

Universidad de Buenos Aires  
Facultad de Ciencias Económicas  
Escuela de Negocios y Administración Pública

---

**MAESTRÍA EN GESTIÓN ECONÓMICA Y FINANCIERA DE  
RIESGOS**

---

TRABAJO FINAL DE MAESTRÍA

---

Probabilidad de incumplimiento para una cartera de  
consumo: árbol de decisión vs regresión logística

Probability of default for a consumer loan portfolio: decision  
tree vs logistic regression

---

AUTOR: ANDRÉS PATIÑO AZUGA

DIRECTOR: SAULO MOSTAJO CASTELÚ

SEPTIEMBRE 2023

---

## **RESUMEN EJECUTIVO**

El presente documento de investigación consiste en la aplicación de 2 modelos para medir la probabilidad de incumplimiento, específicamente para el caso de una cartera de créditos de consumo del Banco Ganadero S.A. (Bolivia).

Se identificó que el problema es la falta de un modelo estadístico para predecir la probabilidad de incumplimiento de clientes crediticios. Se utilizan 2 modelos: uno de regresión logística y otro de árbol de decisión, ambos utilizando la herramienta Python.

En el capítulo 1 se realizará la presentación del problema, junto con los antecedentes pertinentes a la investigación, la justificación de la realización de la investigación y los objetivos planteados.

En el capítulo 2 se hace referencia al marco teórico utilizado para la realización del trabajo final de grado, que incluye las bases y los fundamentos teóricos amplios que han sido utilizados para apoyar la investigación.

En el capítulo 3 se presenta la metodología de investigación utilizada para el presente trabajo, junto con la presentación de la validación de datos y sistematización de variables y el procedimiento que se ha utilizado para el desarrollo del documento.

En el capítulo 4 se encuentran las actividades y los resultados obtenidos, en este se detallan las actividades realizadas para la obtención de los resultados de ambos modelos

En el capítulo 5 se presentan las conclusiones que surgen a partir del análisis de los resultados

En el capítulo 6 se presentan las recomendaciones finales que surgen a partir del presente trabajo.

En el capítulo 7 se presenta la bibliografía utilizada para la elaboración del presente trabajo.

En el capítulo 8 se presentan los anexos del presente trabajo.

## ÍNDICE

1.	Introducción .....	5
1.1.	Historia.....	5
1.1.1.	Modelos binarios .....	5
1.1.2.	Carteras de crédito y riesgo crediticio .....	6
1.1.3.	Tiempo hasta la ocurrencia.....	7
1.2.	Problema de investigación .....	7
1.3.	Objetivo General .....	8
1.3.1.	Objetivos Específicos .....	8
1.4.	Hipótesis.....	8
1.5.	Justificación.....	9
1.5.1.	Relevancia .....	9
1.5.2.	Originalidad.....	9
1.5.3.	Interés .....	9
1.5.4.	Factibilidad.....	10
2.	Marco Teórico.....	10
2.1.	Carteras de crédito.....	10
2.2.	Tipos de Cartera Crediticia .....	13
2.2.1.	Crédito empresarial .....	13
2.2.2.	Microcrédito .....	13
2.2.2.1.	Microcrédito Individual.....	13
2.2.2.2.	Microcrédito Solidario .....	14
2.2.2.3.	Microcrédito Banca Comunal .....	14
2.2.3.	Crédito de vivienda .....	14
2.2.3.1.	Crédito hipotecario de vivienda .....	14
2.2.3.2.	Crédito de vivienda sin garantía hipotecaria .....	14
2.2.3.3.	Crédito de vivienda sin garantía hipotecaria debidamente garantizado .....	15
2.2.3.4.	Crédito hipotecario de vivienda de interés social.....	15
2.2.3.5.	Crédito de vivienda de interés social sin garantía hipotecaria.....	16
2.2.4.	Consumo.....	16
2.2.4.1.	Crédito de consumo a persona dependiente: .....	16
2.2.4.2.	Crédito de consumo a persona independiente: .....	16
2.3.	Evaluación y Calificación de Cartera Crediticia .....	17
2.4.	Alcance de la evaluación y calificación: .....	17
2.5.	Riesgo de Crédito.....	18

2.6.	Probabilidad de incumplimiento – PD .....	19
2.6.1.	<i>Scoring</i> .....	19
2.6.2.	<i>Rating</i> .....	21
2.7.	Modelos predictivos .....	22
2.7.1.	Modelo Logit.....	22
2.7.2.	Análisis de residuos.....	23
2.7.3.	Modelo de árbol de decisión .....	24
2.8.	Backtesting.....	27
2.8.1.	Matriz de Confusión.....	28
2.8.2.	Curva Característica Operativa del Receptor (ROC) y Área Bajo la Curva (AUC) .....	29
2.8.3.	Prueba de Mann-Whitney U.....	30
3.	Metodología .....	32
3.1.	Modalidad del Trabajo de Investigación.....	32
3.2.	Tipo de investigación .....	32
3.3.	Método de investigación .....	33
3.4.	Diseño de investigación .....	33
3.5.	Universo y Muestra .....	33
3.6.	Sistematización del Problema .....	34
3.7.	Variables .....	35
3.8.	Dependiente.....	35
3.9.	Independientes.....	35
4.	Resultados: .....	36
4.1.	Análisis de Datos:.....	36
4.2.	Regresión Logística:.....	41
4.3.	Análisis de Residuos: .....	43
4.4.	Modelo Árbol de Decisión: .....	45
4.5.	Backtesting:.....	47
5.	Conclusiones: .....	58
6.	Recomendaciones:.....	59
7.	Bibliografía: .....	60
8.	Anexos: .....	64
8.1.	Scripts Python: .....	64

## 1. Introducción

La estimación de las probabilidades de diferentes eventos es un objetivo primario de la estadística. Sus aplicaciones son utilizadas en diversas áreas de la ciencia como las finanzas, economía, etc. En el caso de eventos binarios, que se los considera como todo hecho de carácter puntual que puede provocar un movimiento rápido y brusco de un activo tanto al alza como a la baja, se pueden utilizar diferentes variables para medir la frecuencia de los resultados; sin embargo estas variables no definen al evento de una manera determinística. Si a este pensamiento, se le suma el hecho de tener una masa crítica (cantidad de individuos expuestos a este evento), el problema toma un aspecto más econométrico, que probabilístico.

Estudiando el caso particular del comportamiento de carteras de crédito, se tienen muchas condiciones que vuelven factible la utilización de técnicas econométricas para medir la influencia de diferentes variables explicativas en una probabilidad calculada anteriormente.

La utilización actual de modelos para evaluar diferentes carteras de crédito se basa en modelos binarios y en modelos logit. Este trabajo busca utilizar un modelo de regresión logística, uno de árbol de decisión y lograr comparar los resultados de ambos modelos.

La regulación local no exige ni provee lineamientos para realizar modelos predictivos de la probabilidad de incumplimiento, se centra en exigir y controlar la previsión genérica y específica a las instituciones financieras a través de tablas detalladas en la normativa vigente.

El COVID-19 impulso a que Gobiernos y Entes Reguladores dispongan de diferentes medidas económicas y financieras para mitigar el impacto que representaba la cuarentena y paralización de actividades a nivel mundial. En Bolivia la situación no fue distinta, y el gobierno dispuso el diferimiento y reprogramación de créditos, esto para que las personas y empresas que fueron impactadas debido a que no pudieron generar flujo debido a la paralización de actividades, dejaran de pagar las cuotas de sus créditos, imposibilitando a las entidades financieras a realizar algún cambio de calificación.

### 1.1. Historia

#### 1.1.1. Modelos binarios

Las primeras metodologías de estimación para eventos binarios se desarrollaron con aproximaciones recursivas aplicadas al estudio de enfermedades coronarias (Walker & Duncan,

1967). Pocos años después se comenzó a hacer énfasis en los métodos de máxima verosimilitud en las estimaciones (Cox, 1970). Estos dos desarrollos fundaron bases para el estudio pormenorizado de este tipo de fenómenos, que llega aún hasta nuestros días. Asimismo, las necesidades específicas de cada campo de aplicación dieron retroalimentación a los modelos y generaron nuevos desarrollos.

Se desarrollaron métodos que permiten estimar la probabilidad del evento bajo un supuesto de distribución normal de la misma (modelos probit) o bien exponencial (modelos logit o de regresión logística, indistintamente). La diferencia entre los mismos radica en la mayor facilidad de interpretación de parámetros de los modelos logísticos (Scott Long & Freese, 2001). El modelado incluye análisis multivariados, donde todas las variables independientes explican la tasa de ocurrencia del evento, y análisis bivariados donde cada variable explicativa debe tener algún tipo de relación con la tasa de ocurrencia del evento en los grupos (Bessis, 2002). En general se eligen los parámetros de manera tal que se maximice una función de verosimilitud construida a partir de las probabilidades calculadas con el modelo.

### 1.1.2. Carteras de crédito y riesgo crediticio

Una vez sentadas las bases del análisis de supervivencia, la aplicación a la medición del riesgo crediticio se fue dando de a poco y con un cierto retraso. Un trabajo de relevamiento de técnicas aplicadas en el ámbito financiero publicado hacia fines de la década del '90 (Altman & Saunders, 1998), no da aún testimonio explícito de la aplicación de modelos de hazard rate o verosimilitud parcial. Sí se deja constancia del uso de las técnicas probit y logit juntamente con técnicas de transición de estados y otras denominadas “derivación de probabilidades de incumplimiento de tipo actuarial” asociadas al incumplimiento pasado de bonos.

Los desarrollos computacionales no tardaron en llegar, y diversos softwares fueron lanzados y ampliamente utilizados para el modelado de tiempos de supervivencia (SAS Institute Inc., 1999) (Fox, 2002) (Smith & Smith).

Iniciado el nuevo milenio se fueron vislumbrando desarrollos específicos para la aplicación del análisis de supervivencia a la medición del riesgo de crédito (Saunders & Allen, 2002) (Duffie & Schaefer, 2003) (Roszbach, 2003) (Bluhm, Overbeck, & Wagner, 2003). Todos estos desarrollos están basados en las premisas fundamentales del modelo de Cox & Oakes y fueron iniciadores de muchos trabajos de aplicación.

Los desarrollos posteriores en el campo del riesgo crediticio llevaron naturalmente a la necesidad de incorporar variables macroeconómicas. Es decir, una vez evaluado un cliente mediante un scoring, pueden cambiar las condiciones macroeconómicas que se tuvieron en cuenta en el momento de evaluación. El análisis de supervivencia permite incorporarlas como variables que afectan la estimación con posterioridad a la evaluación. Esto no es fácilmente realizable con los modelos de regresión logísticos (Bellotti & Crook, 2007).

### 1.1.3. Tiempo hasta la ocurrencia

Desarrollos posteriores al análisis de datos binarios (Cox & Oakes, 1984) llevaron a esbozar no sólo el modelado de una probabilidad de evento, sino también del tiempo que transcurre hasta que dicho evento sucede. Este tipo de análisis es fundamental para el control de tratamientos médicos. También lo es para el objeto de estudio de este trabajo, que es la gestión de una cartera con riesgo crediticio. La construcción de este tipo de modelos sienta sus pilares fundamentales en los análisis bivariados y multivariados, pero no se analiza la tasa de ocurrencia sino el tiempo de permanencia de los individuos en la cartera sin incurrir en incumplimiento, es decir el tiempo de “supervivencia”. Existirán entonces observaciones censuradas, ya que para una parte de la población en cuestión no ocurrirá el evento, o bien ya ha ocurrido una vez iniciado el período de observación. El concepto fundamental para modelar va a ser entonces el denominado *hazard rate* o tasa instantánea de salida de los individuos. El análisis propuesto por Cox & Oakes se denomina verosimilitud parcial, ya que no se maximiza la probabilidad de ocurrencia de la muestra, sino una función que puede interpretarse como una verosimilitud relativa de la intensidad de salida de un grupo respecto del grupo que sobrevivió hasta el instante anterior. Dicha función para maximizar se denomina función de verosimilitud parcial.

## 1.2. Problema de investigación

En la actualidad, la práctica más utilizada a la hora de realizar modelos estimativos de probabilidad de incumplimiento es mediante el modelaje de una variable binaria a través de modelos logísticos. Esto significa que se observa el comportamiento de pago del individuo y se lo clasifica con una marca de incumplimiento que puede tomar valor 0, en el caso de no haber incumplimiento, o 1 en el caso de ocurrir incumplimiento. En general, dichos modelos son calibrados en un momento específico, y se realizan seguimientos periódicos. No habrá diferencia en la probabilidad de incumplimiento o PD estimada de dos individuos idénticos en

el inicio de la implementación o años después. Sin embargo, durante un auge económico o un mejoramiento en las condiciones sistémicas es de esperarse un mejoramiento generalizado de la capacidad de pago de los individuos. En épocas de recesión o de empeoramiento de las condiciones del sistema financiero, se espera que esa capacidad se deteriore. Surge naturalmente la siguiente pregunta: ¿En qué magnitud un modelo de árbol de decisión mejorara la estimación de la probabilidad de incumplimiento de una cartera de consumo?

### 1.3. Objetivo General

Desarrollar un modelo de árbol de decisión para mejorar la estimación de la probabilidad de incumplimiento en una cartera de consumo y validar mediante backtesting.

#### 1.3.1. Objetivos Específicos

- Objetivo específico 1: Seleccionar la base de datos relevante para la cartera de crédito a estudiar.
- Objetivo específico 2: Elegir las variables sistémicas económica y estadísticamente relevantes para añadir al modelo.
- Objetivo específico 3: Estimar la PD utilizando un modelo logit.
- Objetivo específico 4: Estimar la PD utilizando un modelo de árbol de decisión.
- Objetivo específico 5: Modelar y comparar los resultados de ambos modelos.

### 1.4. Hipótesis

Se define la hipótesis de este trabajo como: Desarrollar un modelo de árbol de decisión mejora la estimación de la probabilidad de incumplimiento en una cartera de consumo.

Esta hipótesis se basa en la premisa de que el modelo de árbol de decisión, al ser evaluado a través de un backtesting, permitirá obtener resultados más precisos y confiables en la estimación de la probabilidad de incumplimiento en una cartera de consumo.

Hipótesis nula: No hay diferencia significativa en la estimación de la probabilidad de incumplimiento de una cartera de consumo, al utilizar un modelo de árbol de decisión y realizar un backtesting.



Hipótesis alternativa: Existe una diferencia estadísticamente significativa en la estimación de la probabilidad de incumplimiento de una cartera de consumo, al utilizar un modelo de árbol de decisión y realizar un backtesting.

La hipótesis nula plantea que no hay diferencia entre el modelo de árbol de decisión en la estimación de la probabilidad de incumplimiento y realizar el backtesting. En contraste, la hipótesis alternativa sugiere que sí existe una diferencia significativa en la estimación al utilizar este modelo y realizar el backtesting.

## 1.5. Justificación

Todo analista de riesgo crediticio requiere estimar lo mejor posible la probabilidad de incumplimiento de su cartera de créditos. En periodos de auge económico o un mejoramiento en las condiciones sistémicas, es de esperarse un mejoramiento generalizado de la capacidad de pago de los individuos. En épocas de recesión o de empeoramiento de las condiciones del sistema financiero, se espera que esa capacidad se deteriore. Esto lleva al constante seguimiento de la modelización de la probabilidad de incumplimiento.

### 1.5.1. Relevancia

Implementar un modelo de supervivencia a una cartera de crédito ayudara a crear otra alternativa de modelización de la probabilidad de incumplimiento y por ende, del riesgo crediticio. Permitiendo a la gestión de riesgos otro enfoque relevante para la toma de decisiones.

### 1.5.2. Originalidad

Si bien la probabilidad de incumplimiento y el riesgo crediticio son temas bastante estudiados en el ámbito financiero, es muy poco lo que se estudia o se desarrolla acerca de nuevos modelos o metodologías para una mejor calibración de este riesgo, sobretodo con las nuevas tecnologías y lo relacionado con *machine learning*.

### 1.5.3. Interés

El interés en el desarrollo del tema surgió debido a las diferentes maneras de gestionar el riesgo crediticio, más específicamente, la probabilidad de incumplimiento, expuestas las materias dentro de la Maestría en Gestión Económica y Financiera de Riesgos, lo cual genero interés y curiosidad para realizar la investigación sobre modelos aplicables a carteras de crédito locales.

#### 1.5.4. Factibilidad

Los recursos humanos, materiales y técnicos se encuentran disponibles para iniciar el estudio y concluir con la presente investigación, por lo tanto, se considera factible la realización de este, asimismo se considera que el tiempo disponible es apropiado para que esta investigación alcance un nivel adecuado de integridad y refinamiento.

## 2. Marco Teórico

### 2.1. Carteras de crédito

Una cartera de préstamos es un conjunto de créditos y financiamientos que los bancos, compañías de inversión o incluso agencias del gobierno poseen o manejan. El fondo está compuesto por los documentos que amparan los activos financieros y también por operaciones a través de las cuales se financia a un tercero. El tenedor de la cartera o de los mencionados documentos se reserva el derecho de exigir las obligaciones descritas en el texto. Las carteras de crédito son un activo, pues generan ingresos recurrentes derivados de los pagos de los préstamos. La cartera de préstamos de un banco es la suma de las cuantías entregadas a los acreditados más los intereses ganados y no cobrados.

Una cartera de crédito normalmente está compuesta por varios tipos de préstamos como los préstamos comerciales, las líneas de crédito de capital y préstamos hipotecarios.

Clasificación de las carteras de crédito

Existen dos grandes clasificaciones de las carteras de crédito:

- 1) Según la naturaleza de sus activos.
- 2) Según el nivel de endeudamiento.

Un préstamo al consumo es un tipo de operación económica dirigida a promover la financiación de una gran variedad de bienes por parte de los individuos. con él.

Con la mejoría de las condiciones de vida en las últimas décadas y el aumento progresivo de la renta per capita, los individuos han ido a su vez aumentando su deseo de consumo de bienes de más valor.

Este hecho ha ayudado a que en un momento dado se planteen la adquisición de bienes relacionados con su ocio, sus gustos, su educación, etc. Por medio de la intermediación de las entidades financieras han surgido gran número de posibilidades como el préstamo al consumo.

