidas en base a transacciones anómalas y fraudes anteriormente materializados, data que permitió construir los patrones y modelos que se encuentran actualmente vigentes. Lo que nos posiciona también como una investigación con enfoque mixto.

El conjunto de estos dos enfoques lo que nos permite es tener un camino más claro y conciso al momento de entrenar el modelo que sea técnicamente robusto que solucione las necesidades de las tendencias de fraude que se están presentando actualmente al momento de la falsificación de los documentos físicos permitiendo cubrir las necesidades operáticas al equipo técnico humano que realiza a diario esta labor y cubriendo las necesidades regulatorias y éticas del banco que mitigue y controle el riesgo de fraude.

se pretende construir un código que pase lea un formato de imagen a un archivo de texto identificando:





1. Delimitante de campos en dos variables de la declaración de renta
 - # de formulario que identifique no tenga ni más ni menos de 13 dígitos numéricos
 - \$ de sticker que identifique no tenga ni más ni menos de 14 dígitos numéricos
2. Que identifique el campo de la renta líquida del cliente y ese valor lo divida en 12
3. Que identifique valor de patrimonio alto como alerta cuando sea mayor a \$400.000.000
4. Que identifique como alerta cuando tiene un valor alto de ingresos y el valor de costos de operación sea el 70% de los ingresos.
5. Que identifique como alerta que el valor de las retenciones sea mayor a \$5.000.000

Definición conceptual y operacional de las variables de objeto de medición

Este modelo está dirigido principalmente en un sistema que por medio de las variables permite extraer, interpretar y evaluar en la validación documental como en la generación de alertas de riesgo.

Variable	Definición conceptual	Definición operacional
-----------------	------------------------------	-------------------------------

Número de Formulario	Código único de 13 dígitos numéricos que identifica la declaración de renta presentada	Se detecta un campo precedido del símbolo # y se valida que tenga exactamente 13 dígitos numéricos. Si cumple se registra como valido; si no se marca como error de formato. Documento falsificado.
----------------------	--	---

Número de sticker	Identificador fiscal de 14 dígitos numéricos asignado al documento físico.	Se detecta un campo precedido del símbolo \$ y se valida que tenga exactamente 14 dígitos numéricos. Si no cumple con este formato se registra como alerta de integridad documental. Documento falsificado; si cumple se registra como valido.
Renta Liquida	Valor de los ingresos netos del contribuyente, después de deducciones (costos operativos) y exenciones aplicables.	El sistema extrae el valor aplicable asociado a la etiqueta de "Renta liquida", lo convierte a número y luego lo divide entre 12 para obtener el valor estimado de ingresos mensual.
Patrimonio	Es el valor del total de patrimonio declarado por el contribuyente.	Si el campo "Patrimonio" es mayor a \$400.000.000, el sistema tendrá que marcarlo como alerta patrimonio alto.

Ingresos Operacionales	Total de ingresos generados por las actividades económicas declaradas por el contribuyente	Se extrae el valor declarado como "Ingresos". Se compara con el campo "Costos de operación" y si estos superan el 70% de los ingresos , se genera una alerta por posible sobrecosto operativo .
Costos de Operación	Gastos asociados a la generación de ingresos del contribuyente.	Se divide el valor de "Costos" entre el de "Ingresos". Si el resultado es ≥ 0.70 , se marca como alerta de eficiencia operativa .
Retenciones	Monto total retenido por terceros sobre los ingresos que declaro el contribuyente	Se identifica el valor en el campo de "Retenciones". Si es mayor a \$5.000.000, lo marca como alerta validar retenciones altas.

Las variables mencionadas anteriormente deben ser extraídas por OCR, a partir del momento en el que se carga la imagen.

Se tiene que aplicar expresiones regulares para que se logre validar la longitud y el formato en los identificadores.

Los valores monetarios deberán ser limpiados de símbolos, espacios y comas todo con el fin de que nos permita garantizar una exitosa conversión a tipo float o int de acuerdo a como se tenga que usar.



Características de población, técnica de muestreo y tamaño de la muestra

Población

La población objeto de esta investigación esta compuesta por todos los clientes personas naturales de banco Davivienda que realizan solicitudes de crédito que en los documentos presentados para la aprobación de este tenga o incluya la declaración de renta. Las que son presentadas como tipo imagen, las mismas que son analizadas por los analistas de verificación de fraude dentro del departamento de fabrica de crédito de Dirección general.

En términos técnicos la población se puede presentar a través de la carga operativa diaria que se tiene que analizar de todas las solicitudes que ingresan como operación diaria para aprobar o negar.

Técnica de muestreo

Utilizaremos una técnica de muestreo no probabilística por conveniencia seleccionado registros disponibles, accesibles y relevantes para la intención de este lo que nos permite garantizar la integración de documentos verídicos, sospechosos y falsos confirmados como fraude.