En muchas ocasiones este tipo de préstamo no es solamente ofrecido por una entidad financiera o bancaria al uso, sino que grandes compañías desarrollan un modelo de venta a préstamos de consumo, posibilitando a sus clientes los pagos de sus compras en un periodo de tiempo y un número de cuotas. El importe a percibir por parte del prestatario no es normalmente elevado, como sucede por ejemplo en la compra de viviendas o vehículos. En comparación con otros tipos de préstamo, los intereses relativos a esta modalidad suelen ser altos. Los requisitos para el acceso a estos no son tan estrictos como para la financiación inmobiliaria. Su formalización por escrito y la definición de sus cláusulas es similar al de un préstamo bancario tipo. Con la evolución de los tipos de productos financieros y de préstamo en el mercado en los últimos años, han aparecido diversas modalidades dirigidas a la financiación de bienes de consumo.

En ese sentido, son ejemplos para destacar los microcréditos y micropréstamos que facilitan la consecución de una determinada cantidad de dinero en muy corto plazo y de forma muy accesible. Es decir, útiles para desembolsos de objetos de consumo de cierto valor.

El análisis de los diferentes tipos de riesgo que afronta un sistema financiero es de vital importancia para la sostenibilidad de este y para el desarrollo de una economía. En el caso del riesgo de crédito, es de vital importancia estimar la probabilidad de que las empresas que tienen obligaciones contractuales con los bancos incumplan con los pagos durante un determinado período. Una definición de riesgo de crédito es: “la posibilidad de que una entidad incurra en pérdidas y se disminuya el valor de sus activos, como consecuencia de que sus deudores fallen en el cumplimiento oportuno o cumplan imperfectamente los contratos de crédito”<sup>1</sup>

El Sistema Financiero desempeña un papel clave y opera como un intermediario entre las personas naturales e instituciones que disponen de suficiente dinero y aquellas que requieren de recursos monetarios suficientes para ejecutar proyectos de inversión en el mercado y así impulsar la actividad económica. Además, se puede considerar como tradicional al focalizar sus funciones de intermediación en cartera e inversiones; esto hace que el riesgo de crédito sea muy

---

<sup>1</sup> (Superintendencia del Sistema Financiero Colombiano, 2002)

importante. Una de las funciones de intermediación que cumple el sistema monetario en una economía, es recibir los excedentes de liquidez de los agentes superavitarios y que los coloca en forma de contratos de crédito a los agentes deficitarios, lo cual involucra riesgos, en especial el riesgo crediticio. Si este tipo de riesgo se llega a materializar, puede ser resultado de una crisis financiera, que deriva en pérdidas económicas. El papel de los agentes intermediarios es importante en economías en desarrollo, en el que el mercado financiero depende principalmente del bancario, tal como lo señala un estudio realizado por el Banco Interamericano de Desarrollo<sup>2</sup> en el que sostiene: “(...) los países desarrollados cuentan con los mercados financieros más desarrollados en todas sus dimensiones y poseen mercados de capital que pueden complementar y en algunos casos sustituir al crédito bancario”; mientras que los países en vías de desarrollo se han caracterizado por no tener un nivel de actividad económica lo suficientemente alto. La mayoría de los activos colocados en el sistema financiero se debe, principalmente, a los establecimientos de crédito; esto hace que las firmas recurran a este tipo de instituciones para obtener recursos monetarios y así poder desarrollar proyectos de inversión en el mercado.

Por lo descrito anteriormente, el riesgo crediticio es uno de los más importantes que enfrenta el sistema financiero, por lo que debe medirse de manera eficiente, monitoreado y de acuerdo con las características actuales de la economía. En este sentido, el objetivo general es proponer una metodología para estimar el riesgo de incumplimiento. El desarrollo del proyecto de investigación está enfocado hacia tres objetivos: primero identificar las variables que son determinantes en la estimación de la probabilidad de incumplimiento, puesto que estas variables pueden operar como indicadores de alerta temprana ante cambios en la situación financiera de las firmas y ante variaciones de indicadores de crecimiento económico del país, obteniendo así una herramienta fundamental en el análisis de políticas de crédito.

Para la estimación de los modelos de riesgo de crédito, se utiliza como técnica de contraste los modelos logísticos ordenados generalizados con variables explicativas que contienen información de indicadores financieros de garantía, ingresos, egresos comportamiento de pago.

---

<sup>2</sup> (BID, 2005)

La Recopilación de normas para Bancos y Entidades Financieras de Bolivia, define 2 tipos de créditos<sup>3</sup>:

- Créditos individuales: créditos que, por su naturaleza, deben ser evaluados sobre la base de características propias de cada deudor utilizando sus metodologías, mismas que deberán capturar la esencia de este tipo de créditos.
- Créditos masivos: créditos que, por su naturaleza, pueden ser evaluados en forma grupal utilizando metodologías que agrupen deudores con características relevantes similares desde el punto de vista del riesgo.

## 2.2. Tipos de Cartera Crediticia

### 2.2.1. Crédito empresarial

Todo crédito otorgado a una persona natural o jurídica con el objeto de financiar actividades de producción, comercialización o servicios, y cuyo tamaño de la actividad económica se encuentre clasificado en el índice de Gran Empresa.

Crédito PYME: Todo crédito otorgado a una persona natural o jurídica con el objeto de financiar actividades de producción, comercialización o servicios, y cuyo tamaño de la actividad económica se encuentre clasificado en el índice de Mediana Empresa y Pequeña Empresa.

### 2.2.2. Microcrédito

Todo crédito otorgado a una persona natural o jurídica, o a un grupo de prestatarios, con el objeto de financiar actividades de producción, comercialización y servicios, cuya fuente principal de pago la constituye el producto de las ventas e ingresos generados por dichas actividades.

De acuerdo con la tecnología crediticia utilizada, el microcrédito puede ser clasificado como:

#### 2.2.2.1. Microcrédito Individual

Microcrédito concedido a un prestatario, sea persona natural o jurídica, con garantía o sin garantía.

---

<sup>3</sup> ASFI - 2005

#### 2.2.2.2. Microcrédito Solidario

Microcrédito concedido a un grupo de prestatarios, conformado por personas naturales, con garantía mancomunada o solidaria.

#### 2.2.2.3. Microcrédito Banca Comunal

Microcrédito sucesivo y escalonado concedido a una agrupación de personas organizadas en al menos dos (2) grupos solidarios, con garantía mancomunada, solidaria e indivisible; para obtener además del microcrédito servicios complementarios con el fin de lograr el desarrollo humano y económico de sus asociados.

#### 2.2.3. Crédito de vivienda

Todo crédito otorgado a personas naturales destinado exclusivamente para: Adquisición de terreno para la construcción de vivienda, Compra de vivienda individual o en propiedad horizontal, Construcción de vivienda individual o Refacción, remodelación, ampliación, mejoramiento de vivienda individual o en propiedad horizontal, según corresponda.

##### 2.2.3.1. Crédito hipotecario de vivienda

Todo crédito otorgado a personas naturales destinado exclusivamente para:

- Adquisición de terreno para la construcción de vivienda
- Compra de vivienda individual o en propiedad horizontal
- Construcción de vivienda individual
- Refacción, remodelación, ampliación, mejoramiento de vivienda individual o en propiedad horizontal

El crédito hipotecario de vivienda se limita a una primera o segunda vivienda de propiedad del deudor, ocupada o dada en alquiler por el deudor propietario. Asimismo, la garantía debe ser la misma del destino del crédito. No comprende los créditos destinados a financiar viviendas que no tengan las características anteriores o con fines comerciales, ni otros tipos de créditos amparados con garantía hipotecaria.

##### 2.2.3.2. Crédito de vivienda sin garantía hipotecaria

Crédito otorgado a personas naturales destinado exclusivamente para:

- Construcción de vivienda individual.
- Refacción, remodelación, ampliación, mejoramiento de vivienda individual o en propiedad horizontal.
- Anticrético de vivienda

Se debe contar con una tecnología crediticia adecuada para otorgar y monitorear este tipo de créditos.

#### 2.2.3.3. Crédito de vivienda sin garantía hipotecaria debidamente garantizado

Crédito otorgado a personas naturales destinado exclusivamente para:

- Construcción de vivienda individual.
- Refacción, remodelación, ampliación, mejoramiento de vivienda individual o en propiedad horizontal.

De acuerdo con la tecnología crediticia utilizada, el mismo puede ser clasificado como:

- Crédito de vivienda sin garantía hipotecaria debidamente garantizado otorgado a una persona independiente. Es todo crédito de vivienda sin garantía hipotecaria debidamente garantizado concedido a una persona natural no asalariada, con garantía personal.
- Crédito de vivienda sin garantía hipotecaria debidamente garantizado otorgado a una persona dependiente. Es todo crédito de vivienda sin garantía hipotecaria debidamente garantizado concedido a una persona natural asalariada, con garantía personal.

#### 2.2.3.4. Crédito hipotecario de vivienda de interés social

Crédito otorgado a personas naturales destinado exclusivamente para:

- Adquisición de terreno con fines de construcción de vivienda;
- Compra de vivienda individual o en propiedad horizontal;
- Construcción de vivienda individual.
- Refacción, remodelación, ampliación, mejoramiento de vivienda individual o en propiedad horizontal.

Este crédito debe ser aplicado en aquella única vivienda sin fines comerciales, cuyo valor comercial o el costo final para su construcción, incluido el valor del terreno, no supere

UFV400.000.- (Cuatrocientas Mil Unidades de Fomento a la Vivienda) cuando se trate de departamento y de UFV460.000.- (Cuatrocientas Sesenta Mil Unidades de Fomento a la Vivienda) para casas.

Se consideran dentro de la presente definición, a los créditos para compra de terreno, con fines de construcción de una vivienda y sin fines comerciales, cuyo valor comercial no supere el cuarenta por ciento (40%) del valor establecido para casas, definido en el párrafo anterior.

#### 2.2.3.5. Crédito de vivienda de interés social sin garantía hipotecaria

Crédito otorgado a personas naturales destinado exclusivamente para:

- Construcción de vivienda individual;
- Refacción, remodelación, ampliación, mejoramiento de vivienda individual o en propiedad horizontal;
- Anticrético de vivienda.

La EIF debe contar con una tecnología crediticia adecuada para otorgar y monitorear este tipo de créditos.

#### 2.2.4. Consumo

Todo crédito concedido a una persona natural, con el objeto de financiar la adquisición de bienes de consumo o el pago de servicios, amortizable en cuotas sucesivas y cuya fuente principal de pago es el salario de la persona o ingresos provenientes de su actividad, adecuadamente verificados. Esta definición incluye las operaciones realizadas a través del sistema de tarjetas de crédito de personas naturales. De acuerdo con la tecnología crediticia utilizada por la EIF el mismo puede ser clasificado como:

##### 2.2.4.1. Crédito de consumo a persona dependiente:

Es todo crédito de consumo concedido a una persona natural asalariada.

##### 2.2.4.2. Crédito de consumo a persona independiente:

Es todo crédito de consumo concedido a una persona natural no asalariada.



### 2.3. Evaluación y Calificación de Cartera Crediticia

De acuerdo con la normativa, En los créditos de consumo y microcréditos debe darse especial importancia a la política que la EIF emplee para la otorgación de este tipo de crédito, la cual debe considerar aspectos relacionados con: la selección de los prestatarios, la determinación de la capacidad de pago del deudor y la estabilidad de la fuente de sus ingresos, sean éstos por ventas de productos o prestación de servicios, según corresponda, adecuadamente verificados.

Los microcréditos deben ser evaluados y calificados según lo siguiente:

- Categoría A Se encuentran al día o con una mora no mayor a 5 días.
- Categoría B Se encuentran con una mora entre 6 y 30 días.
- Categoría C Se encuentran con una mora entre 31 y 55 días.
- Categoría D Se encuentran con una mora entre 56 y 75 días.
- Categoría E Se encuentran con una mora entre 76 y 90 días.
- Categoría F Se encuentran con una mora mayor a 90 días.

### 2.4. Alcance de la evaluación y calificación:

La Recopilación de normas para Bancos y Entidades Financieras de Bolivia establece que las Entidades Financieras deberán evaluar permanentemente al total de su cartera de créditos, incluidos los activos contingentes que puedan materializar un riesgo de crédito en el futuro.

Cada entidad deberá determinar las metodologías para evaluar y calificar a sus deudores, con base en sus políticas y procedimientos de gestión de riesgos. Tales metodologías podrán basarse en fundamentos matemáticos, estadísticos o de otra naturaleza, que permitan alcanzar el objetivo global de gestionar eficientemente el riesgo de crédito en cartera.

Sobre la base de las metodologías estimarán el monto a provisionar, a través de la estimación de la pérdida esperada. La pérdida esperada está compuesta por la probabilidad de incumplimiento (*PD*), la pérdida dado el incumplimiento (*LGD*) y la exposición al momento del incumplimiento (*EAD*).<sup>4</sup>

---

<sup>4</sup> Altman, E. I. (2017)

Cada entidad deberá adoptar metodologías sustentadas en las mejores prácticas de gestión del riesgo de crédito, pudiendo utilizar información externa, interna o una combinación de ambas, según lo establezca su metodología y que sean adecuadas a la naturaleza de su negocio y contribuyan eficientemente al logro de los objetivos de largo plazo.

Dentro del proceso de gestión del riesgo de crédito, deben considerarse pruebas constantes y periódicas que permitan medir la eficiencia del modelo a través del contraste entre los resultados.

## 2.5. Riesgo de Crédito

Se entiende como riesgo de crédito a la posibilidad de sufrir pérdidas por el incumplimiento que un deudor o contraparte hace de sus obligaciones contractuales. El riesgo de crédito está presente en las operaciones dentro y fuera de balance. También está presente en el riesgo de liquidación, es decir cuando una transacción financiera no pueda completarse o liquidarse según lo pactado.

Las pérdidas por riesgo de crédito se originan por el incumplimiento del deudor o contraparte de sus obligaciones y su magnitud depende básicamente de dos factores <sup>5</sup>:

- i) El monto de la exposición en el momento del incumplimiento; y
- ii) Los recuperos obtenidos por las entidades, constituidos por los pagos que se obtengan del deudor y por la ejecución de los mitigadores de riesgo -como por ejemplo, las garantías o los derivados crediticios- que respaldan la operación crediticia, limitando la severidad de las pérdidas.

Una cartera crediticia es un subconjunto de la totalidad de financiaciones de una entidad que se obtiene a partir de algún proceso de partición o segmentación que las agrupa en función de características comunes, de los deudores o de sus deudas. El riesgo de crédito contempla distintos tipos de riesgos. Entre ellos incluye el riesgo país y el riesgo de crédito de contraparte.

Se entiende por riesgo país al riesgo de sufrir pérdidas generadas en inversiones y créditos a individuos, sociedades y gobiernos por la incidencia de acontecimientos de orden económico, político y social acaecidos en un país extranjero.

---

<sup>5</sup> Crouhy, M., Galai, D., & Mark, R. (2006)

Por su parte, el riesgo de crédito de contraparte es el riesgo de que una de las partes de la operación incumpla su obligación de entregar efectivo o los efectos acordados –tales como títulos valores, oro o moneda extranjera- ocasionando una pérdida económica si las operaciones -o cartera de operaciones con la contraparte- tuvieran un valor económico positivo en el momento del incumplimiento. A diferencia del riesgo de crédito por préstamos, que sólo es asumido por la entidad financiera acreedora, este tipo de riesgo de crédito conlleva una pérdida potencial para ambas partes de la operación, ya que su valor de mercado puede ser positivo o negativo para cualquiera de ellas en virtud de que ese valor es incierto y puede oscilar según varíen los factores de mercado subyacentes.

Existen 3 parámetros utilizados para medir el riesgo de crédito:

- i) Probabilidad de Incumplimiento o PD por sus siglas en ingles.
- ii) Exposición al riesgo o EAD por sus siglas en ingles.
- iii) Perdida dado el incumplimiento o LGD por sus siglas en ingles.

## 2.6. Probabilidad de incumplimiento – PD

La PD es una medida de calificación crediticia que se otorga a un cliente o a un contrato con el objetivo de estimar su probabilidad de incumplimiento a un año vista <sup>6</sup>. El proceso de obtención de la PD se realiza a través de herramientas de *scoring* y de *rating*.

### 2.6.1. *Scoring*

Es un instrumento estadístico focalizado en la estimación de la probabilidad de incumplimiento en función de características propias del binomio contrato-cliente y están enfocadas a la gestión de créditos de tipo retail: consumo, hipotecas, tarjetas de crédito de particulares, préstamos a negocios, etc. Existen diferentes tipos de scoring: reactivos, de comportamiento, proactivos y de bureau.

Los *scorings* reactivos tienen como principal objetivo pronosticar la salud crediticia de las solicitudes de crédito realizadas por los clientes y tratan de predecir la morosidad de los solicitantes, en caso de que la operación fuera concedida.

---

<sup>6</sup> Merton, R. C. (1974)

La sofisticación de los *scorings* y su capacidad de adaptación al contexto económico está permitiendo enfocar cada vez más las herramientas al perfil de los clientes, mejorando la capacidad de identificar diferentes calidades crediticias dentro de colectivos concretos (jóvenes, clientes, etc.). El resultado es un elevado ajuste de la capacidad discriminadora de las herramientas en colectivos de especial relevancia en el negocio.

Una característica de los *scorings* reactivos es la convergencia de las tasas de incumplimiento de los diferentes segmentos a medida que pasa el tiempo <sup>7</sup>.

Los *scorings* de comportamiento evalúan contratos ya concedidos incorporando la información de comportamiento del cliente y del propio contrato. A diferencia del *scoring* reactivo, es un análisis a posteriori, esto es, una vez concedido el contrato. Se utilizan para realizar revisiones en los límites de las tarjetas, seguimiento del riesgo, etc., y tienen en cuenta variables propias de la operación y del cliente disponibles internamente: comportamiento que ha tenido un determinado producto en el pasado (retrasos en pagos, mora, etc.) y comportamiento general del cliente con la entidad (saldo medio en cuentas, recibos domiciliados, etc.)

Los *scorings* proactivos tienen en cuenta las mismas variables que los de comportamiento, pero varían en su finalidad, ya que éstos ofrecen una calificación del cliente en su conjunto, no de una operación concreta. Esta visión de cliente se complementa con adaptaciones a cada tipología de producto. Los *scorings* proactivos disponibles en el Grupo permiten un mayor seguimiento del riesgo de los clientes, una mejora en los procesos de admisión de riesgo y una gestión más activa de la cartera, como es la realización de ofertas de crédito adaptadas al perfil de riesgo de cada cliente.

Adicionalmente, tienen una importancia muy significativa los llamados *scorings* de bureau, de uso muy extendido en América. Este tipo de herramienta se asemeja a los *scorings* anteriormente mencionados, con la diferencia de que éstos utilizan la información interna del propio banco para su construcción, mientras que los *scorings* de bureau requieren el aporte de información crediticia del resto de instituciones o bancos (sobre el incumplimiento o sobre el comportamiento del cliente). Para obtener esta información existen agencias crediticias de referencia que se encargan de recopilar los datos del resto de entidades. No todos los bancos

---

<sup>7</sup> Baesens, B., Roesch, D., & Scheule, H. (2017)

colaboran facilitando esta información, y, generalmente, sólo las entidades que participan pueden disponer de la misma.

Una gestión adecuada de las herramientas reactivas, comportamentales, proactivas y de bureau por parte del Grupo facilita la obtención de parámetros de riesgo actualizados y adaptados a la realidad económica. Ello se traduce en un conocimiento preciso de la salud crediticia de las operaciones/clientes. Esta tarea adquiere especial relevancia en la coyuntura actual, ya que permite identificar los contratos o clientes que atraviesan por dificultades y, de este modo, poder tomar las medidas necesarias con el fin de gestionar los riesgos ya asumidos.

### *2.6.2. Rating*

Estas herramientas están enfocadas a la calificación de clientes mayoristas: empresas, corporaciones, pymes, administraciones públicas, etc., en las que el incumplimiento que se predice es a nivel del cliente en lugar de ser a nivel contrato.

La información proporcionada por las herramientas de rating se utiliza de cara a la admisión de operaciones, así como para la revisión de límites. Entre las carteras mayoristas, se gestiona carteras denominadas como de bajo incumplimiento, en las que existen pocos incumplimientos (riesgos soberanos, corporaciones, etc.). Para obtener las estimaciones de PD en estas carteras se complementa la información interna con información externa, principalmente proporcionada por agencias de calificación crediticia y bases de datos de proveedores externos <sup>8</sup>.

Una métrica relevante de cara a la correcta gestión del riesgo es la probabilidad de incumplimiento media a lo largo de un ciclo económico, ya que es una medida que ayuda a atenuar los efectos de las turbulencias económico-financieras en la medición del riesgo de crédito, como por ejemplo la volatilidad del capital.

La probabilidad de incumplimiento varía con el ciclo, siendo mayor en períodos de recesión y menor en períodos de bonanza. Al proceso de ajuste con el fin de trasladar las tasas de incumplimiento observadas empíricamente a tasas de incumplimiento medias de ciclo se le conoce como ajuste a ciclo. En el ajuste a ciclo se emplean series económicas suficientemente largas relacionadas con el incumplimiento de las carteras y se compara su comportamiento con el de los incumplimientos de las carteras de la Entidad. Adicionalmente, se puede tener en cuenta

---

<sup>8</sup> Fitch Ratings. (2019)

las diferencias que pueda haber entre el ciclo económico pasado y el futuro, lo que dotaría al enfoque de un componente prospectivo.

## 2.7. Modelos predictivos

Existen varios modelos predictivos construidos y utilizados a lo largo del tiempo por parte de las Entidades Financieras; sin embargo, el más utilizado en la práctica debido a su capacidad de predicción es el modelo Logit.

A partir de la aparición y el crecimiento del sector de la inteligencia artificial, comenzaron a salir otros modelos que tratan de predecir la probabilidad de incumplimiento utilizando las nuevas herramientas, es por esta razón que en el último tiempo se está comenzando a utilizar modelos de árboles de decisión para la clasificación de las variables al momento de predecir la probabilidad de incumplimiento. Estos dos modelos serán expuestos a continuación:

### 2.7.1. Modelo Logit

Los modelos dedicados para predecir el incumplimiento o el cumplimiento incluyen la probabilidad lineal y los modelos Logit y Probit son los más adecuados. Estos modelos usan la técnica de regresión multivariante. Las variables explicativas son los atributos observables. El modelo de probabilidad lineal simple ilustra el principal. La probabilidad P del evento, incumplimiento o no incumplimiento, es una función lineal de varios atributos  $X_i$ <sup>9</sup>. La variable explicada es Y, que toma los valores 0 por no incumplimiento y 1 por incumplimiento. Si X es el vector de atributos, el modelo es:

$$Y = \beta_0 + \sum_{i=1,n} \beta_i X_i + \varepsilon$$

La expectativa de Y es la probabilidad de incumplimiento P (Y=1), dado que:

$$E(Y) = 1P(Y = 1) + 0[1 - P(Y = 0)]$$

Si se quita la expectativa de la ecuación, y se otorga una expectativa de para el error de la regresión:

---

<sup>9</sup> Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013)

$$P(Y = 1) = \alpha + \beta E(X)$$

El modelo proporciona el valor de la probabilidad predeterminada como una función del vector de atributos X. Sin embargo, la regresión lineal proporciona coeficientes tales que los valores de Y, dada los valores X, no necesariamente se encuentran dentro del rango de 0 a 1. Los valores modelados de Y deben ser removidos para evitar tales valores atípicos. El modelo Logit evita este inconveniente. El modelo Logit resuelve el problema de imponer que Y esté en el rango de valores [0,1]. La variable Y se expresa nuevamente como una función lineal de los atributos  $X_i$ ,  $Y = \alpha + \beta X + \epsilon$ . Pero, en lugar de asignar directamente Y a una probabilidad, el modelo Logit usa Y como argumento de una función de distribución acumulativa F (Y). La función acumulativa tiene valores entre 0 y 1 e incrementa monótonamente. Un valor de la función acumulativa se asigna a un solo valor de Y, y cualquier valor de Y corresponde a una probabilidad usando una función de distribución conocida.

El modelo Logit utiliza para F (Y) la distribución de probabilidad logística acumulativa. La probabilidad P (Y) se expresa como:

$$P(Y) = \frac{1}{[1 + \exp(-Y)]} = \frac{1}{\{1 + \exp[-(\alpha + \beta X + \epsilon)]\}}$$

La regresión logística asume una relación lineal entre las variables independientes y la variable dependiente en el logaritmo de las probabilidades, lo que puede no ser cierto en todos los casos, para verificar esta relación se realiza un análisis de los residuos.

### 2.7.2. Análisis de residuos

El análisis de residuos es una parte fundamental del proceso de modelado estadístico y se utiliza para evaluar la calidad del ajuste de un modelo a los datos. Los residuos son las diferencias entre los valores observados y los valores predichos por el modelo. El análisis de residuos es importante porque proporciona información sobre cómo el modelo se ajusta a los datos y si los supuestos del modelo se cumplen. Se pueden utilizar los siguientes gráficos para analizar los residuos:

- Gráfico de dispersión de residuos vs. valores ajustados: Este gráfico muestra la dispersión de los residuos de la respuesta en función de los valores ajustados por el

modelo. Idealmente, se espera ver una distribución aleatoria de los puntos alrededor de la línea de referencia en  $y=0$ . Si los puntos están concentrados en una región o siguen algún patrón específico (como una forma de U), podría indicar que el modelo tiene dificultades para capturar ciertos patrones en los datos.

- Histograma de residuos: Muestra la frecuencia de los diferentes valores de residuos. Si los residuos siguen una distribución normal alrededor de cero, el histograma debería ser aproximadamente simétrico y en forma de campana. Desviaciones significativas de la normalidad podrían sugerir problemas con la adecuación del modelo<sup>10</sup>.
- Gráfico Q-Q de los residuos: El gráfico Q-Q (*quantile-quantile*) compara la distribución de los residuos con una distribución teóricamente normal. Si los puntos siguen aproximadamente una línea diagonal, eso indica que los residuos se distribuyen de manera cercana a una distribución normal. Desviaciones de la línea diagonal pueden indicar desviaciones de la normalidad.

### 2.7.3. Modelo de árbol de decisión

La construcción del árbol comienza en el nodo madre, este incluye todos los registros de datos. A partir del nodo madre, se pasa a buscar la variable más adecuada para partirlo en 2 nodos, considerados como nodos hijos. Para elegir la mejor variable debe utilizarse una medida de pureza en la valoración de los 2 nodos hijos posibles (la variable que consigue una mayor pureza se convierte en la utilizada en primer lugar, y así sucesivamente). Debe buscarse una función de partición que asegure que la pureza en los nodos hijos sea la máxima <sup>11</sup>. Una de las funciones más utilizadas es la denominada Gini (se alcanza un índice de pureza que se considera como máximo).

El índice de Gini en el nodo  $t$ ,  $g(t)$ , se puede formular del modo siguiente:

$$g(t) = \sum_{j \neq i} p(j/t) p(i/t)$$

donde  $i$  y  $j$  son las categorías de la variable predictora y  $p$  es proporción.

---

<sup>10</sup> (Samprit Chatterjee & Ali S. Hadi – 2006)

<sup>11</sup> (Trujillano, Sarria Esquerda, Badia, Palma, March – 2008)



La función de criterio  $\Phi(s,t)$  para la división  $s$  en el nodo  $t$  se define como:

$$\Phi(s,t) = g(t) - p_L g(t_L) - p_R g(t_R)$$

donde  $p_L$  es la proporción de casos de  $t$  enviados al nodo hijo de la izquierda, y  $p_R$  al nodo hijo de la derecha.

Cuando se comienza en el nodo raíz  $t = 1$  (y también en las particiones sucesivas), se busca la división  $s^*$ , de entre todas las posibles de  $S$ , que de un valor con mayor reducción de la impureza:

$$\Phi(s^*, 1) = \max_{s \in S} \Phi(s, 1)$$

Luego se divide el nodo 1 en 2 nodos hijos ( $t = 2$  y  $t = 3$ ) utilizando la división  $s^*$ . Este valor de la función de impureza, ponderado por la proporción de todos los casos del nodo  $t$ , es el valor del que se informa en el árbol como «mejora».

En el proceso sucesivo de crecimiento del árbol se debe asignar una clase (etiqueta) a cada nodo. El procedimiento de asignación de clase debe hacerse por medio de una función de asignación, en la que se tiene en cuenta la probabilidad a priori asignada a cada clase (según la base de datos empleada), la pureza de la partición y la proporción final de casos que aparecen en los nodos hojas. Al igual que puede determinarse la pureza para un nodo concreto, puede evaluarse de forma conjunta para todo el árbol.

El crecimiento de un árbol continúa hasta que se produce cualquiera de estas 3 posibilidades: sólo hay una observación (caso) en cada nodo hoja, todas las observaciones tienen la misma probabilidad asignada en los nodos hoja (es imposible determinar el criterio de máxima pureza), o se ha fijado un límite externo de la profundidad (número de niveles máximo) del crecimiento del árbol. El árbol que se ha generado de esta forma clasifica correctamente los registros utilizados en su proceso de aprendizaje (se dice que este «sobreadaptación» se obtiene porque el modelo ha «sobreajustado» los datos empleados en esta fase), pero cuando se enfrente a nuevos registros no se asegura su capacidad de generalización <sup>12</sup>.

---

<sup>12</sup> (Trujillano, Sarria Esquerda, Badia, Palma, March – 2008)

El árbol complejo que se ha creado debe simplificarse para que alcance esta capacidad de generalización. Se utiliza un método de poda de árbol. La poda asegura que sólo se retiren los nodos que incrementan muy poco la precisión del árbol. Se utiliza una medida de coste-complejidad (que combina los criterios de precisión frente a complejidad en el número de nodos y velocidad de procesamiento), buscando el árbol que obtiene menor valor en este parámetro. Los árboles más sencillos (podados con este criterio) aseguran una mayor capacidad de generalización.

De todos los árboles podados posibles debe seleccionarse el mejor. El mejor árbol (árbol solución) será el que consigue menor error en el ajuste de los registros utilizados en su proceso de aprendizaje. Pero esta condición no es suficiente, debe ajustarse bien la base de datos utilizada en su aprendizaje, pero también debe ajustarse registros no empleados en esta fase. Para conseguir este objetivo hay diversos métodos.

El método más común (implementado en los programas de mayor utilización), que no precisa un conjunto de prueba independiente, se denomina validación cruzada. La validación cruzada es un método de remuestreo que aprovecha el total de la información disponible en la base de datos sin prescindir de una parte de sus registros.

En la validación cruzada se divide de forma aleatoria la base de datos utilizada en la fase de aprendizaje (conjunto de aprendizaje) en  $N$  partes (normalmente 10). De forma secuencial, cada uno de estos subconjuntos se reserva para emplearse como conjunto de prueba frente al modelo de árbol generado por los  $N-1$  subconjuntos restantes. Obtenemos así  $N$  modelos diferentes, donde se puede evaluar la precisión de las clasificaciones tanto en el conjunto de aprendizaje ( $N-1$ ) como en los subconjuntos de prueba ( $N$ ), y podemos seleccionar el árbol óptimo cuando la precisión se alcance tanto en uno como en otro subconjunto.

Las diferencias principales entre los distintos algoritmos de construcción de árboles de decisión radican en las estrategias de poda y en la regla adoptada para partir los nodos.

## 2.8. Backtesting

El backtesting es un proceso utilizado en finanzas y en el campo de la modelación, para evaluar el rendimiento histórico de una estrategia de inversión o de un modelo financiero <sup>13</sup>. El marco teórico para el backtesting implica la comprensión de los conceptos clave relacionados con este proceso, así como los métodos y técnicas utilizados. Se siguen las siguientes directrices para la realización de un backtesting:

- a) **Definición del backtesting:** El backtesting es la simulación de una estrategia de inversión o modelo estadístico utilizando datos históricos para evaluar su rendimiento pasado. Implica aplicar la estrategia a datos antiguos y medir cómo habría funcionado en el pasado.
- b) **Selección de datos históricos:** Para realizar el backtesting, se requiere una selección adecuada de datos históricos relevantes. Esto puede incluir precios de activos, datos de clientes, datos económicos y otros factores relevantes para la estrategia o modelo en cuestión.
- c) **Construcción de la estrategia o modelo:** Se debe tener una comprensión clara de la estrategia de inversión o el modelo financiero que se va a evaluar. Esto implica definir las reglas específicas de compra y venta, indicadores técnicos, metodología de gestión de riesgos y otros elementos relevantes.
- d) **Implementación del backtesting:** Utilizando los datos históricos seleccionados y la estrategia o modelo definido, se aplican los resultados obtenidos a través de los datos del período analizado.
- e) **Evaluación del rendimiento:** Se analizan y calculan las métricas de rendimiento, como el rendimiento absoluto, el rendimiento relativo al mercado de referencia, el índice de Sharpe, la relación de ganancia-pérdida, entre otros. Esto permite evaluar y comparar el rendimiento de la estrategia o modelo con los resultados obtenidos en el pasado.
- f) **Análisis de resultados y ajustes:** Se evalúan los resultados del backtesting y se realizan ajustes en la estrategia o modelo si es necesario. Esto implica analizar las fortalezas y

---

<sup>13</sup> (Prado, R. 2018)

debilidades identificadas y realizar mejoras o modificaciones para optimizar la utilidad futura.

### 2.8.1. Matriz de Confusión

Una matriz de confusión es una representación gráfica o tabular del rendimiento de un clasificador o algoritmo de aprendizaje automático en la ciencia de datos. Las matrices de confusión pueden utilizarse para evaluar qué funciones realiza un sistema de aprendizaje automático de forma correcta e incorrecta, y así ayudar en el análisis predictivo<sup>14</sup>.

Al crear una matriz de confusión, incluya tanto los valores predictivos como los reales que pruebe en el sistema, correspondiendo cada fila a cada clase predicha y cada columna a la clase real. Dependiendo del número de salidas a las que llegue para cada entrada, la matriz de confusión puede calcular problemas de clasificación de clases múltiples o de dos clases.

La matriz organiza los datos de entrada y salida de forma que permite a los analistas y programadores visualizar la exactitud, la recuperación y la precisión de los algoritmos de aprendizaje automático que aplican a los diseños de los sistemas. En un problema de clasificación de dos clases, o binario, la matriz de confusión es crucial para determinar dos resultados, positivos o negativos, donde estas variables representan valores numéricos en un sistema de aprendizaje automático.

La matriz de confusión permite calcular diversas tasas o métricas que evalúan el rendimiento de un clasificador o modelo de aprendizaje automático. Estas tasas se derivan de los valores de la matriz de confusión y proporcionan una medida más completa del rendimiento del modelo en términos de su capacidad para clasificar correctamente las instancias positivas y negativas.

Las tasas comúnmente calculadas a partir de la matriz de confusión son:

- a) Tasa de precisión (*Accuracy*): Es el porcentaje de instancias clasificadas correctamente por el modelo, tanto positivas como negativas. Se calcula como:  $(TP + TN) / (TP + TN + FP + FN)$ .

---

<sup>14</sup> [www.historiadelaempesa.com](http://www.historiadelaempesa.com)

- b) Tasa de sensibilidad o tasa positiva verdadera (*True Positive Rate*): Es el porcentaje de instancias positivas que el modelo clasifica correctamente. Se calcula como:  $TP / (TP + FN)$ .
- c) Tasa de especificidad o tasa negativa verdadera (*True Negative Rate*): Es el porcentaje de instancias negativas que el modelo clasifica correctamente. Se calcula como:  $TN / (TN + FP)$ .
- d) Tasa de falsos positivos (*False Positive Rate*): Es el porcentaje de instancias negativas que el modelo clasifica incorrectamente como positivas. Se calcula como:  $FP / (FP + TN)$ .
- e) Tasa de falsos negativos (*False Negative Rate*): Es el porcentaje de instancias positivas que el modelo clasifica incorrectamente como negativas. Se calcula como:  $FN / (TP + FN)$ .