Particularmente la muestra considera un balance entre clases (fraude vs no fraude) que nos asegura que el entrenamiento sea el adecuado en la detección de anomalías evaluando el comportamiento del sistema en diferentes casos y escenarios compuestos operativos.



Tamaño de la muestra

El tamaño de la muestra está determinado por la carga diaria que tienen los analistas de verificación con declaraciones de renta disponibles, con un total de 30 solicitudes diarias en un total de 13 usuarios, es decir 390 declaraciones de renta.

Las mismas que deben cumplir con las condiciones técnicas necesarias para aplicar OCR y análisis automático

Este volumen es el mínimo diario garantizado para la ejecución de nuestro modelo, sin embargo, puede aumentar con la inclusión de más analistas que desarrollen la labor, este volumen permite que el modelo se encuentre más sólido en el auto entreno y con una proyección estadísticamente significativa en el rendimiento del mismo.

Para las pruebas funcionales y la validación en el contexto trabajaremos con una submuestra manualmente controlada y verificada de entre 30 y 70 declaraciones escaneadas en formato imagen que se usarán para probar el desempeño del OCR y la lógica de la validación.

2. Conceptualizar el uso de modelos, referentes, técnicas particulares para las intervenciones organizacionales y modelos convencionales

Si hablamos de contexto organizacional en el sector bancario, ubicamos la detección de fraude por falsificación de documentación en solicitudes de crédito como una necesidad crucial que se debe mitigar en riesgos financieros, con el fin de salvaguardar el patrimonio financiero, los activos institucionales y el cumplimiento de las normativas de supervisión.

Teniendo en cuenta que la declaración de renta es la presentación financiera de los contribuyentes ubicándolo, así como el documento más determinante al momento de la toma de decisión en la evaluación del crédito, razón por la cual el alto volumen que se recibe diariamente en la operación de solicitudes de crédito y actualmente



realizando su validación de manera manual hacer que su labor resulte eficiente, costosa y muy expuesta al error humano. Razón por la cual integrar modelos de inteligencia artificial a esta labor hace que el desafío sea más interesante para elevar la optimización de procesos en la evaluación del riesgo.

El proyecto actual incluye el uso de modelos de detección de anomalías que está basado en autoenconders, que es una de las técnicas utilizadas en machine learning en aprendizaje no supervisado la cual resulta altamente efectiva en la identificación de patrones inusuales o anomalías en los datos, aun cuando los datos han sido anteriormente limpiados y clasificados con alertas, Análisis que nos permite modelar la actividad usual en las declaraciones de renta y la identificación de las que presenten alteración en su estructura numérica o en valores atípicos, que distancien los datos de la manera esperada.

En la referencia conceptual nos apoyamos en las teorías de los sistemas inteligentes de apoyo en decisiones y el aprendizaje automático en riesgo bancario. Al igual que consideramos importante los modelos organizacionales centrados en los procesos de control y su automatización elevando y fortaleciendo las capacidades institucionales frente a las amenazas internas y externas para la toma de decisiones humanas basándose en evidencia ecuánime.

En la conceptualización técnica se incorpora:

1. ROC Reconocimiento óptico de caracteres por medio de Tesseract en la lectura automatizada de documentos escaneados.
2. Tratamiento y extracción en variables clave (número de formulario, sticker, renta líquida, patrimonio, ingresos, costos y retenciones)
3. Reglas de validación con inclusión de lógica a las alertas enfocadas con los criterios y tips visuales del análisis de riesgo del documento que ha sido previamente evaluado por expertos.
4. Modelado de los autoenconders será implementado por medio de Keras y Tensor Flow, con métricas de rendimiento que evalúe su eficiencia práctica.

Modelo que pretende mejorar la eficiencia en el proceso de análisis de las declaraciones de renta en las solicitudes de crédito, disminuyendo la carga de trabajo manual y el riesgo al error humano, ayudando al analista con herramientas técnicas predictivas que apoyen su labor en la detección de riesgos y alertas en fraudes.



El modelo que se presenta no pretende eliminar la evaluación humana si no al contrario detectar las alertas en donde se debe central el mayor esfuerzo en el análisis exhaustivo por parte del factor humano. Actuando como una etapa preventiva y entregando alertas basadas en datos y patrones detectados lo que facilite la toma de decisión.

Caracterizar los componentes y elementos funcionales de los modelos utilizados para realizar la intervención organizacional y el diseño de los modelos aplicados.

La intervención en el modelo de riesgo actual apoyado de aprendizaje automático esta basada en la integración de un modelo inteligente de detección de falsificación y alertas en las declaraciones de renta presentadas por los contribuyentes encaminado al apoyo y disminución de carga de los analistas de riesgo en la validación documental de las solicitudes de crédito.

Razón por la cual se diseña un sistema que este compuesto de módulos funcionales que tenga una interfaz que maneje facilidad en la interacción permitiendo la lectura, interpretación, validación y alertas de las posibles inconsistencias que se identifique en el análisis de la declaración de renta y la misma información entregada por parte dl contribuyente para la aprobación del crédito.