Estas tasas proporcionan información sobre aspectos importantes del rendimiento del modelo, como su capacidad para evitar falsos positivos y falsos negativos, su capacidad para clasificar correctamente las instancias positivas y negativas, y la precisión general de las predicciones <sup>15</sup>.

### 2.8.2. Curva Característica Operativa del Receptor (ROC) y Área Bajo la Curva (AUC)

La curva ROC (Receiver Operating Characteristic) y el AUC (Area Under the Curve) son medidas utilizadas para evaluar y comparar la capacidad predictiva de modelos de clasificación binaria.

La curva ROC es una representación gráfica de todas las matrices de confusión posibles, muestra la relación entre la tasa de verdaderos positivos (sensibilidad) y la tasa de falsos positivos (1 - especificidad) para diferentes umbrales de clasificación. En la curva ROC, el eje x representa la tasa de falsos positivos y el eje y representa la tasa de verdaderos positivos. Cada punto en la curva ROC corresponde a un umbral de clasificación diferente.

---

<sup>15</sup> (Sokolova, M., & Lapalme, G. 2009)

La curva ROC proporciona información sobre el rendimiento de un modelo de clasificación en términos de su capacidad para discriminar entre las clases. Cuanto más se acerque la curva ROC al rincón superior izquierdo del gráfico, mejor será el rendimiento del modelo. Un modelo con una curva ROC que se aproxima a la línea diagonal (45 grados) indica que el modelo tiene un rendimiento similar al azar.

El AUC es una medida numérica que resume la información contenida en la curva ROC. Representa el área bajo la curva ROC y proporciona una medida agregada de la capacidad de discriminación del modelo. El AUC varía entre 0 y 1, donde un valor de 1 indica un modelo perfecto que puede distinguir perfectamente entre las clases, mientras que un valor de 0.5 indica un modelo que tiene un rendimiento similar al azar.

En resumen, la curva ROC y el AUC son herramientas que se utilizan para evaluar y comparar modelos de clasificación en términos de su capacidad de discriminación. Proporcionan información sobre la sensibilidad y especificidad del modelo para diferentes umbrales de clasificación y resumen esta información en una medida numérica, el AUC <sup>16</sup>.

### 2.8.3. Prueba de Mann-Whitney U

La prueba de Mann-Whitney U, también conocida como U - de Mann-Whitney-Wilcoxon, es una prueba no paramétrica utilizada para comparar las diferencias entre dos muestras independientes en términos de sus ubicaciones medias. Esta prueba es adecuada cuando los datos no cumplen con los supuestos de normalidad o cuando las varianzas son heterogéneas. Es especialmente útil cuando se comparan distribuciones de datos ordinales o continuos pero no normales.

La prueba de Mann-Whitney U evalúa si las dos muestras provienen de la misma población o si hay una diferencia significativa entre ellas en términos de ubicaciones medias<sup>17</sup>. Los pasos que se siguen son:

- Ordenar y Asignar Rangos:

---

<sup>16</sup> Fawcett, T. (2006)

<sup>17</sup> David S. Moore, George P. McCabe, & Bruce A. Craig (2021)

Combinar los datos de ambas muestras y ordenar en orden ascendente. Luego, asignar rangos a los datos en función de su orden, asignando el rango más bajo al valor más pequeño, el siguiente rango al siguiente valor y así sucesivamente. En caso de empates (datos iguales), se promedian los rangos.

- Calcular la Suma de Rangos:

Calcular la suma de los rangos para cada muestra. En el caso de empate, el promedio de los rangos se multiplica por el número de datos en el empate.

- Calcular el Estadístico U de Mann-Whitney:

El estadístico U se calcula sumando los rangos de cada una de las muestras y ajustándolos por su tamaño<sup>18</sup>. Cuando las muestras tienen el mismo tamaño ( $n_1 = n_2$ ) el cálculo es:

$$\text{Estadístico U para muestra 1: } U_1 = n_1 * n_2 + \frac{n_1 * (n_1 + 1)}{2} - R_1$$

$$\text{Estadístico U para muestra 2: } U_2 = n_1 * n_2 + \frac{n_2 * (n_2 + 1)}{2} - R_2$$

Donde  $R_1$  y  $R_2$  son las sumas de los rangos de la muestra 1 y la muestra 2 respectivamente.

Luego de calcular el resultado para cada muestra, el estadístico U es el valor mínimo entre  $U_1$  y  $U_2$ .

- Calcular el Valor p:

Luego de calcular el valor de U, se puede calcular el valor p utilizando una aproximación normal:

$$\text{Valor P: } p = 2 * \theta * \left( -\frac{Z}{\sqrt{2}} \right)$$

Donde:  $\theta$  es la función de distribución acumulativa de la distribución normal estándar y Z es el valor Z calculado, que se obtiene a través de la siguiente formula:

$$\text{Valor Z } Z = \frac{U - \frac{n_1 * n_2}{2}}{\sqrt{\frac{n_1 * n_2 * (n_1 + n_2 + 1)}{12}}}$$

---

<sup>18</sup> Mann, H. B., & Whitney, D. R. (1947)

Donde  $U$  es el estadístico  $U$  calculado previamente y  $n_1$ ,  $n_2$  son los tamaños de las muestras.

- Comparar el Valor  $p$  con el Nivel de Significancia:

El último paso es comparar el valor  $p$  dado un nivel de significancia. Si el valor  $p$  es menor que el nivel de significancia (por ejemplo, 0.05), se rechaza la hipótesis nula y se acepta la hipótesis alternativa, que establece que hay una diferencia estadísticamente significativa entre las muestras. Si el valor  $p$  es mayor, no se tiene suficiente evidencia para rechazar la hipótesis nula, y como consecuencia, se acepta la hipótesis nula que establece que no existe una diferencia estadísticamente significativa entre las muestras.

### 3. Metodología

#### 3.1. Modalidad del Trabajo de Investigación

La modalidad del trabajo de investigación es considerada como "Proyecto Factible", que de acuerdo con el Manual de Trabajos de Grado de la Universidad Pedagógica "Libertador" <sup>19</sup> de Caracas – Venezuela, tiene las siguientes características: propone un Modelo Teórico – Práctico, que para este caso específico es la comparación de un modelo de regresión logística versus un modelo de árbol de decisión para medir la probabilidad de incumplimiento de una cartera de consumo. Este problema es investigable, pues trata de una necesidad conectada a una situación real.

#### 3.2. Tipo de investigación

La investigación realizada se enmarca en el tipo de investigación Descriptiva que de acuerdo a Hernández, Fernandez y Baptista <sup>20</sup> señalan que: "Los estudios descriptivos buscan especificar las propiedades importantes de las personas, grupos, comunidades o cualquier otro fenómeno que sea sometido a un análisis, así mismo indica que los estudios descriptivos miden de manera independiente los conceptos o variables con las que tienen que ver, aunque desde luego pueden integrar las mediciones de cada una de dichas variables, para decir como es y cómo se manifiesta el fenómeno.

---

<sup>19</sup> (UPEL, 2002)

<sup>20</sup> (Hernandez, 1996)



De la misma manera, Carlos Méndez<sup>21</sup> indica: "Se ocupa de la descripción de características que identifican los diferentes elementos y componentes", establece comportamientos concretos.

### 3.3.Método de investigación

El método de investigación a utilizar fue el deductivo, que consiste en un proceso de conocimiento que se inicia con la observación de fenómenos generales con el propósito de señalar las verdades particulares contenidas explícitamente en la situación general.

### 3.4.Diseño de investigación

En relación al diseño de investigación, el presente trabajo está comprendido como No Experimental, que de acuerdo a Hernández, Fernandez y Baptista<sup>22</sup> es aquel que: 'Se realiza sin manipular deliberadamente variables', así mismo, de acuerdo a los mismos autores, es transaccional porque: "Recolectan datos en un solo momento, en un tiempo único, su propósito es describir variables y analizar su incidencia o interpretación en un momento dado", a la vez es descriptivo siempre de acuerdo a Hernández, Fernandez y Baptista porque: "Tiene como objetivo indagar la incidencia y los valores en que se manifiesta una o más variables".

Por lo planteado, el diseño es combinado (No experimental – Transaccional), en cuanto a su forma, es una investigación aplicada, ya que se desarrolla con el objetivo de aplicar directamente los conocimientos que ella arroja para resolver un problema real y de aplicación inmediata.

### 3.5.Universo y Muestra

En lo que se refieren al Universo, Carlos Méndez<sup>23</sup> indica que es importante definir, por sus características, el volumen del portafolio, unidades empresariales, sector o subsector en el que van a aplicarse algunas técnicas en la recolección de información, o sobre el cual se realizará la investigación con el propósito de identificar hechos o fenómenos que los caracterizan. Este ámbito demográfico de tipo organizacional, sectorial, del país, grupo, etc., constituye el universo de investigación.

---

<sup>21</sup> (Mendez, 2000)

<sup>22</sup> (Hernandez, 1996)

<sup>23</sup> (Mendez, 2000)

La población o universo es el conjunto de todos los casos que concuerdan con una serie de especificaciones<sup>24</sup>. La muestra suele ser definida como un subgrupo de la población<sup>25</sup>. Para seleccionar la muestra deben delimitarse las características de la población. Muchos investigadores no describen lo suficiente las características de la población o asumen que la muestra representa automáticamente a la población. Es preferible, establecer claramente las características de la población, a fin de, delimitar cuáles serán los parámetros muestrales.

Así mismo, en relación a la muestra y población, el Manual de Trabajo de Grado de la Universidad Pedagógica Libertador<sup>26</sup> indica que: “se describe el universo afecto por el estudio, el grupo seleccionado, las características, tamaño y metodología, seguida para la selección de la muestra o de los sujetos, la asignación de las unidades a estudios de campo realizados con enfoques en los cuales los conceptos de población y muestra, no sean aplicables; se describirán los sujetos, fenómenos o unidades de investigación, así como también los criterios utilizados para su escogencia”.

La unidad de análisis para este trabajo está constituida por una cartera de préstamos de consumo de una Entidad Bancaria Argentina. Por motivos de confidencialidad, algunos datos que se exponen se encuentran previamente multiplicados por un escalar.

### 3.6.Sistematización del Problema

El planteamiento de la hipótesis, se formula a partir de la sistematización del problema de investigación, como se muestra a continuación:

<b>Problema</b>	<b>Objetivo</b>	<b>Hipótesis</b>
¿En qué magnitud un modelo de árbol de decisión mejorara la estimación de la probabilidad de	Implementar dos modelos, uno de regresión logística y uno de árbol de decisión.	Desarrollar un modelo de árbol de decisión mejora la estimación de la probabilidad de incumplimiento en una cartera de consumo

<sup>24</sup> (Sellitz, 2003)

<sup>25</sup> (Naghi, 2008)

<sup>26</sup> (UPEL, 2002)

incumplimiento de una cartera de consumo?		
<b>Provocan</b>	<b>Para</b>	<b>Permitirá</b>
Bajos niveles de rentabilidad. Altos niveles de riesgo.	Mejorar la gestión de activos y pasivos del Banco, midiendo de mejor manera el riesgo de la cartera de consumo.	Mejorar la estimación de la probabilidad de incumplimiento de una cartera de consumo.

Fuente: Elaboración propia

### 3.7. Variables

Tomando en cuenta que la variable que se desea explicar con la investigación se considera como la variable dependiente y la variable que se espera que explique el cambio de la variable dependiente, es referida como la variable independiente (Méndez)<sup>27</sup> se definen a continuación ambas variables utilizadas para la presente investigación

### 3.8. Dependiente

La variable dependiente es:

- Probabilidad de incumplimiento (PD)

### 3.9. Independientes

Las variables independientes son:

- Departamento
- Tamaño Deudor
- Número de Codeudores
- Monto Desembolsado USD
- Tasa
- Plazo

---

<sup>27</sup> (Mendez, 2000)

- Patrimonio
- Ingresos / Ventas
- Importe Garantía
- Actividad Económica
- Tipo de Actividad

#### 4. Resultados:

Los datos mensuales se encuentran en archivo Excel expresados de la siguiente manera:

COD_OPERACIÓN	DESC_DEPARTAMENTO	TAMANIO ACT.DEUDOR	NRO_CODEUDORES	MONTO_DES_SUS
XXXXXX	CHUQUISACA	0.04886161	1	46938.78

TASA	PLAZO	PATRIMONIO	INGRESO_VENTAS	ACTIVIDAD ECONÓMICA	TIP_ACT_ECO	INCUMPLIMIENTO
11.95	4383	289796.25	628712.64	VENTA AL POR MAYOR Y MENOR	D	0

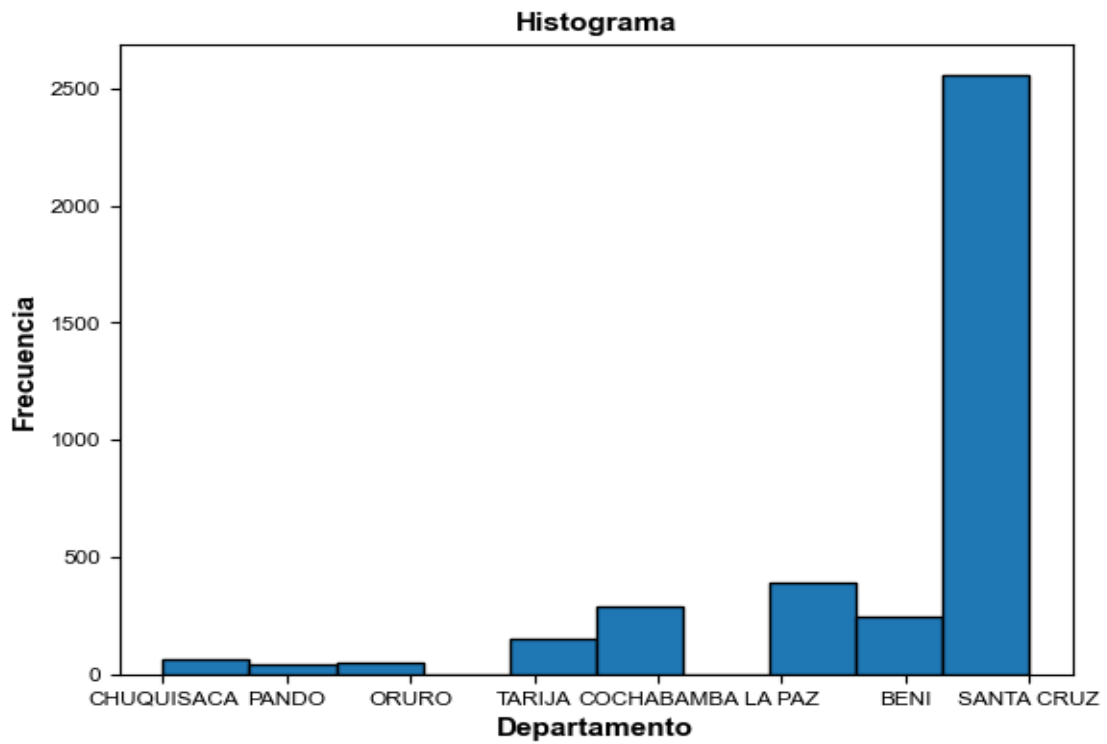
Fuente: Archivos mensuales generados por el Banco

A partir de estos datos, se utiliza el lenguaje de programación Python como herramienta para poder realizar el análisis de datos y los modelos anteriormente mencionados.

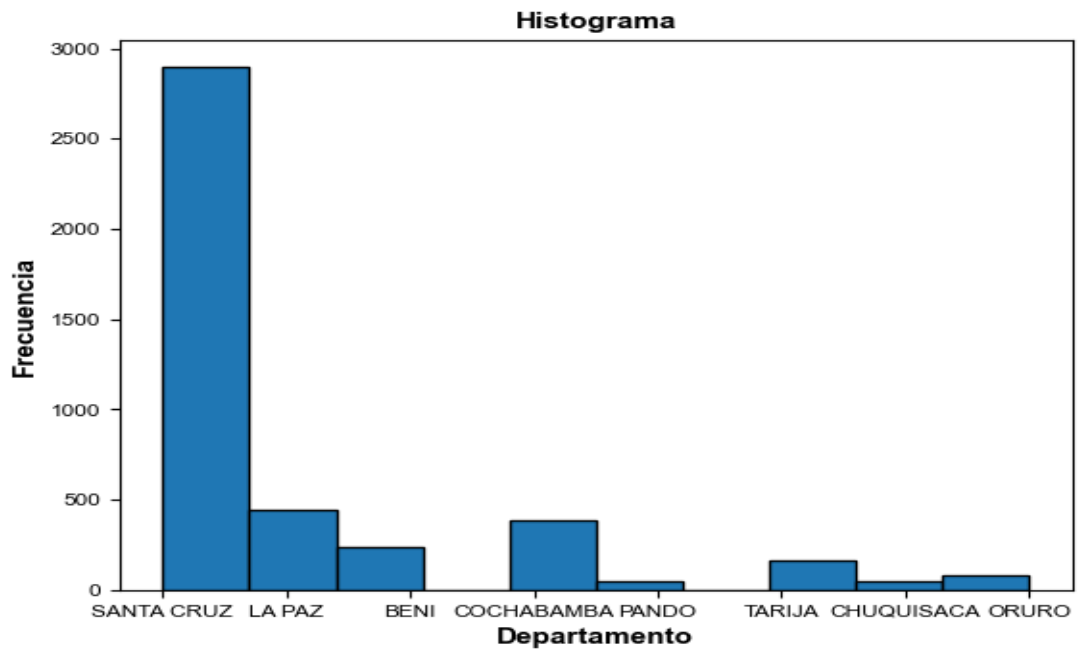
##### 4.1. Análisis de Datos:

Se realiza la creación de histogramas para las distintas variables categóricas:

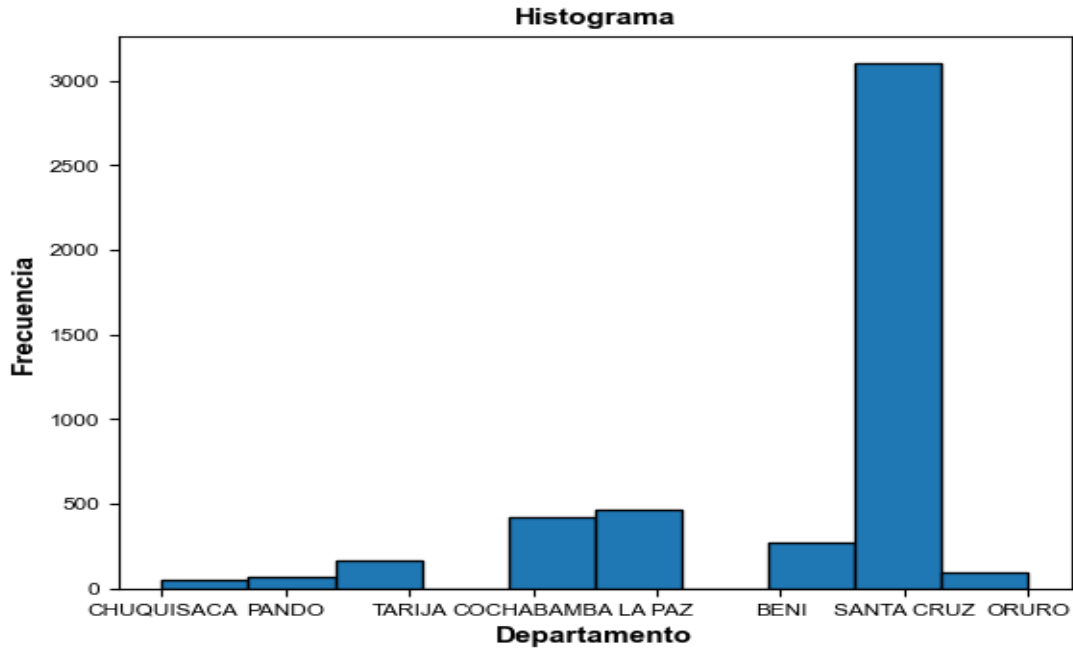
- Departamento:



Fuente: Elaboración propia (junio-2021)



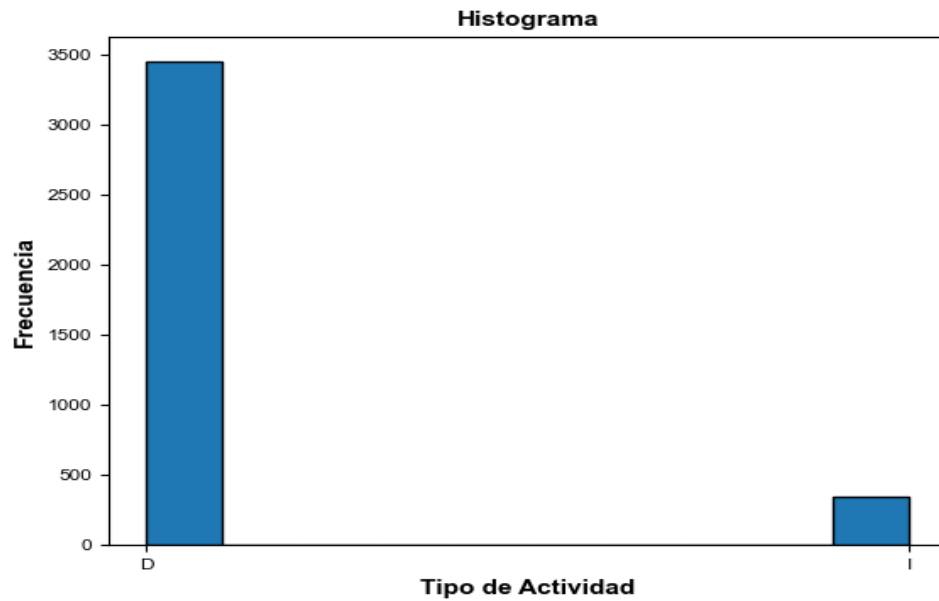
Fuente: Elaboración propia (diciembre-2021)




Fuente: Elaboración propia (mayo-2022)

En los resultados obtenidos se evidencia que la cartera del Banco está posicionada en la región oriental, siendo Santa Cruz la principal plaza. Al ser un banco cuya cartera está orientada al sector productivo, se tiene esta distribución.

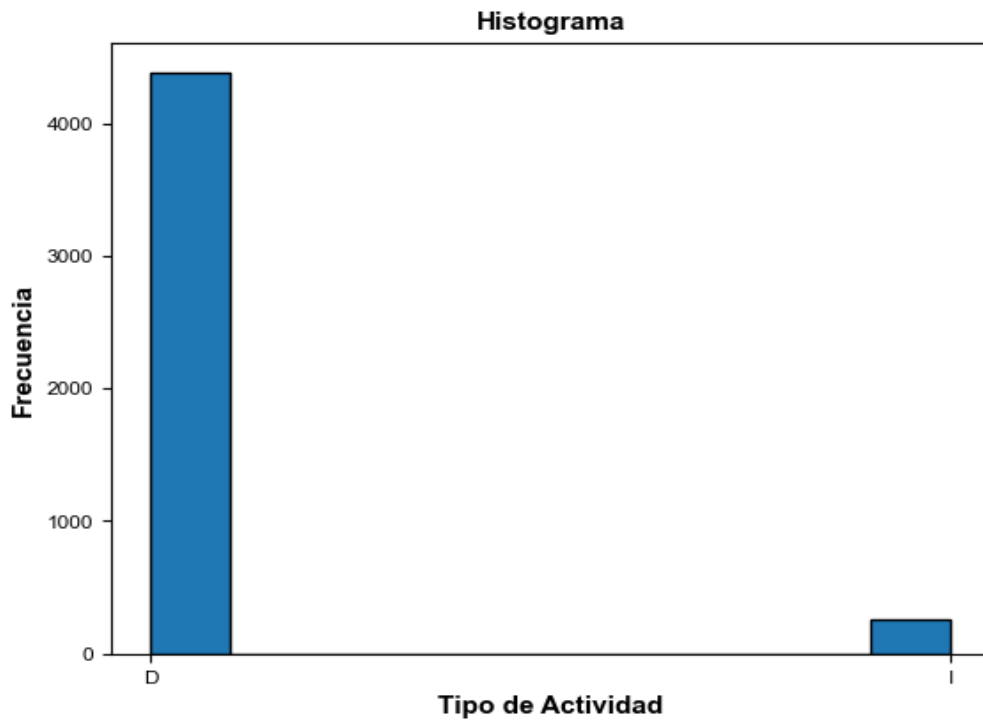
- Actividad económica (independiente-dependiente):



Fuente: Elaboración propia (junio-2021)



Fuente: Elaboración propia (diciembre-2021)



Fuente: Elaboración propia (mayo-2022)

En los resultados obtenidos se evidencia que la cartera del Banco está enfocada en personas dependientes, dado el tipo de crédito seleccionado se da esta situación.

- Variables no categóricas:

VARIABLES	TAMANIO ACT.DEUDOR	NRO_CODEUDORES	MONTO_DES_SUS	TASA	PLAZO	PATRIMONIO	INGRESO_VENTAS	IMP_GTIA	DEFAULT
count	3,786	3,786	3,786	3,786	3,786	3,786	3,786	3,786	3,786
mean	0.00	0.34	6,613.75	0.16	1,757.54	41,247.56	16,687.78	3,750.73	0.11
std	0.01	0.47	10,577.92	0.03	494.14	244,782.64	44,973.81	21,417.12	0.31
min	-	-	728.86	0.04	342.00	- 32,592.32	-	-	-
25%	-	-	3,061.22	0.14	1,805.25	6,000.00	6,317.25	-	-
50%	-	-	4,664.72	0.14	1,819.00	10,000.00	9,600.00	-	-
75%	-	1.00	7,288.63	0.17	1,830.00	30,784.00	15,480.00	-	-
max	0.12	1.00	252,186.59	0.25	5,485.00	13,264,176.40	1,854,249.48	394,842.85	1.00

Fuente: Elaboración propia (junio-2021)

VARIABLES	TAMANIO ACT.DEUDOR	NRO_CODEUDORES	MONTO_DES_SUS	TASA	PLAZO	PATRIMONIO	INGRESO_VENTAS	IMP_GTIA	DEFAULT
count	4,302	4,302	4,302	4,302	4,302	4,302	4,302	4,302	4,302
mean	4.04	0.29	6,131.97	0.16	1,760.68	34,280.05	13,729.77	2,670.34	0.10
std	22.05	0.45	10,625.35	0.03	426.63	230,628.15	28,048.93	19,289.48	0.30
min	-	-	728.86	0.04	229.00	- 32,592.32	-	-	-
25%	-	-	3,061.22	0.14	1,811.00	6,000.00	5,696.13	-	-
50%	-	-	4,373.18	0.14	1,820.00	9,240.67	8,372.58	-	-
75%	-	1.00	6,559.77	0.16	1,831.00	20,109.60	12,915.00	-	-
max	186.00	1.00	350,888.63	0.25	7,315.00	13,264,176.40	630,066.48	380,072.40	1.00

Fuente: Elaboración propia (diciembre-2021)

VARIABLES	TAMANIO ACT.DEUDOR	NRO_CODEUDORES	MONTO_DES_SUS	TASA	PLAZO	PATRIMONIO	INGRESO_VENTAS	IMP_GTIA	DEFAULT
count	4,644	4,644	4,644	4,644	4,644	4,644	4,644	4,644	4,644
mean	0.00	0.27	6,044.68	0.16	1,753.25	33,098.76	13,884.39	2,496.42	0.10
std	0.01	0.44	10,303.66	0.03	420.17	231,935.75	40,388.30	19,319.98	0.30
min	-	-	655.98	0.04	329.00	- 32,592.32	-	-	-
25%	-	-	3,061.22	0.14	1,811.00	6,088.92	5,627.10	-	-
50%	-	-	4,373.18	0.16	1,820.00	9,496.94	8,220.00	-	-
75%	-	1.00	6,559.77	0.16	1,831.00	18,992.21	12,602.61	-	-
max	0.46	1.00	350,888.63	0.25	7,315.00	13,264,176.40	2,015,219.04	380,072.40	1.00

Fuente: Elaboración propia (mayo-2022)

Los cuadros anteriores señalan que, en promedio, la cartera utilizada para el presente trabajo tiene un plazo residual de aproximadamente 5 años, la tasa promedio es de 15% anual, el monto desembolsado promedio es de 6.200 USD, que equivalen en moneda local a 43.152 Bs, el tipo de cambio oficial del país es de 6.96 Bolivianos por 1 Dólar Americano.



## 4.2.Regresión Logística:

Para realizar la regresión logística, se separan los datos en 2 grupos (entrenamiento y prueba), 80% de los datos se utilizarán como entrenamiento para realizar la regresión logística y el restante 20% para probar los resultados.

Los resultados se detallan en la siguiente tabla:

Logit Regression Results – DIC 22			
Dep. Variable:	INCUMPLIMIENTO	No. Observations:	3441
Model:	Logit	Df Residuals:	3411
Method:	MLE	Df Model:	29
Date:	Wed, 12 Jul 2023	Pseudo R-squ.:	0.3964
Time:	09:04:57	Log-Likelihood:	-692.14
converged:	False	LL-Null:	-1146.7
Covariance Type:	nonrobust	LLR p-value:	1.311e-172

VARIABLES	coef	std er	z	P> z	[0.025	0.975]
TAMANIO ACT.DEUDOR	0.0306	0.003	11.017	0	0.025	0.036
NRO_CODEUDORES	-0.0112	0.167	-0.067	0.946	-0.339	0.317
MONTO_DES_SUS	1.91E-05	1.92E-05	0.992	0.321	-1.86E-05	5.68E-05
TASA	11.3332	1.727	6.561	0	7.947	14.719
PLAZO	-0.0034	0	-17.772	0	-0.004	-0.003
PATRIMONIO	-7.59E-07	9.31E-07	-0.816	0.415	-2.58E-06	1.07E-06
INGRESO_VENTAS	5.39E-07	3.59E-06	0.15	0.881	-6.50E-06	7.58E-06
IMP_GTIA	1.78E-06	1.15E-05	0.155	0.877	-2.08E-05	2.44E-05
DESC_DEPARTAMENTO_CHUQUISACA	-0.2833	0.953	-0.297	0.766	-2.151	1.585
DESC_DEPARTAMENTO_COCHABAMBA	0.2172	0.481	0.452	0.652	-0.725	1.16
DESC_DEPARTAMENTO_LA PAZ	0.7173	0.43	1.669	0.095	-0.125	1.56
DESC_DEPARTAMENTO_ORURO	-15.9542	2308.549	-0.007	0.994	-4540.628	4508.719
DESC_DEPARTAMENTO_PANDO	-0.3074	0.885	-0.347	0.728	-2.042	1.427
DESC_DEPARTAMENTO_SANTA CRUZ	1.225	0.348	3.517	0	0.542	1.908
DESC_DEPARTAMENTO_TARIJA	-1.0222	0.889	-1.15	0.25	-2.764	0.72
ACT ECONOMICA_AGRICULTURA Y GANADERIA	-0.7925	0.583	-1.36	0.174	-1.935	0.35
ACT ECONOMICA_CAZA SILVICULTURA Y PESCA	-11.6804	1117.189	-0.01	0.992	-2201.33	2177.97
ACT ECONOMICA_CONSTRUCCION	0.184	0.291	0.633	0.527	-0.386	0.754
ACT ECONOMICA_EDUCACION	-0.6171	0.295	-2.092	0.036	-1.195	-0.039
ACT ECONOMICA_EXTRACCION DE PETROLEO CRUDO Y GAS N	0.0812	0.377	0.215	0.829	-0.658	0.82
ACT ECONOMICA_INDUSTRIA MANUFACTURERA	-0.42	0.875	-0.48	0.631	-2.134	1.294
ACT ECONOMICA_INTERMEDIACION FINANCIERA	-1.3709	0.781	-1.756	0.079	-2.901	0.159
ACT ECONOMICA_MINERALES METALICOS Y NO METALICOS	-0.4564	0.317	-1.44	0.15	-1.078	0.165
ACT ECONOMICA_PRODUCION Y DISTRIBUCION DE ENERGIA	-0.4852	0.514	-0.944	0.345	-1.493	0.522
ACT ECONOMICA_SERVICIO DE ORGANIZACIONES Y ORGANO	-0.1945	0.268	-0.725	0.468	-0.72	0.331
ACT ECONOMICA_SERVICIOS INMOBILIARIOS EMPRESARIALE	0.1715	0.601	0.285	0.775	-1.007	1.35
ACT ECONOMICA_SERVICIOS SOCIALES COMUNALES Y PERSO	-166.159	3.06E+36	-5.44E-35	1	-5.99E+36	5.99E+36
ACT ECONOMICA_TRANSPORTE ALMACENAMIENTO Y COMU	-0.2216	0.298	-0.744	0.457	-0.805	0.362
ACT ECONOMICA_VENTA AL POR MAYOR Y MENOR	0.2914	0.326	0.894	0.371	-0.348	0.93
TIP_ACT_ECO_I	2.1692	0.238	9.108	0	1.702	2.636

=====

Fuente: Elaboración propia

Esta es la regresión para un mes de estudio, se repiten los pasos para realizar el análisis de todos los meses del periodo analizado.

El resumen de las regresiones nos entrega los siguientes resultados:

- R-cuadrado promedio: 40%
- Variables estadísticamente significativas:
  - Departamento: La Paz y Santa Cruz.
  - Tamaño Act. Deudor.
  - Tasa.
  - Plazo.
  - Actividad Económica: Ventas al Por Mayor y Menor, Construcción, Educación, Agricultura y Ganadería.
  - Tipo de Actividad Económica: Independiente.

A partir de estos resultados, realizamos una nueva regresión para eliminar las variables que no son estadísticamente significativas (valor p) y los resultados son los siguientes para el primer de estudio:

Logit Regression Results			
=====			
Dep. Variable:	INCUMPLIMIENTO	No. Observations:	3441
Model:	Logit	Df Residuals:	3431
Method:	MLE	Df Model:	9
Date:	Thu, 17 Jul 2023	Pseudo R-squ.:	0.3889
Time:	10:45:13	Log-Likelihood:	-686.17
converged:	True	LL-Null:	-1122.8
Covariance Type:	nonrobust	LLR p-value:	3.658e-182
=====			

VARIABLES	coef	std err	z	P> z	[0.025	0.975]
TAMANIO ACT.DEUDOR	0.0318	0.003	11.381	0	0.026	0.037
TASA	10.0887	1.4	7.204	0	7.344	12.833
PLAZO	-0.0034	0	-21.435	0	-0.004	-0.003
DESC_DEPARTAMENTO_LA PAZ	0.7482	0.342	2.191	0.028	0.079	1.418
DESC_DEPARTAMENTO_SANTA CRUZ	1.3065	0.221	5.9	0	0.872	1.74
ACT_ECONOMICA_AGRICULTURA Y GANADERIA	-1.06	0.581	-1.823	0.068	-2.2	0.08
ACT_ECONOMICA_CONSTRUCCION	0.374	0.222	1.688	0.091	-0.06	0.808
ACT_ECONOMICA_EDUCACION	-0.4782	0.228	-2.093	0.036	-0.926	-0.03
ACT_ECONOMICA_VENTA AL POR MAYOR Y MENOR	0.4575	0.26	1.759	0.078	-0.052	0.967
TIP_ACT_ECO_I	2.1962	0.228	9.63	0	1.749	2.643

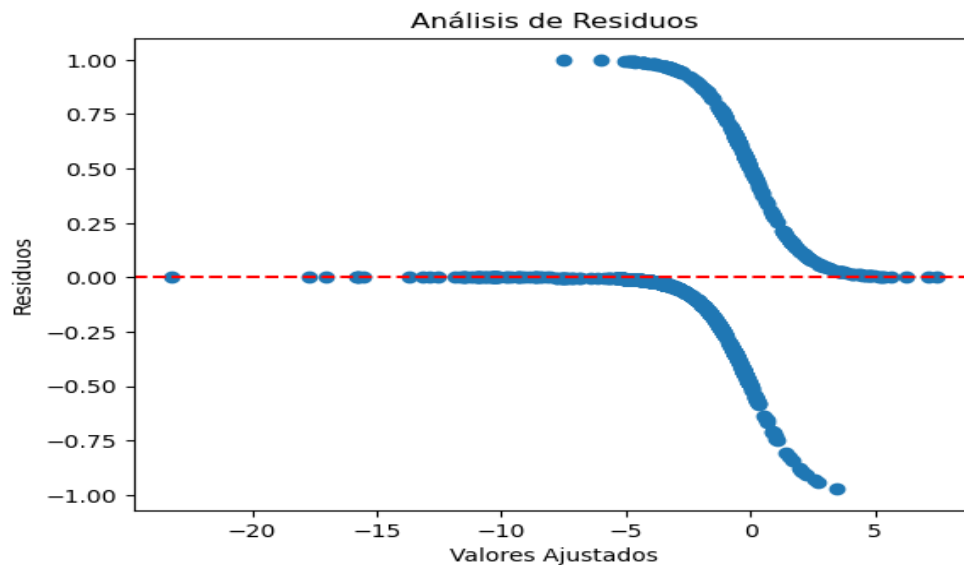
Fuente: Elaboración propia

Los resultados denotan que, si bien no hubo una mejora significativa en algunos indicadores como por ejemplo el “*log-likelihood*” y r-cuadrado que resultaron similares, a un nivel de confianza del 90%, aceptamos todas las variables introducidas.

### 4.3. Análisis de Residuos:

Debido al supuesto de que la relación entre las variables independientes y el logaritmo de las *odds* (probabilidad logarítmica) de la variable dependiente sea lineal. Pasamos a comprobar mediante gráficos este supuesto:

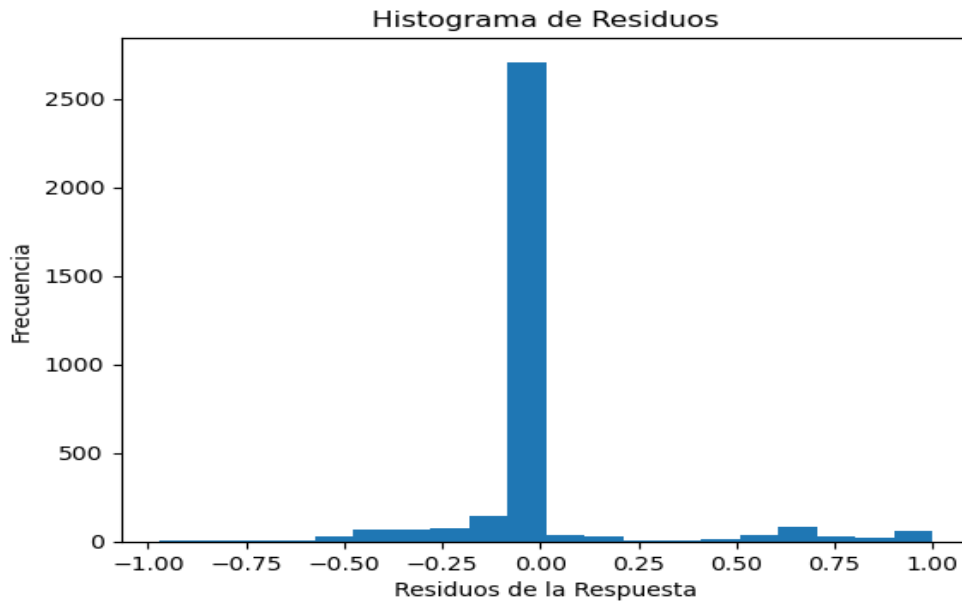
- Gráfico de dispersión de residuos versus valores ajustados



Fuente: Elaboración propia

Se puede evidenciar que los puntos no siguen una distribución aleatoria, siguen un cierto patrón de curva, por lo que el modelo denota una dificultad en capturar ciertos patrones en los datos.


- Histograma de residuos



Fuente: Elaboración propia

Se puede evidenciar que el histograma presenta una distribución leptocúrtica, esta distribución es sensible a valores atípicos, tiene una mayor variabilidad y presenta una mayor dificultad al momento de modelización. Evidenciar que la distribución del histograma de residuos no tiene una distribución en forma de campana, sugiere problemas con la adecuación del modelo.

- Gráfico Q-Q de los residuos



Fuente: Elaboración propia

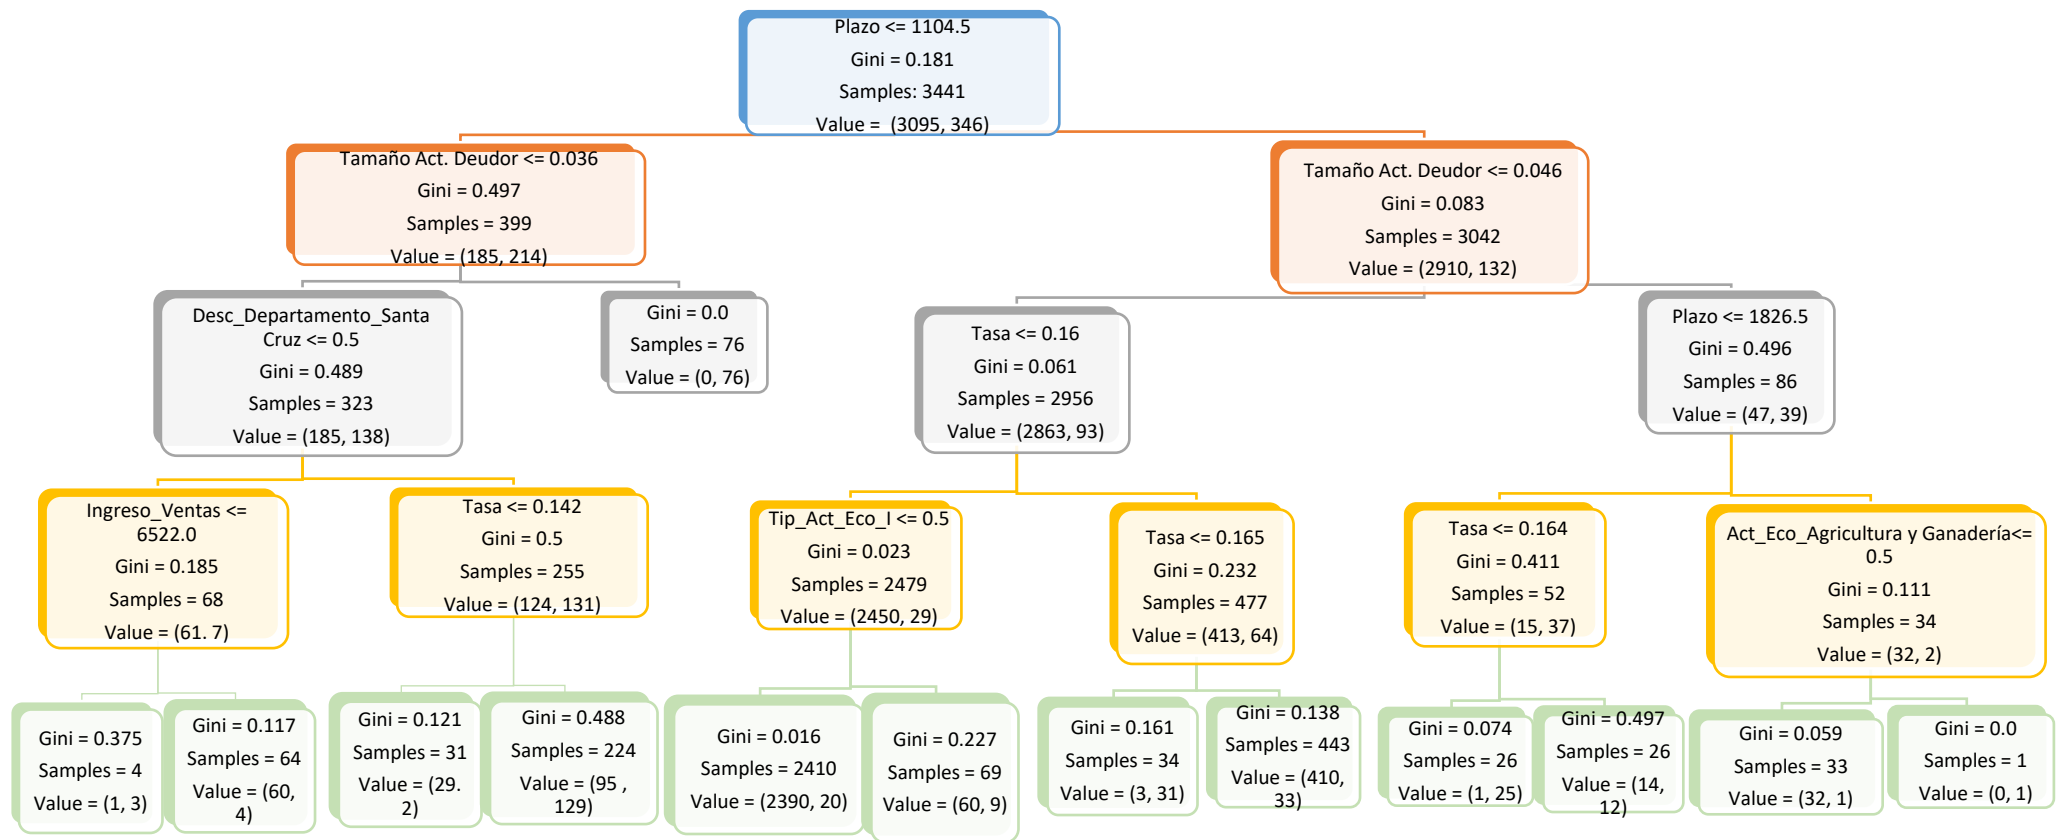
Si bien los puntos siguen la tendencia de una línea diagonal, se evidencia cierta volatilidad, esto indica desviaciones de la normalidad.

#### 4.4. Modelo Árbol de Decisión:

De la misma manera, para realizar el modelo de árbol de decisión, se separan los datos en 2 grupos (entrenamiento y prueba), 80% de los datos se utilizarán como entrenamiento para realizar la regresión logística y el restante 20% para probar los resultados.

El primer resultado que se obtiene a través de realizar el modelo de árbol de decisión denota un árbol con muchos niveles de profundidad, que no permiten observar correctamente los coeficientes, por lo tanto se modifica el script limitando el nivel de ramos del árbol de decisión.

A continuación se presenta el árbol de decisión:



Fuente: Elaboración propia

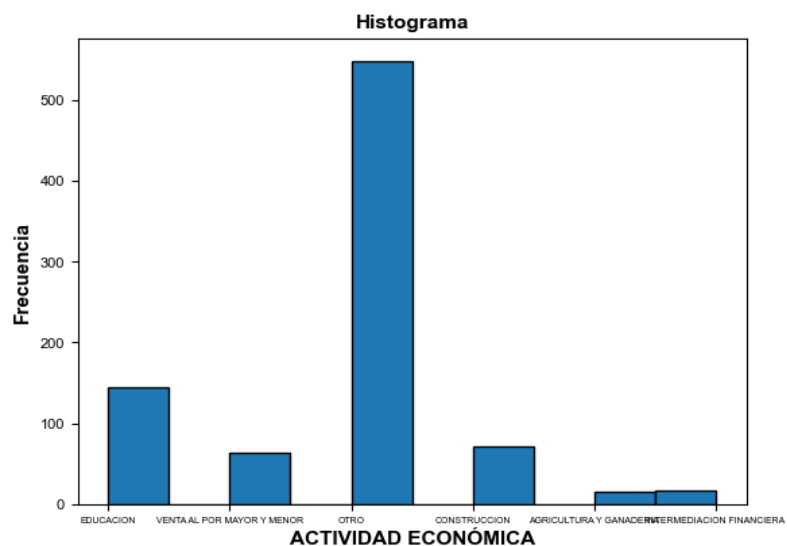
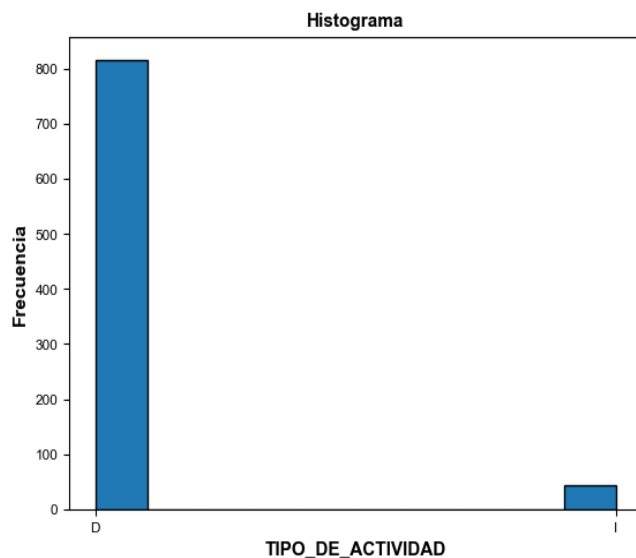
Se utiliza el mismo script para evaluar todos los meses de estudio, observando lo siguiente:

- En la mayoría de los meses, el plazo y el tamaño deudor son las variables que el modelo escoge como primarias.
- El monto desembolsado y el importe de la garantía no son seleccionadas como variables relevantes por el modelo.
- Añadir más niveles de profundidad no generan resultados más relevantes.

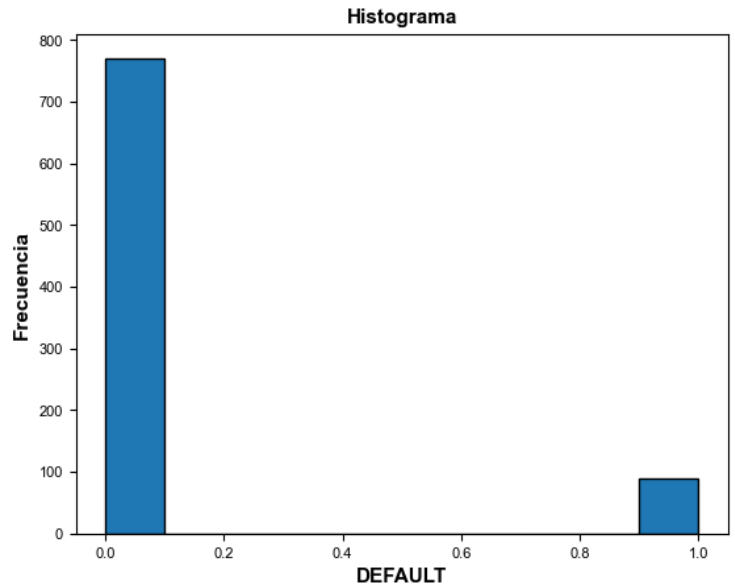
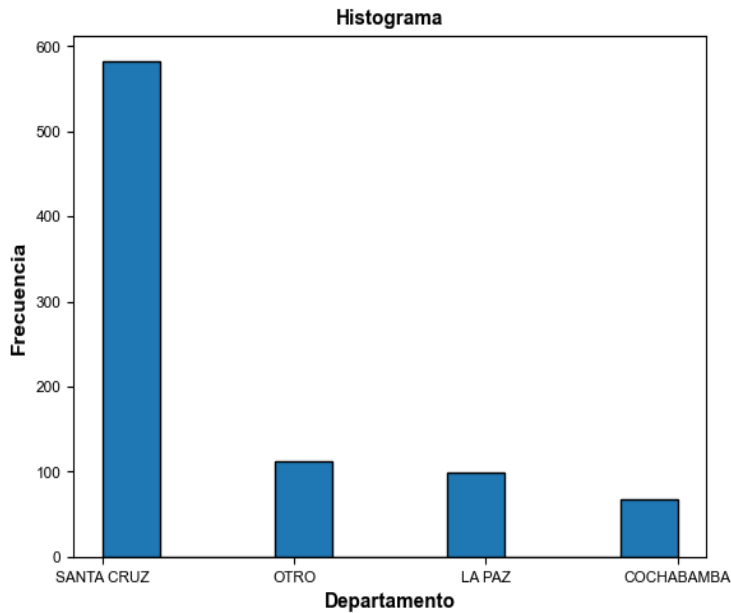
#### 4.5. Backtesting:

Como se menciona anteriormente, se hizo la separación de los datos en 2 grupos, el 80% fue utilizado como entrenamiento para realizar los modelos, mientras que el 20% de los datos se usaron para comprobar los resultados de los modelos. A continuación se presentan las características del 20%:

VARIABLE	TAMANIO ACT.DEUDOR	TASA	PLAZO
count	861	861	861
mean	4.185208947	0.1562	1784.27
std	22.29521194	0.02799	455.812
min	0	0.0848	557
25%	0	0.1399	1811
50%	0	0.1399	1820
75%	0	0.16	1831
max	186	0.2498	4397



Fuente: Elaboración propia



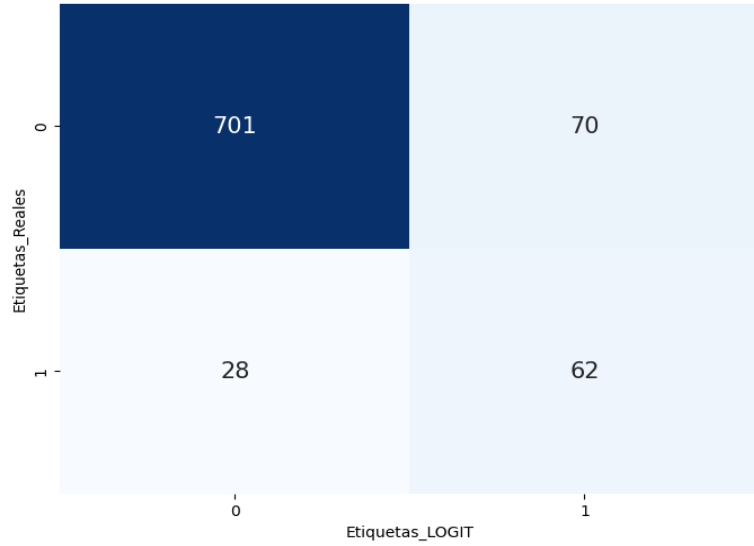
Fuente: Elaboración propia

Los datos del grupo separado para comprobar los resultados presentan características similares a las del grupo utilizado para los modelos, esto se dio debido a que se separaron los datos de manera aleatoria.