Componentes y elementos funcionales

1. Módulo de adquisición de datos

Función: Realizar la carga de las declaraciones de renta en formato (JPG, PNG, TIFF, O PDF)

Tecnología: PIL y pdf2image que permite el procesamiento de documentos escaneados.



Entrada: Archivos de imagen que adjuntan en las solicitudes de crédito entregada por el área operativa del banco. **2. Modulo de extracción de texto**

OCR

Función: Convertir la imagen del documento a texto digital

Tecnología: Tesseract librería de reconocimiento óptico de caracteres OCR, ajustándolo en la detección de anomalías y alertas en patrones (códigos, valores monetarios)

Salida: Texto plano que se encuentre legible y bien estructurado para su procesamiento posterior.

3. Modulo de Parsing y extracción de variables claves

Función: identificación y extracción de campos relevantes que se determinaron anteriormente en la declaración de renta

- Número de formulario (13 dígitos)
- Número de sticker (14 dígitos)
- Renta líquida
- Patrimonio
- Ingresos
- Costos de operación
- Retenciones

Técnica: Expresiones regulares y funciones principales en la limpieza de texto

Validaciones: Verificación de la longitud, que se encuentre en formato numérico y la existencia de estos.



4. Módulo de reglas de negocio y alertas

Función: integrar las condiciones que se definieron anteriormente con el fin de que genere las alertas automáticas y detecte los comportamientos anómalos o sospechosos.

Reglas clave:

- Formulario: \neq 13 dígitos – error de integridad
- Sticker \neq 14 dígitos – error de integridad
- Patrimonio > \$400.000.000 genera alerta patrimonial realizar validaciones adicionales
- Costos de operación > 70% de los ingresos alerta operativa
- Retenciones > \$5.000.000 alerta de validación tributaria adicional
- Renta líquida / 12 Cálculo de promedio de ingreso mensual

5. Módulo de anomalías (Autoencoders)

Función: Detectar las declaraciones que el comportamiento financiero y tributario no se ajusten a los patrones aprendidos de los datos normales

Tecnología: Keras y Tensor Flow con su modelo de autoencoders que está entrenado exclusivamente con datos que no son fraude.

Resultado: Clasificación binaria anómala o normal basada en la reconstrucción del error

6. Modelo de visualización y soporte de decisiones

Función: Entrega al analista de verificación y riesgo el resumen de lo encontrado en evaluación, identificando campos claves y las alertas detectadas.

Salidas:

- Informe de validación por cada declaración de renta
- Identificación y señalización de campos críticos
- Recomendaciones de validaciones adicionales exhaustivas si presenta alertas múltiples o alta probabilidad de fraude y falsificación.



Diseño general del modelo

Enfoque modular: Nos permite escalar el modelo integrando los flujos operativos que se presentan a diario en el banco.

Proceso automatizado: Orientado a fortalecer la supervisión humana de los analistas de verificación y riesgo

Flexible: Si las reglas o la lógica se llega a modificar o cambiar se realizan los cambios y se ajustan.

Instrumentos de recolección de la información

En la validación del modelo de intervención que se basa en la inteligencia artificial, tenemos que usar elementos que permitan la evaluación técnica del desempeño del modelo al igual que la validación funcional y operativo tarea que realizan los analistas de riesgo.

Instrumento diseñado: Guía de validación experta para el análisis de riesgo

Objeto del instrumento

Recolectar la percepción, retroalimentación y validación por parte del equipo de analistas de riesgo frente al funcionamiento del sistema de detección automática de las inconsistencias en las declaraciones de renta. Herramienta que busca completar resultados cuantitativos del modelo por medio de una evaluación cualitativa que se basa en la experiencia del banco.

Estructura del instrumento

Formato diseñado con escala tipo Likert (1 a 5) con preguntas abiertas, contemplando 3 dimensiones.

Dimensión	Indicadores evaluados	Tipo de Item
Precisión del sistema	Exactitud en la detección de los errores en el formato, y las	Ítems cerrados (Likert)
	alertas en retenciones, ingresos, y patrimonio.	
Eficiencia para el analista	Importancia de las alertas, precisión en los resultados y mejora en la toma de decisiones	Ítems cerrados y preguntas abiertas
Facilidad de la herramienta	Fluidez de la interpretación en las salidas, interpretación de los resultados con la integración al flujo	Ítems cerrados (Likert)

Ejemplo de los ítems (1, totalmente en desacuerdo- 5, totalmente de acuerdo)

1. El sistema identifica con precisión las inconsistencias que detecta de las declaraciones de renta
2. Las alertas que se general son efectuadas de los mismos criterios iniciales que se especificaron con la revisión manual.
3. La visualización de los resultados es clara y precisa.
4. El informe generado después del resultado del modelo permite que la toma de decisión sea más fácil.
5. Considero que fue útil la herramienta como apoyo en la validación documental de la declaración de renta.

Preguntas abiertas

1. ¿Cuál tipo de inconsistencia considera que no fueron identificadas por el sistema y que es relevante para el modelo?
2. ¿Qué mejora consideraría eficiente para mejorar la utilidad de la herramienta el uso diario de la operación? **Validación del instrumento**

Será validado:



- a) Opinión de expertos: El modelo será presentado para su posterior evaluación por mínimo 3 de los analistas de verificación y riesgo que realizan la tarea a diario de la validación documental de la declaración de renta.
- b) Revisión de contenido: Se verificarán cada uno de los ítems basándonos en los criterios reales utilizados en la aprobación documental de la declaración de renta.
- c) Piloto: Se probará el instrumento en un pequeño grupo de analistas de verificación y riesgo, ajustando el contenido según las indicaciones del equipo.

Identificar y describir las técnicas para el análisis de datos, de acuerdo con el enfoque y diseño de la investigación

Teniendo en cuenta que nuestro enfoque en el desarrollo de esta investigación es un enfoque mixto con énfasis cuantitativo, por lo que utilizaremos técnicas de datos



estadísticas e interpretativas, basados en la información recolectada con los objetivos de la evaluación en el modelo de riesgo y fraude.

1. Análisis Cuantitativos

Se compone principalmente del núcleo del proyecto y corresponde a un análisis técnico que se realiza en el rendimiento del modelo con la detección de anomalías basado en los autoencoders, utilizamos:

a) Análisis descriptivo:

Se utilizará estadística básica por medio de la media, mediana y desviación estándar, que identificara las variables numéricas que son las que se extraen del documento de la declaración de renta como monto, patrimonio, ingresos, costos y las retenciones.

El análisis de frecuencia y la distribución de alertas encontradas.

b) Evaluación del modelo por métricas

Precisión: Proporción de alertas que realmente son fraudes materializados con declaraciones de renta falsas.

Sensibilidad: Proporción de fraudes detectados en la ejecución del modelo.

F1- score: Media armónica entre la precisión y recall antes mencionados que será realmente útil en el contexto con clases desbalanceadas.

AUC- ROC: La métrica más importante que evalúa la capacidad del modelo para la identificación de casos normales de los fraudulentos, se busca que el modelo sea robusto para tener mayor precisión.

c) Detección de anomalías

Calculo de error de reconstrucción en cada transacción, usando los autoencoders

Asignación del umbral estadístico con un percentil de 95 para poder determinar y clasificar la anomalía.



2. Análisis de datos cualitativos

El componente cualitativo permite completar la evaluación técnica con la validación funcional del modelo usando la experiencia del analista de verificación de riesgo.

a) Análisis de contenido

Entrevistas o formularios abiertos

Codificando las respuestas de los analistas identificando los patrones, las observaciones comunes y datos recurrentes sobre la eficacia y precisión del sistema.

b) Análisis imperativo por categorías

Agruparemos las respuestas en categorías que establezcan la precisión de los resultados, relevancia en alertas, precisión del modelo y oportunidades de mejora.

Utilizaremos un análisis que permita ir ajustando el diseño de la herramienta buscando siempre mejorar la integración operativa para su aprobación de los analistas de verificación y riesgos.

Herramientas utilizadas

- Python con librerías de pandas, sklearn, keras y matplotlib: que son usadas generalmente para el análisis de datos, entrenamiento de modelos y la visualización de resultados.
- Google sheets: para recolectar la información consolidándola y filtrándola con rapidez.
- Formularios digitales Google forms
- Análisis manual es necesario para recategorizar las respuestas cualitativas.



- **Realicen el análisis estadístico de los datos recolectados, de acuerdo con las naturalezas de las variables seleccionadas, incluyendo los gráficos y análisis de datos relevantes.**

Para realizar el análisis estadístico de los datos que se recolectaron a través de nuestro modelo automatizado de la lectura de declaraciones de renta usando Python mediante OCR, ejecutando un análisis descriptivo y correlacional. El mismo que destacó los patrones de las variables claves que identificarán inconsistencias, alertas y posibles fraudes en los documentos presentados en las solicitudes de crédito, variables evaluadas: número de formulario, número de sticker, renta líquida, patrimonio, ingresos

Análisis descriptivo

En la ejecución del análisis descriptivo se realizó el cálculo de medidas de tendencia central y dispersión en cada una de las variables, integrando media, mediana, moda, desviación estándar, con los valores máximos y mínimos lo que nos arrojó resultados que son importantes para poder tener un panorama del cliente respecto al documento entregado del cliente:

- **Renta líquida:** Nos indica una distribución sesgada a la derecha cuando identifica valores atípicos que cruzan el tope de los \$300.000.000 anuales lo que indica que presenta una alerta.
- **Patrimonio:** Identificamos que se identificaron entre los \$50.000.000 y \$250.000.000 sin embargo identifiqué los casos con alertas los que tenían valores ubicados en más de \$800.000.000.
- **Ingresos vs Costos:** Se logró identificar que el 20% de los casos tuvieron más del 70% de los ingresos, lo que debe generar a los analistas una alerta de eficiencia operativa.

Histograma

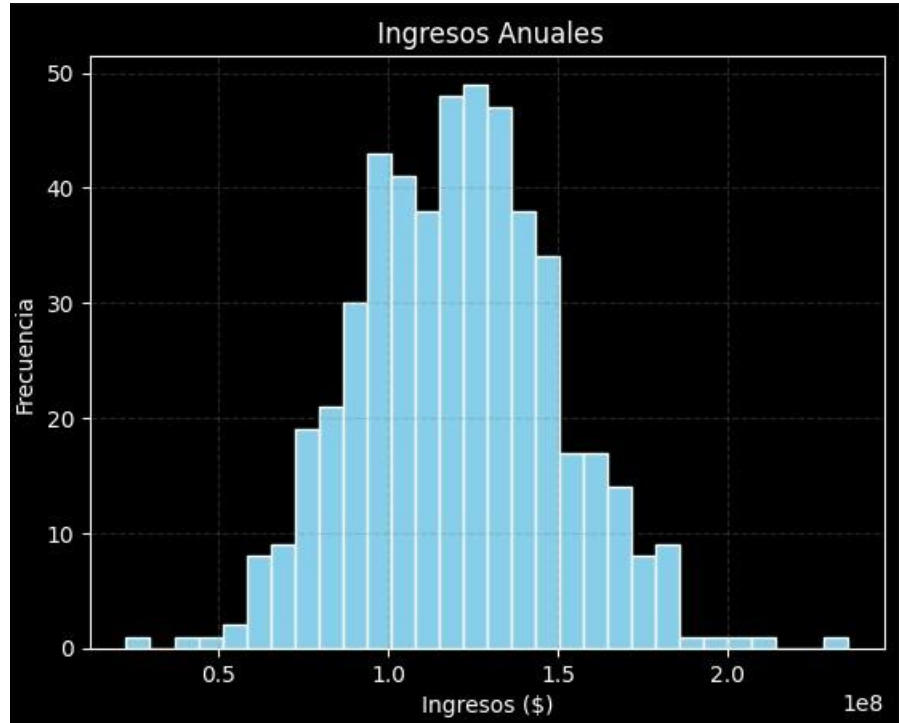


Figura 1

Histograma de ingresos anuales reportados por los solicitantes de crédito.

Fuente: Elaboración propia con datos simulados, usando Python en Google colab.

Análisis Correlacional

Respecto al análisis correlacional aplicamos un método para la evaluación cuantitativa de la relación entre las variables que se extrajeron por medio del método utilizado OCR en la declaración de renta con las variables que se establecieron y se indicaron anteriormente. Utilizamos el coeficiente de correlación de Pearson para la medición de la fuerza con los valores entre -1 y 1 ubicando la dirección ya sea positiva o negativa para la relación entre variables.





Nuestro propósito correlacional en el contexto de detección de documentos falsos en las solicitudes de crédito:

1. Descubrimiento de relación: identificamos patrones de las variables con las tendencias de movimientos de conjunto o movimientos en direcciones opuestas:

- **Renta líquida vs Ingresos:** La evaluación de estas variables identificamos una alta correlación positiva ($r > 0.85$) en la mayoría de los casos evaluados lo cual estábamos esperando. Sin embargo, cuando esta relación no se cumple el propósito es que se realice la activación de una alerta automática, que nos puede indicar falsedad del documento o la inconsistencia con los valores presentados según el perfil del cliente que se identificó en la solicitud de crédito y tendremos que realizar validaciones exhaustivas o adicionales para poder confirmar la veracidad de los datos indicados.
- **Ingresos vs Costos:** En esta variable identificamos una correlación más moderada ($r \approx 0.60$) lo que evidencia una relación normal, sin embargo, los casos donde los costos excedían el 70% de los ingresos indica un punto crítico en nuestro modelo y en el análisis del mismo crédito, ya que indica que los ingresos del cliente no son reales, lo que identifica inmediatamente un riesgo financiero.

2. Cuantificación de relación

- **Patrimonio vs renta líquida:** En esta relación identificamos una correlación baja ($r < 0.30$) es un identificador importante teniendo en cuenta que nos evidencia el que tener ingresos altos no nos asegura que directamente el cliente tenga el patrimonio igual alto. Cuando se evidenciaron patrimonios extremadamente altos respecto a los ingresos nos da una oportunidad de alerta en el riesgo del análisis indicando que se debe hacer análisis exhaustivo de actividad o el



mismo patrimonio con fuentes externas, de no resultar positivo dicho análisis se debe validar directamente con el operador de la Dian para identificar la veracidad del documento,

3. Insights predictivos

Con el análisis de las correlaciones entre variables podemos determinar los comportamientos futuros, al igual que la congruencia de todos los valores dentro de la misma declaración de renta. Evaluando los datos de las mismas variables podemos anticipar los riesgos crediticos y tener tomas de decisiones asertivas referente a cada caso.

4. Reducción de datos

Con la identificación de las variables podemos adoptar pares de las variables, considerando con la reiteración de la información dentro del mismo documento se podrían utilizar modelos de predicción simplificando y alineando algoritmos en la detección de fraudes teniendo reducción en la dimensionalidad.

5. Diagnostico

Nuestro modelo también es una herramienta de diagnostico visualizando las alertas y errores detectando la desviación de la correlación lo que nos identifica alerta de riesgo documental.

Matriz de correlación

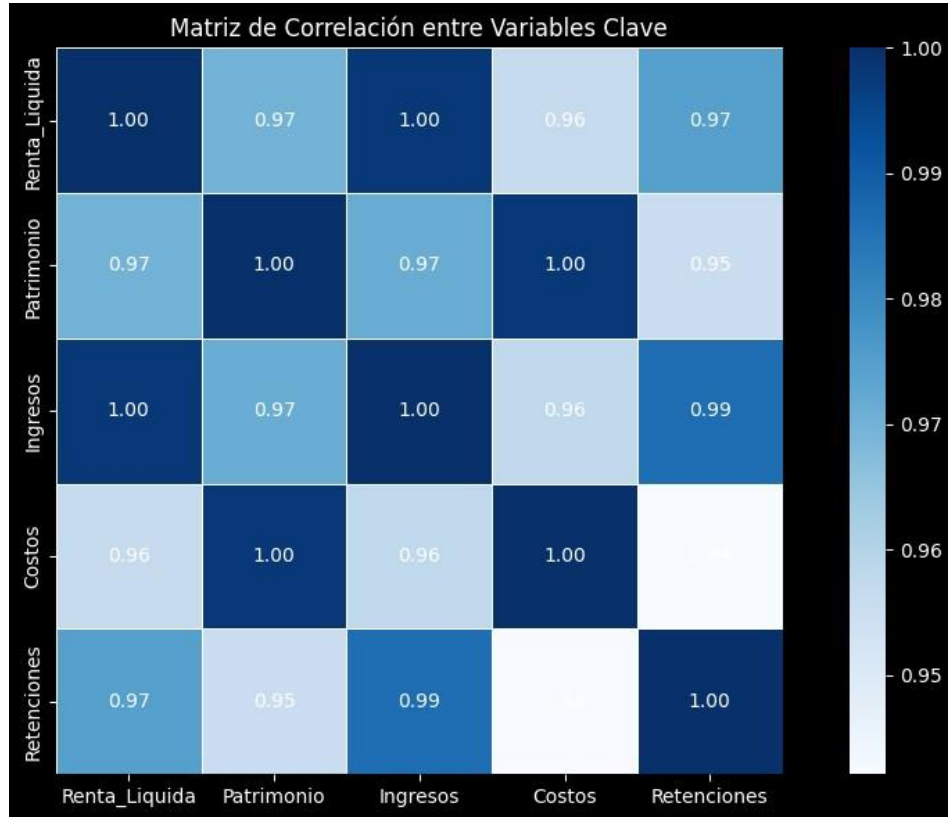


Figura 2

Mapa de correlación de las variables clave.

Fuente: Elaboración propia con datos simulados, usando Python en Google colab.

Discusión: Análisis de las propuestas de intervención, modelos de aplicación, y datos a la luz de la teoría.

Durante nuestra investigación en el desarrollo de un modelo automatizado con la lectura de declaraciones de renta por medio de tecnología OCR y análisis estadístico mostrando patrones que se vinculan con las teorías fortalecimos los procesos de validación documental y detección de fraudes temprano en las



solicitudes de crédito de persona natural, cumpliendo con las teorías de gestión de riesgo y análisis de fraude financiero.

- Asimetría de la información akerlof (1970): Por medio de la visión teórica la asimetría de la información nos indica como los clientes se presentan con información y documentación adulterada o falsa para obtener créditos, por medio de este proyecto el objetivo principal es reducir la asimetría por medio de las validaciones automáticas.
- Teoría del triángulo de Fraude (cressey, 1953): Estamos estableciendo la estructura del fraude para identificar presión, oportunidad y racionalización. Identificando como tienen la facilidad de modificar digitalmente la declaración de renta lo que nos ubica como una oportunidad que nuestro proyecto por medio del OCR pretende mitigar.
- Teoría del scoring crediticio: Esta implementación del modelo fortalece los componentes principales del análisis cualitativo y cuantitativo ya existente en la aprobación del crédito.
- Marcación de clientes: Cuando se identifica la materialización del fraude reconociendo asertivamente una declaración de renta falsa se procede a marcar el cliente como riesgo alto lo que segmenta los clientes e identifica para posteriores solicitudes presentadas una toma decisión definitiva.
- Análisis predictivo basado en correlación: Objetivo fundamental identificando y anticipando comportamientos financieros posteriores basados en la información recolectada, generando utilidad en modelos de previsión de riesgo y fraude financiero.

1. Fundamentación de las propuestas de intervención:

Las reglas utilizadas en nuestro modelo, como las validaciones por conteo del número de formulario y sticker, análisis entre ingresos y costos, alertas entre patrimonios y retenciones, las fundamentamos en modelos financieros y tributarios que nos permitieran darnos un patron como dechow, Ge y schrand del año 2010 que son destacados con las inconsistencias sistemáticas del equilibrio financiero básico.



Líneas que proponen intervenciones que adoptan un enfoque financiero preventivo, automatizando inspecciones que dependen naturalmente del juicio humano, lo que nos permite no solamente reducir riesgos si no por el contrario reducir sesgos.

2. Aplicabilidad en Modelos

El modelo que se implementó de detección de anomalías por medio de autoenconders es una arquitectura de redes neuronales no supervisadas que nos permite aprender un patrón de comportamiento como “normal” en las transacciones por medio de la presentación de declaraciones. Según estudios revisados los autoenconders resultan ser efectivos en los entornos financieros que deben su capacidad a la identificación de de desviaciones sutiles en datos altamente dimensionales y no lineales.

Lo que fuimos complementando adicionalmente con un análisis estadístico descriptivo y correlacional que identifico asociaciones significativas entre las variables. El uso de estas técnicas apporto a nuestro modelo un sesgo robusto desde lo cuantitativo y facilito su interpretación en las visualizaciones y modelos estadísticos.

Este modelo puede implementarse por medio de los flujos de operación del riesgo crediticio en la entidad financiera supervisado por arquitectura modular lo que nos permite:

- reducción de tiempos en validación documental
- Afinar la precisión en la detección y mitigación de fraudes
- Construcción de big data para tener un modelo mas robusto que facilite la trazabilidad y en caso de auditoría.
- Ayudar a la toma de decisión final del analista respecto a la aprobación del crédito.



3. Análisis de resultados

Nuestros datos recolectados en este modelo revelaron varias alertas estructurales que identificaron casos donde el patrimonio reportado superaba los \$400.000.000, lo que según las políticas definidas de riesgo puede exigir validaciones exhaustivas o solicitud de documentación adicional para poder respaldar el origen de los datos identificados.

También identificamos que en algunas declaraciones los costos representaban más del 70% de los ingresos, indicando que su capacidad de pago puede ser disminuida y con riesgo crediticio muy alto.

Las correlaciones observadas aportaron elementos importantes y relevantes. Una fuerte relación entre ingresos y patrimonio indican que existe una sólida consistencia financiera que apalanca el crédito solicitado, lo que nos da un buen indicador aumentando la probabilidad de pago de la obligación lo que disminuye riesgo de liquidez o de cartera, sin embargo pero las desviaciones significativas si indican anomalías que deben ser revisadas indicándonos que se debe buscar un equilibrio y coherencia del perfil del cliente que nos lleva por dos caminos importantes y es determinar la falsedad del documento o soportar los datos presentados y obtenidos con los valores de la declaración de renta por medio de otras herramientas haciendo una verificación exhaustiva que nos permita aterrizar más la información presentada.

Encontramos también casos con ingresos importantes pero sus costos operacionales elevados lo que nos daba un resultado de la operación en la renta líquida muy bajo y nos ubica inmediatamente en que el cliente está inflando ingresos presentando valores no reales con su actividad llevándonos inmediatamente a la toma de decisión final para no permitir la materialización del riesgo.

Todo este conjunto de resultados apalanca importantemente la eficacia del modelo automatizado acá presentado como herramienta de apoyo en las decisiones finales al tener una interpretación financiera justificado en la evidencia cuantitativa lo que mitiga la exposición de fraude y mantiene saneada la cartera.



Es importante tener en cuenta que el modelo presentado es únicamente para la verificación del documento en este caso la declaración de renta no quiere decir que basados en el mismo se toma la decisión final del crédito, esto va acompañado del perfilamiento del cliente junto con documentos adicionales que también deben ser analizados por el validador.

Conclusiones

- La automatización del análisis documental nos generó eficiencia y aumento de la precisión en la validación crediticia.

El modelo automatizado OCR en la lectura de declaraciones de renta que extrae los datos de manera asertiva y estructurada mitigando el tiempo y reduciendo los riesgos operativos que afectan directamente la disminución de errores humanos en el proceso de aprobación.

- Por medio del análisis de las variables se identificaron patrones que tuvieron gran utilidad en la identificación de documentos adulterados e inconsistencias.

De acuerdo al análisis descriptivo se validaron valores extremos e identificando los comportamientos anormales que están lineados a la política de riesgo de la entidad. Valido los patrimonios que no tenían proporcionalidad, ni los costos operativos que junto con la renta líquida tenían coherencia, los cuales fueron identificados por el modelo generando las alertas pertinentes para lo que fue entrenado.

- El análisis correlacional generó datos valiosos que evaluaron la consistencia de la declaración de renta.

Se validaron las relaciones entre ingresos, renta líquida y patrimonio lo que indica confiabilidad en los datos, al igual que la identificación de desviación significativa de las mismas correlaciones que indicaron que el documento tenía información alterada o modificada para la aprobación del crédito, lo que afina el sistema de vigilancia del modelo para que su desarrollo sea más robusto.



- La integración de inteligencia artificial con estadística en la etapa de validación documental fortalece el modelo teniendo en cuenta que el análisis correlacional soporta objetivamente el modelo.
- La herramienta se compone de una buena base para obtener modelos predictivos mas avanzados.



Bibliografía

- Chollet, F. (2018). *Deep Learning with Python*. Manning Publications.
(Usado para fundamentar el uso de **autoencoders** con Keras y TensorFlow)

- Geron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (2nd ed.). O'Reilly Media.

(Referente técnico para el desarrollo y evaluación de modelos de **machine learning** y métricas de desempeño)

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

(Referencia conceptual sobre **redes neuronales profundas** y aprendizaje no supervisado)

- Yin, H., & Kaynak, C. (2015). Big Data for Modern Industry: Challenges and Trends. *Proceedings of the IEEE*, 103(2), 143–146. <https://doi.org/10.1109/JPROC.2015.2388958>

(Usado para justificar el **impacto de modelos inteligentes** en la industria financiera)

- Flick, U. (2015). *Introducción a la investigación cualitativa* (5ª ed.). Ediciones Morata.

(Apoya el diseño del enfoque **cualitativo y validación mediante expertos**)

- Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2014). *Metodología de la investigación* (6ª ed.). McGraw-Hill.

(Base para la **estructura metodológica**, diseño mixto, población y muestreo)

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.

(Fundamento de técnicas de **visión artificial y reconocimiento de texto en imágenes**)

- Tesseract OCR. (2023). *Tesseract Open Source OCR Engine*. <https://github.com/tesseract-ocr/tesseract>

(Referencia oficial para el uso de **OCR** en el procesamiento de declaraciones escaneadas)



- Yin, R. K. (2016). *Investigación cualitativa desde el diseño hasta la redacción* (2ª ed.). Ediciones PUV.

(Sustento para el análisis **cualitativo de entrevistas o formularios** de validación)

- ISO/IEC 25010. (2011). *Systems and Software Engineering – Systems and software Quality Requirements and Evaluation (SQuaRE) – System and software quality models.*+
- Banco Davivienda. (2023). *Lineamientos internos para la validación documental en solicitudes de crédito*. Documento interno no publicado políticas actuales 2025.
- **Dechow, P. M., Ge, W., & Schrand, C.** (2010). Understanding earnings quality: A review of the proxies, their determinants and their consequences. *Journal of Accounting and Economics*, 50(2-3), 344–401. <https://doi.org/10.1016/j.jacceco.2010.09.001>
- **Yin, H., & Kaynak, C.** (2015). Big Data for Modern Industry: Challenges and Trends. *Proceedings of the IEEE*, 103(2), 143–146. <https://doi.org/10.1109/JPROC.2015.2388958>
- **Buczak, A. L., & Guven, E.** (2016). A Survey of Data Mining and Machine Learning Methods for Cyber Security Intrusion Detection. *IEEE Communications Surveys & Tutorials*, 18(2), 1153–1176. <https://doi.org/10.1109/COMST.2015.2494502>
- **Aggarwal, C. C.** (2017). *Outlier Analysis* (2nd ed.). Springer. <https://doi.org/10.1007/978-3-319-47578-3>
- **LeCun, Y., Bengio, Y., & Hinton, G.** (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Cohen, J., Cohen, P., West, S. G., & Aiken, L. S. (2013). *Applied multiple regression/correlation analysis for the behavioral sciences* (3rd ed.). Routledge. <https://doi.org/10.4324/9780203774441>
- Dancey, C. P., & Reidy, J. (2017). *Statistics without maths for psychology* (7th ed.). Pearson Education.
- Siegel, E. (2016). *Predictive analytics: The power to predict who will click, buy, lie, or die* (2nd ed.). Wiley.



Seminario de Investigación
Especialización



- Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media.
- Wells, J. T. (2014). *Principles of fraud examination* (4th ed.). Wiley.
- Wilks, T. J., & Zimbelman, M. F. (2004). Using game theory and strategic reasoning concepts to prevent and detect fraud. *Accounting Horizons*, 18(3), 173–184.
<https://doi.org/10.2308/acch.2004.18.3.173>