Elegir un umbral de 0.15 indica que cuando la probabilidad de incumplimiento sea mayor que 0.15 (15%), se definirá como que el cliente incumplirá y esto se compara con los datos del grupo de pruebas. Este umbral es definido por cada institución de manera interna, de acuerdo a su apetito de riesgo. Instituciones con mayor apetito de riesgo definirán umbrales más altos permitiendo la entrada de créditos con una probabilidad de incumplimiento mayor, al contrario, instituciones más conservadoras definirán umbrales más cercanos a 0, rechazando una mayor cantidad de créditos. Se realizará la comparación entre la matriz de confusión que resulta del modelo de regresión logística y del modelo de árbol de decisión seleccionando umbrales de 0.15, 0.3, 0.45, 0.6, 0.75 y 0.9.



Matriz de Confusión - Umbral 0.15



Matriz de Confusión - Umbral 0.15




Fuente: Elaboración propia

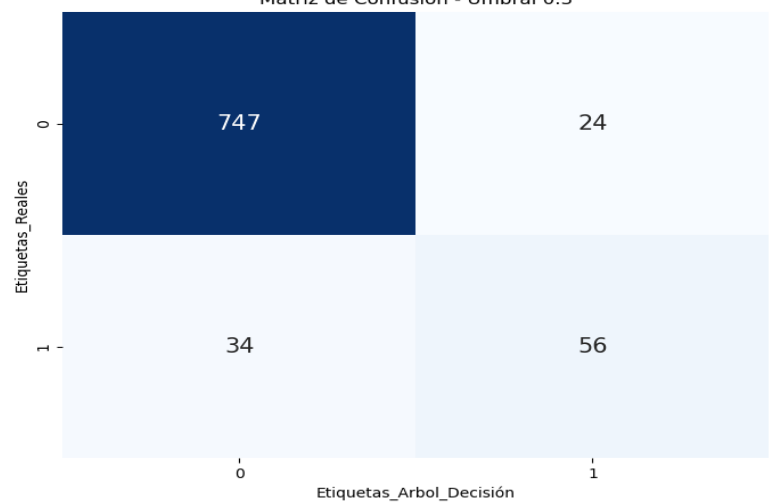
Cuando seleccionamos el umbral de 0.15, el modelo LOGIT presenta 701 casos correctamente clasificados como no incumplimiento y 62 casos correctamente clasificados como incumplimiento, mientras que clasifica 28 casos incorrectamente como incumplimiento y 70 casos como no incumplimiento.

El modelo de árbol de decisión con el umbral de 0.15 presenta 747 casos correctamente clasificados como no incumplimiento y 56 casos correctamente clasificados como incumplimiento, mientras que clasifica 34 casos incorrectamente como incumplimiento y 24 casos como no incumplimiento.

Matriz de Confusión - Umbral 0.3



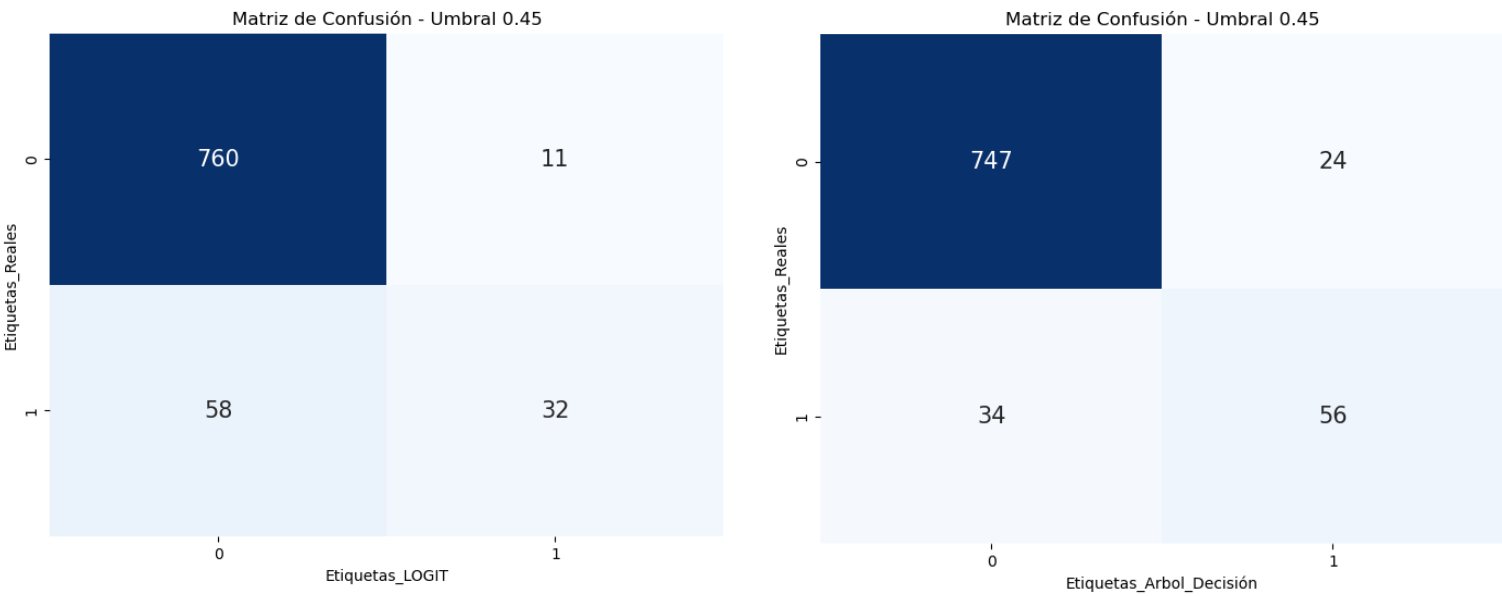
Matriz de Confusión - Umbral 0.3



Fuente: Elaboración propia

Cuando seleccionamos el umbral de 0.3, el modelo LOGIT presenta 732 casos correctamente clasificados como no incumplimiento y 54 casos correctamente clasificados como incumplimiento, mientras que clasifica 36 casos incorrectamente como incumplimiento y 39 casos como no incumplimiento.



El modelo de árbol de decisión con el umbral de 0.3 presenta 747 casos correctamente clasificados como no incumplimiento y 56 casos correctamente clasificados como incumplimiento, mientras que clasifica 34 casos incorrectamente como incumplimiento y 24 casos como no incumplimiento, no hubo cambios respecto al umbral de 0.15.



Fuente: Elaboración propia

Cuando seleccionamos el umbral de 0.45, el modelo LOGIT presenta 760 casos correctamente clasificados como no incumplimiento y 32 casos correctamente clasificados como incumplimiento, mientras que clasifica 58 casos incorrectamente como incumplimiento y 11 casos como no incumplimiento.

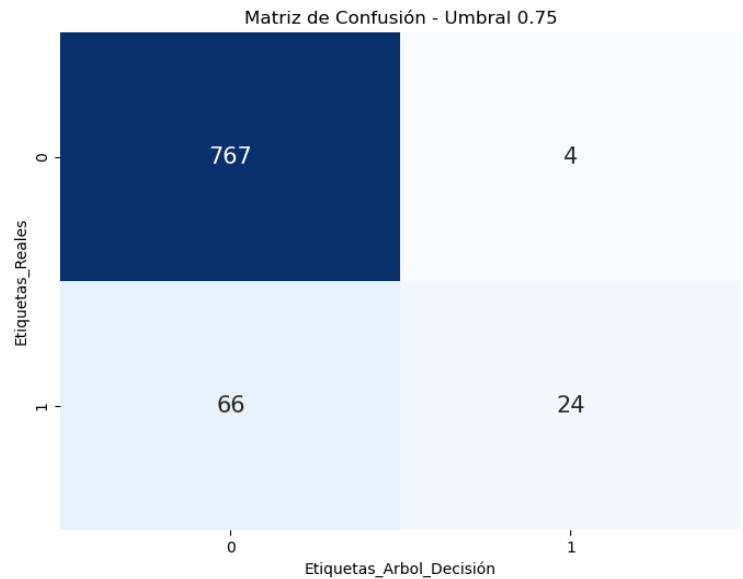
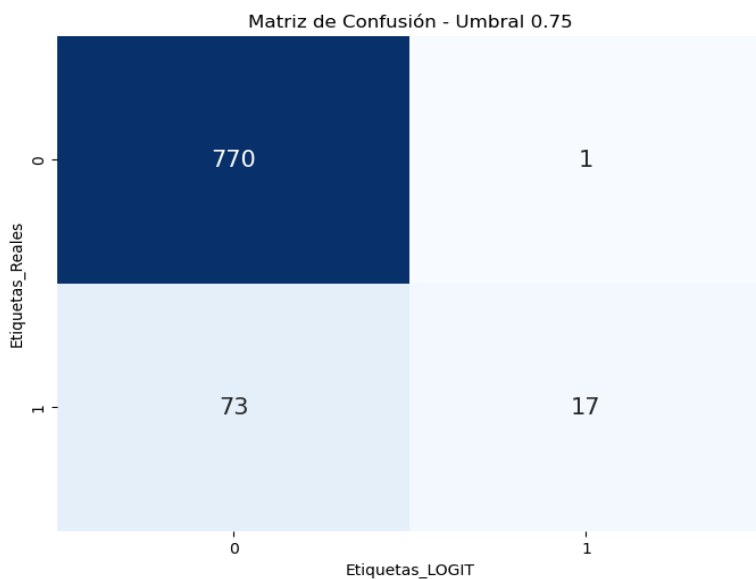
El modelo de árbol de decisión con el umbral de 0.45 presenta 747 casos correctamente clasificados como no incumplimiento y 56 casos correctamente clasificados como incumplimiento, mientras que clasifica 34 casos incorrectamente como incumplimiento y 24 casos como no incumplimiento, no hubo cambios respecto al umbral de 0.3.



Fuente: Elaboración propia

Cuando seleccionamos el umbral de 0.6, el modelo LOGIT presenta 767 casos correctamente clasificados como no incumplimiento y 22 casos correctamente clasificados como incumplimiento, mientras que clasifica 68 casos incorrectamente como incumplimiento y 4 casos como no incumplimiento.


El modelo de árbol de decisión con el umbral de 0.6 presenta 767 casos correctamente clasificados como no incumplimiento y 24 casos correctamente clasificados como



incumplimiento, mientras que clasifica 66 casos incorrectamente como incumplimiento y 4 casos como no incumplimiento.

Cuando seleccionamos el umbral de 0.75, el modelo LOGIT presenta 770 casos correctamente clasificados como no incumplimiento y 17 casos correctamente clasificados como incumplimiento, mientras que clasifica 73 casos incorrectamente como incumplimiento y 1 caso como no incumplimiento.

El modelo de árbol de decisión con el umbral de 0.75 presenta 767 casos correctamente clasificados como no incumplimiento y 24 casos correctamente clasificados como incumplimiento, mientras que clasifica 66 casos incorrectamente como incumplimiento y 4 casos como no incumplimiento.



Fuente: Elaboración propia

Cuando seleccionamos el umbral de 0.9, el modelo LOGIT presenta 770 casos correctamente clasificados como no incumplimiento y 9 casos correctamente clasificados como incumplimiento, mientras que clasifica 81 casos incorrectamente como incumplimiento y 1 caso como no incumplimiento.

El modelo de árbol de decisión con el umbral de 0.9 presenta 770 casos correctamente clasificados como no incumplimiento y 24 casos correctamente clasificados como


incumplimiento, mientras que clasifica 66 casos incorrectamente como incumplimiento y 1 caso como no incumplimiento.

Debido a que el presente estudio trata de predecir la probabilidad de incumplimiento de una cartera de créditos a través de 2 modelos, el factor más importante son los casos en los que el modelo predijo que no iba a ocurrir un incumplimiento y sin embargo, si ocurrió el incumplimiento (falso negativo). Revisando las matrices de confusión, el modelo de árbol de decisión presenta una menor cantidad de falsos negativos en todos los umbrales analizados, con excepción del umbral de 0.15.

Las matrices de confusión son expresadas a través de la curva ROC. A continuación se presenta la curva ROC para los resultados de la regresión logística:

Fuente: Elaboración propia

A continuación se presenta la curva ROC para los resultados del árbol de decisión:



Fuente: Elaboración propia

La curva ROC representa la relación entre la tasa de verdaderos positivos (sensibilidad) y la tasa de falsos positivos (1 - especificidad) a medida que varía el umbral de clasificación, Debido a la similitud de ambas curvas, no se puede evidenciar diferencias significativas de algún modelo.

El último paso es calcular el score AUC, que mide la capacidad del modelo para distinguir entre clases positivas y negativas, a continuación se calcula el score AUC en cada periodo de cada modelo:

Periodo	Modelo LOGIT	Modelo Árbol de Decisión
Junio – 2021	0.8867383065333687	0.9276089024751626
Julio – 2021	0.8637689054088695	0.9204130351192001
Agosto – 2021	0.859068176239568	0.8957949803632793
Septiembre – 2021	0.8676434462186349	0.9158975258817337
Octubre – 2021	0.8885119128198186	0.8689082171382159
Noviembre – 2021	0.9186093578999446	0.9291036385170083
Diciembre – 2021	0.8739299610894942	0.8830739299610895
Enero – 2022	0.8692730880230882	0.8769905689548546
Febrero – 2022	0.8845866886207517	0.8721217422624713
Marzo - 2022	0.862195137580581	0.8916721134991733
Abril - 2022	0.8787262872628726	0.9141034327009936
Mayo - 2022	0.8446912060863728	0.8538655180129784

Fuente: Elaboración propia

Ambos modelos presentan scores por arriba de 0.5 y cercanos a 1, lo cual establece que ambos modelos pueden clasificar correctamente la mayoría de las instancias positivas y negativas. El modelo que presenta un mejor score en 10 de los 12 periodos es el modelo de Árbol de Decisión, sin embargo, solo por decimales.

Se realizó la prueba de Mann-Whitney U, para comparar los scores AUC de ambos modelos y ver si realmente existe diferencia estadística significativa entre los resultados de los modelos. A continuación se presenta el valor del estadístico Mann-Whitney U y su P-Value.

Estadístico	Valor
Mann-Whitney U Statistic	110.5

P-Value	0.028206082679416676
---------	----------------------

Fuente: Elaboración propia

A continuación se detalla si se existe diferencia estadísticamente significativa para rechazar la hipótesis nula (no hay diferencia significativa en la estimación de la probabilidad de incumplimiento de una cartera de consumo, al utilizar un modelo de árbol de decisión y realizar un backtesting), o si no existe evidencia suficiente para rechazar la hipótesis nula y se acepta la hipótesis alternativa (existe una diferencia estadísticamente significativa en la estimación de la probabilidad de incumplimiento de una cartera de consumo, al utilizar un modelo de árbol de decisión y realizar un backtesting).

Nivel de Confianza (Alpha)	Resultado
90%	Diferencia estadísticamente significativa (rechazar H0)
95%	Diferencia estadísticamente significativa (rechazar H0)
99%	No hay evidencia suficiente para rechazar H0 (aceptar H0)

Fuente: Elaboración propia

Estos resultados permiten rechazar la hipótesis nula bajo los niveles de confianza del 90% y 95%, por lo tanto aceptamos la hipótesis alternativa. Si existe una diferencia estadísticamente significativa entre el uso de un modelo de árbol de decisión versus un modelo de regresión logística.

Como complemento de lo analizado, se hace la verificación de los Falsos Positivos expuestos para ambos modelos, para el modelo de regresión logística utilizando un umbral de 0.3 tenemos los siguientes resultados:

VARIABLE	Grupo de Prueba	Falsos Positivos
TASA (PROMEDIO)	15.78%	16.20%
PLAZO (PROMEDIO)	1737.83	1617.82
DESC_DEPARTAMENTO_LA PAZ	103	7
DESC_DEPARTAMENTO_SANTA CRUZ	602	47
ACT_ECONOMICA_AGRICULTURA Y GANADERIA	14	0
ACT_ECONOMICA_CONSTRUCCION	78	5
ACT_ECONOMICA_EDUCACION	177	12
ACT_ECONOMICA_VENTA AL POR MAYOR Y MENOR	71	2
TIP_ACT_ECO_I	56	6

Fuente: Elaboración propia

Se puede notar que para las variables que el modelo Logit *performa* de peor manera son: tasas de interés más altas, menores días de plazo y con la variable de tipo de actividad económica independiente.

Para el modelo de árbol de decisión utilizando un umbral de 0.3 se tienen los siguientes resultados, destacando las variables más significativas:

VARIABLE	Grupo de Prueba	Falsos Positivos
TASA (PROMEDIO)	15.78%	16.20%
PLAZO (PROMEDIO)	1737.83	1702.68
DESC_DEPARTAMENTO_LA PAZ	103	5
DESC_DEPARTAMENTO_SANTA CRUZ	602	33
ACT_ECONOMICA_AGRICULTURA Y GANADERIA	14	0
ACT_ECONOMICA_CONSTRUCCION	78	4
ACT_ECONOMICA_EDUCACION	177	4
ACT_ECONOMICA_VENTA AL POR MAYOR Y MENOR	71	4
ACTIVIDAD ECONÓMICA_PRODUCION Y DISTRIBUCION DE ENERGIA ELECTRICA GAS Y AGUA	26	2
ACTIVIDAD ECONÓMICA_EXTRACCION DE PETROLEO CRUDO Y GAS NATURAL	34	3
ACTIVIDAD ECONÓMICA_INDUSTRIA MANUFACTURERA	11	2
TIP_ACT_ECO_I	56	8

Fuente: Elaboración propia

Se puede evidenciar que para las variables que el modelo árbol de decisión *performa* de peor manera son tasas más altas, con las actividades económicas de industria manufacturera, extracción de petróleo crudo, y tipo de actividad económica independiente.

Para el modelo de regresión logística utilizando un umbral de 0.45 tenemos los siguientes resultados:



VARIABLE	Grupo de Prueba	Falsos Positivos
TASA (PROMEDIO)	15.78%	16.25%
PLAZO (PROMEDIO)	1737.83	1418.55
DESC_DEPARTAMENTO_LA PAZ	103	8
DESC_DEPARTAMENTO_SANTA CRUZ	602	73
ACT_ECONOMICA_AGRICULTURA Y GANADERIA	14	0
ACT_ECONOMICA_CONSTRUCCION	78	5
ACT_ECONOMICA_EDUCACION	177	9
ACT_ECONOMICA_VENTA AL POR MAYOR Y MENOR	71	6
TIP_ACT_ECO_I	56	7

Fuente: Elaboración propia

Se puede notar que para las variables que el modelo Logit *performa* de peor manera son: tasas de interés más altas, menores días de plazo y con la variable de tipo de actividad económica independiente, resultados similares a los del umbral 0.3.

Para el modelo de árbol de decisión utilizando un umbral de 0.45 se tienen los siguientes resultados, destacando las variables más significativas:

VARIABLE	Grupo de Prueba	Falsos Positivos
TASA (PROMEDIO)	15.78%	16.22%
PLAZO (PROMEDIO)	1737.83	1705.68
DESC_DEPARTAMENTO_LA PAZ	103	6
DESC_DEPARTAMENTO_SANTA CRUZ	602	33
ACT_ECONOMICA_AGRICULTURA Y GANADERIA	14	0
ACT_ECONOMICA_CONSTRUCCION	78	4
ACT_ECONOMICA_EDUCACION	177	4
ACT_ECONOMICA_VENTA AL POR MAYOR Y MENOR	71	4
ACTIVIDAD ECONÓMICA_PRODUCION Y DISTRIBUCION DE ENERGIA ELECTRICA GAS Y AGUA	26	2
ACTIVIDAD ECONÓMICA_EXTRACCION DE PETROLEO CRUDO Y GAS NATURAL	34	3
ACTIVIDAD ECONÓMICA_INDUSTRIA MANUFACTURERA	11	2
TIP_ACT_ECO_I	56	8

Fuente: Elaboración propia

Se puede evidenciar que para las variables que el modelo árbol de decisión *performa* de peor manera son tasas más altas, con las actividades económicas de industria manufacturera, extracción de petróleo crudo, y tipo de actividad económica independiente, resultados similares a los del umbral 0.3.

## 5. Conclusiones:

El COVID 19 y las medidas tomadas para precautelar la salud de la población, como la cuarentena y la paralización de actividades, dejaron un impacto importante para la economía mundial y, sobretodo, para países no desarrollados que dependen de la exportación de sus principales materias primas.

Dado el contexto boliviano, situaciones atípicas como que el empleo informal llegue a niveles del 70-75% en distintos municipios del país, llevó a entender que una paralización de actividades y una cuarentena estricta iba a ocasionar que la gente no cuente con los recursos necesarios para poder pagar sus préstamos. La Autoridad del Sistema Financiero Boliviano (ASFI) implemento como primera medida, el diferimiento de las cuotas de créditos para clientes que vieron afectado su ingreso, como complemento a esta medida, obligó a los Bancos a no deteriorar las calificaciones de riesgo de los prestamistas. Esto generó una distorsión en el monitoreo de la mora del sistema financiero boliviano, ocultando el verdadero impacto de la pandemia en la salud financiera del país. El año 2022, la medida de diferimiento y prórroga fue regularizada y los bancos pudieron comenzar a contabilizar la verdadera mora del sistema. Los datos demuestran que existen ciertos sectores económicos menos riesgosos (Banca Empresas y Banca Productiva), mientras que existen otros con mayor riesgo (Banca Micro y Banca Personas), sobretodo en créditos de consumo. La regulación actual en Bolivia para la medición de los distintos riesgos se encuentra muy por detrás de países desarrollados e inclusive de países vecinos como Argentina y Chile.

El presente trabajo buscó poder introducir dos modelos que son comúnmente utilizados para predecir la probabilidad de incumplimiento de un crédito de consumo, utilizando información otorgada por el cliente, y junto con el apetito del riesgo de la institución, aprobar o rechazar un crédito de consumo. El modelo de regresión logística presento 2 limitaciones principales: la primera es que asume el supuesto de linealidad en escala logarítmica, este supuesto no se está cumpliendo para esta base de datos y la segunda es la sensibilidad ante datos atípicos. Mientras que la principal ventaja es la interpretación de los coeficientes, que permiten cuantificar la influencia de cada variable. El modelo de árbol de decisión tiene 2 ventajas fundamentales: no requiere que las relaciones entre las variables sean lineales y tiene una menor sensibilidad a

valores atípicos en comparación a la regresión logística. La principal desventaja es el *overfitting* o sobreajuste, sin embargo, esta desventaja fue mitigada al limitar las ramificaciones del árbol.

Al separar el total de los datos en 2 grupos (entrenamiento y prueba), se puede comprobar la precisión de ambos modelos. Al realizar el backtesting, se evidencia que ambos modelos predicen de manera correcta una buena proporción de no incumplimientos y de incumplimientos. Las matrices de confusión denotan datos muy similares entre los dos modelos, sin embargo, dado que el trabajo consiste en predecir la probabilidad de incumplimiento, el indicador que más interesa revisar es el de falsos negativos (que el modelo apruebe el préstamo y el préstamo entre en default en el transcurso del tiempo), el modelo que menor falsos negativos presenta es el árbol de decisión para casi todos los umbrales de decisión. Luego de comparar el gráfico de la curva ROC y el score AUC, se evidencia que el modelo de árbol de decisión presenta una leve mejora por sobre el modelo LOGIT. Para comprobar estadísticamente esta afirmación, se hace la prueba de Mann-Whitney U cuyos resultados demuestran que el modelo de árbol de decisión tiene resultados estadísticamente mejores que el modelo LOGIT.

Debido a estas razones, se puede concluir que el modelo de árbol de decisión brinda mayor un mejor desenvolvimiento para este caso de estudio y una mayor libertad para futuros proyectos similares. Si bien se intuía este resultado, se podía inferir también que la regresión logística trabaja mejor con datos estructurados, como los utilizados en este caso, sin embargo, para este caso, se evidencia que el árbol de decisión resulta el mejor modelo.

El modelo de árbol de decisión es mejor porque no exige el supuesto de normalidad, al ser un modelo no paramétrico permite separar los datos.

A medida que el banco decide aumentar su apetito al riesgo, el modelo de árbol de decisión gana mayor preponderancia.

## 6. Recomendaciones:

La normativa boliviana no da ningún lineamiento para la utilización de modelos estadísticos o de carácter predictivo para la medición de los distintos riesgos que presentan las instituciones financieras, la regulación local del riesgo de crédito se limita a la revisión posterior de ocurrido el incumplimiento, a través de la previsión genérica y específica. En el marco internacional, Basilea II ya hace referencia a modelos internos para la predicción de la probabilidad

incumplimiento, y con el paso del tiempo el comité de Basilea profundiza más en la utilización de modelos estadísticos. El ente regulador y las entidades de intermediación financiera deberían comenzar a adecuarse a estándares internacionales, tomando las recomendaciones del comité de Basilea para una mejor gestión del riesgo.

El contexto macroeconómico debería impulsar al ente regulador a liberar ciertas tasas activas, que actualmente se encuentran reguladas, para que la banca nacional pueda volverse más eficiente y pueda gestionar de mejor manera su cartera de créditos, buscando el mayor rendimiento con el menor riesgo posible.

El modelo de regresión logística es históricamente el más utilizado para la medición de la probabilidad de incumplimiento, sin embargo, la disrupción de nuevos instrumentos y herramientas tecnológicas, permiten el desarrollo de nuevos modelos. Si bien el capital regulatorio tiene fundamentos ya incorporados, las entidades financieras junto con el ente regulador deberían explorar estos modelos para la medición del capital económico, precautelando los depósitos de los ahorristas y la salud financiera del país.

Se tuvieron ciertos inconvenientes al momento de ordenar, limpiar y depurar la información, evidenciando ciertos vacíos e incongruencias sobretodo en la variable de actividad económica. Se realiza la recomendación a la entidad de incluir procesos de controles para un mejor control y gestión.

El score crediticio no exime al banco de los procesos normativos, los resultados denotan la necesidad de un cambio en la matriz del esquema crediticio. Dando mayor relevancia a la gestión de seguimiento y cobranza desde el primer filtro, que es el área comercial.

Ambos modelos *performan* de peor manera con tasas de interés más altas y con tipo de actividad económica independiente, esto se da debido a que clientes que trabajan de manera independiente presentan mayor volatilidad en sus ingresos, presenta más *outliers* respecto a la media, complicando la captura precisa de esta variable.

## 7. Bibliografía:

- Altman, Edward I. (2000). Predicting financial distress of companies: Revisiting the Z-score and ZETA models. Stern School of Business, New York University, 9-12.

- Altman, E. I. (2017). *Corporate Financial Distress and Bankruptcy: Predict and Avoid Bankruptcy, Analyze and Invest in Distressed Debt*.
- Atiya, A. F. (2001). Bankruptcy prediction for credit risk using neural networks: A survey and new results. *IEEE Transactions on Neural Networks*, 12(4), 929-935.
- Autoridad de Supervisión del Sistema Financiero, *Recopilación de Normas para Entidades de Intermediación Financiera*.
- Baesens, B., Roesch, D., & Scheule, H. (2017). *Credit Risk Analytics: Measurement Techniques, Applications, and Examples in SAS*.
- Bank for International Settlements. Basel III: “International framework for liquidity risk measurement, standards and monitoring”, Dec 2010.
- Bessis, J. "Risk Management in Banking" 4th Ed. John Wiley & Sons, 2015.
- Bessis, J. "Risk Management in Banking". John Wiley & Sons, 2002
- Bluhm, C., L. Overbeck, and C. Wagner "An Introduction to Credit Risk Modelling" Boca Raton, Fla.: Chapman & Hall/CRC, 2003.
- Boyd, D., & Crawford, K. (2012). Critical questions for big data. *Information, Commun.*
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and Regression Trees*. Monterey, CA: Wadsworth, Inc.
- Carter, C., & Carlett, J. (1987). Assessing Credit Card Applications Using Machine Learning. *IEEE Expert*, 2(3), 71-79.
- Crook, J., Belloti, T. "Credit Scoring with macroeconomic variables using survival analysis", *Journal of the Operational Research Society*, 2009.
- Crouhy, M., Galai, D., & Mark, R. (2006). *The Essentials of Risk Management*.
- David S. Moore, George P. McCabe, & Bruce A. Craig (2021). *Introduction to the Practice of Statistics*.
- Desai, V. S., Crook, J. N., & Overstreet, G. A. (1996). A comparison of neural networks and linear scoring models in the credit union environment. *European Journal of Operational Research*, 95(1), 24-37.
- Fawcett, T. (2006). *An introduction to ROC analysis*.
- Fitch Ratings. (2019). *Global Rating Criteria for Non-Financial Corporates*.

- Ghailan, O., Mokhtar, H. M. O., & Hegazy, O. (2016). Improving Credit Scorecard Modeling Through Applying Text Analysis. 7(4).
- Gujarati, D. (2003). *Econometría*. México, D. F. McGraw-Hill.
- Gutiérrez Girault, M. A. (2007). *Modelos de Credit Scoring. Qué, Cómo, Cuándo y Para Qué*. Banco Central de la República Argentina.
- Hernandez, R. (1996). *Metodología de la Investigación*. Mexico Distrito Federal.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression*. John Wiley & Sons.
- Löffler, Gunter y Peter N. Posch "Credit risk modeling using Excel and VBA" Chichester, England: John Wiley & Sons Ltd, 2007.
- Mann, H. B., & Whitney, D. R. (1947). Test of Whether one of Two Random Variables is Stochastically Larger than the Other.
- McAfee, A., Brynjolfsson, E., Davenport, T. H., Patil, D. J., & Barton, D. (2012). *Big data: The management revolution*. Harvard business.
- Medina, R. S. (2007). *El riesgo de crédito en el marco del acuerdo de Basilea II*. Delta Publicaciones.
- Mendez, C. (2000). *Guía para elaborar diseños de investigación*.
- Merton, R. C. (1974). On the Pricing of Corporate Debt: The Risk Structure of Interest Rates. *The Journal of Finance*.
- Munafo, F. (2018). Aplicación del modelo de Merton utilizando VBA. *Revista de investigación en Modelos Financieros*, 07(01), 109-123.
- Naghi, M. (2008). *Metodología de la Investigación*.
- Perez Ramirez, F. O., & Fernandez Castaño, H. (2007). Las redes neuronales y la evaluación del riesgo de crédito. *Revista Ingenierías Universidad de Medellín*, 6(10), 77-91.
- Prado, R. (2018). *Advances in Financial Machine Learning*. John Wiley & Sons.
- Saavedra García, M. L., & Saavedra García, M. J. (2010). *Modelos para medir el riesgo de crédito de la banca*. Cuadernos de administración.
- Samprit Chatterjee & Ali S. Hadi (2006). *Regression Analysis by Example*.
- Saunders, A. y L. Allen "Credit Risk Measurement", Wiley, 2002.

- Scandizzo, S. (2016). The validation of risk models.
- Sellitz, C. (2003). Metodología de investigación en las relaciones sociales.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*.
- UPEL. (2002). *Manual de Trabajos de Grado*. Caracas.
- Wei, R. (2008). Development of credit risk model based on Fuzzy theory and its application for credit risk management of commercial banks in China. 4th International Conference on Wireless Communications, Networking and Mobile Computing, 1-31 , 10339-10342.
- West, D. (2000). Neural network credit scoring models. *Computers and Operations Research*, 27(11-12), 1131–1152.

## 8. Anexos:

### 8.1. Scripts Python:

- Importar librerías

```
import pandas as pd
import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt
import matplotlib.pyplot as plt
import statsmodels.api as sm
import statsmodels.formula.api as smf
from sklearn.linear_model import LogisticRegression
from sklearn.feature_selection import RFE
from sklearn.model_selection import train_test_split
from statsmodels.graphics.regressionplots import plot_partial_residuals
from sklearn.metrics import confusion_matrix, classification_report, roc_auc_score, roc_curve, accuracy_score
from sklearn import linear_model
from sklearn import model_selection
from sklearn.metrics import classification_report
from sklearn.metrics import confusion_matrix
from sklearn.metrics import accuracy_score
from sklearn.tree import DecisionTreeClassifier
from sklearn.tree import plot_tree
from statsmodels.stats.weightstats import ttest_ind
%matplotlib inline
```

- Importar archivo desde Excel:

```
dataframe = pd.read_excel(r'C:\Users\andres.patino\Documents\Documentos\Tesis Maestría UBA\Datosdic.xlsx')
print(dataframe)
```

- Histograma

```
plt.hist(dataframe['DESC_DEPARTAMENTO'], bins=None, range=None, density=False, cumulative=False, color=None, edgecolor='black')
font = {'family': 'Arial', 'color': 'black', 'weight': 'bold', 'size': 11}
plt.xlabel('Departamento', fontdict=font)
plt.ylabel('Frecuencia', fontdict=font)
plt.title('Histograma', fontdict=font)
plt.xticks(fontname='Arial', fontsize=8.5)
plt.yticks(fontname='Arial', fontsize=8.5)
plt.show()
```

- Convertir variables dummy/catóricas:

```
dataframe = pd.get_dummies(dataframe, columns=['DESC_DEPARTAMENTO'], prefix='DESC_DEPARTAMENTO', drop_first=True)
dataframe = pd.get_dummies(dataframe, columns=['ACTIVIDAD ECONOMICA'], prefix='ACT ECONOMICA', drop_first=True)
dataframe = pd.get_dummies(dataframe, columns=['TIP_ACT_ECO'], prefix='TIP_ACT_ECO', drop_first=True)
dataframe.head()
```

- Definir las variables independientes (x) y la variable dependiente(y):

```
x = dataframe.drop(['DEFAULT'],1)
y = dataframe['DEFAULT']
```



- Separar los datos para entrenamiento y para probar los resultados:

```
x_train, x_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
```

- Regresión logística con los datos de entrenamiento:

```
logit_model=sm.Logit(y_train,x_train)
result=logit_model.fit()
print(result.summary())
```

- Gráfico de dispersión de residuos versus valores ajustados:

```
residuals = model.resid_response
```

```
plt.scatter(model.fittedvalues, residuals)
plt.xlabel('Valores Ajustados')
plt.ylabel('Residuos')
plt.title('Análisis de Residuos')
plt.axhline(y=0, color='r', linestyle='--') # Línea de referencia en y=0
plt.show()
```

- Histograma de residuos:

```
plt.hist(residuals, bins=20)
plt.xlabel('Residuos de la Respuesta')
plt.ylabel('Frecuencia')
plt.title('Histograma de Residuos')
plt.show()
```

- Gráfico Q-Q de Residuos:

```
sm.qqplot(residuals, line='s')
plt.title('Gráfico Q-Q de Residuos')
plt.show()
```

- Árbol de decisión con los datos de entrenamiento:

```
model = DecisionTreeClassifier()
model.fit(X_train, y_train)
plot_tree(decision_tree=model, feature_names=X.columns, filled=True);
```

- Árbol de decisión con limitando las ramificaciones:

```
model = DecisionTreeClassifier(max_depth=4)
model.fit(X_train, y_train)
plt.figure(figsize=(21, 21))
plot_tree(decision_tree=model, feature_names=X.columns, filled=True, fontsize=10);
```

- Se realiza la matriz de confusión:

```
y_pred = model.predict_proba(X_test)[:,-1]
```

```
y_pred_probabilities = y_pred
```

```
threshold = 0.3
```

```
y_pred_labels = (y_pred_probabilities >= threshold).astype(int)
```

```
cm = confusion_matrix(y_test, y_pred_labels)
```

```
plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt="d", cmap="Blues", cbar=False, annot_kws={"size": 15})
plt.xlabel('Etiquetas_Arbol_Decisión')
plt.ylabel('Etiquetas_Reales')
plt.title('Matriz de Confusión - Umbral 0.9')
plt.show()
```

- Se gráfica la curva ROC:

```
fpr, tpr, thresholds = roc_curve(y_test, y_pred)
plt.plot(fpr, tpr)
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('ROC Curve')
plt.show()
```

- Calcular el score AUC:

```
roc_auc_score(y_test, y_pred)
```

- Test de Mann-Whitney U:

