



**BIBLIOTECA INFOTEC
VISTO BUENO DE TRABAJO TERMINAL**

**Maestría en Ciencia de Datos e Información
(MCDI)**

Ciudad de México, a 20 de enero de 2025

**UNIDAD DE POSGRADOS
PRESENTE**

Por medio de la presente se hace constar que el trabajo de titulación:

“Modelo de medición de riesgo del crédito mediante técnicas de aprendizaje computacional”

Desarrollado por el alumno: **Gaspar García Báez**, bajo la asesoría de la **Dra. Briceyda Berenice Delgado López** y el **Dr. Edgar González Fernández**, cumple con el formato de Biblioteca, así mismo, se ha verificado la correcta citación para la prevención del plagio; por lo cual, se expide la presente autorización para entrega en digital del proyecto terminal al que se ha hecho mención. Se hace constar que el alumno no adeuda materiales de la biblioteca de INFOTEC.

No omito mencionar, que se deberá anexar la presente autorización al inicio de la versión digital del trabajo referido, con el fin de amparar la misma.

Sin más por el momento, aprovecho la ocasión para enviar un cordial saludo.



Dr. Juan Antonio Vega Garfias
Subgerente de Innovación Gubernamental



JAVG/jah

C.c.p. Mtra. Anely Mendoza Rosales. – Encargada de la Gerencia de Capital Humano. - Para su conocimiento.
Gaspar García Báez. - Alumno de la Maestría en Ciencia de Datos e Información. – Para su conocimiento.



INFOTEC CENTRO DE INVESTIGACIÓN E
INNOVACIÓN EN TECNOLOGÍAS DE LA
INFORMACIÓN Y COMUNICACIÓN

DIRECCIÓN ADJUNTA DE INNOVACIÓN Y
CONOCIMIENTO
GERENCIA DE CAPITAL HUMANO
POSGRADOS

MODELO DE MEDICIÓN DE RIESGO DE CRÉDITO MEDIANTE TÉCNICAS DE APRENDIZAJE COMPUTACIONAL

Implementación de proyecto laboral
Que para obtener el grado de MAESTRO EN CIENCIA DE
DATOS E INFORMACIÓN

Presenta:

Gaspar García Báez

Asesor:

Dra. Briceyda Berenice Delgado López

Coasesor:

Dr. Edgar González Fernández

Ciudad de México, Mayo, 2024

Agradecimientos

A mi madre, por el apoyo incondicional y su amor que tiende hacia el infinito; gracias por ser la más grande guía en mi vida. A Eli, por nunca soltar mi mano y acompañarme en todas mis locuras; te amaré hasta que se descubra el último decimal de π . A mi hermano, por compartir conmigo tu alegría y entusiasmo desde mi primer día en este mundo; siempre serás mi hermano favorito (y único). Para mi Michi, que estuvo conmigo en cada una de las desveladas mientras daba forma a este trabajo.

Sin ustedes, nada de esto sería posible.

Tabla de contenido

Glosario	8
Siglas	9
Introducción	1
1. Trabajos Previos	5
1.1. Componentes del Riesgo de Crédito	5
1.1.1. Modelos de Probabilidad de Incumplimiento	7
1.1.2. Modelos de Severidad de la Pérdida	8
1.1.3. Modelos de Exposición al Incumplimiento	9
1.2. Modelos de VaR de Crédito	10
1.2.1. CreditMetrics	10
1.2.2. Modelo KMV	11
1.2.3. CreditRisk +	12
1.2.4. CreditPortfolioView	12
2. Metodología Propuesta	15
2.1. Objetivos y Alcance	15
2.2. Descripción del Modelo Propuesto	16
2.3. Proyecto para la Implementación del Modelo	19
2.3.1. Adquisición de Información	19
2.3.2. Modelos de Componentes de Riesgo	20
2.3.3. Implementación Cálculo del VaR	21
2.3.4. Elaboración del Aplicativo	21
3. Modelos de Componentes de Riesgo	24
3.1. Modelo de Probabilidad de Incumplimiento	24
3.1.1. Definición de Probabilidad de Incumplimiento	24
3.1.2. Generación de Series Históricas	26

3.1.3. Segmentación de Población	27
3.1.4. Identificación de Predictores	35
3.1.5. Modelado de la PD	50
3.2. Modelo de Severidad	65
3.3. Modelo de Exposición	69
4. Implementación del Cálculo VaR	72
4.1. Integración de Modelos	72
4.2. Resultados Obtenidos	74
4.3. Trabajos Futuros	77
4.4. Conclusiones	80
Bibliografía	84

Índice de figuras

2.1. Modelo propuesto para implementación y cálculo del VaR.	18
2.2. Etapas proyectadas del proyecto.	19
2.3. Actividades del proyecto previstas.	20
3.1. Series históricas de PD.	27
3.2. Series de PD por grupos de productos.	29
3.3. Series de PD por grupo de actividad.	30
3.4. Series de PD por grupo de agencias.	31
3.5. Distribución geográfica de las agencias.	32
3.6. Series de PD de los grupos finales.	33
3.7. Caracterización de los grupos finales.	34
3.8. S&P500.	39
3.9. Inversión Fija Bruta.	39
3.10. Correlaciones observadas entre predictores y la PD del Grupo 1.	41
3.11. Composición porcentual del Grupo 1.	41
3.12. Correlaciones observadas entre predictores y la PD del Grupo 2.	42
3.13. Composición porcentual del Grupo 2.	43
3.14. Correlaciones observadas entre predictores y la PD del Grupo 3.	43
3.15. Composición porcentual del Grupo 3.	44
3.16. Correlaciones observadas entre predictores y la PD del Grupo 4.	45
3.17. Composición porcentual del Grupo 4.	45
3.18. Information Value por grupo.	47
3.19. Information Value por grupo (Interno).	50
3.20. Modelos e hiperparámetros evaluados.	53
3.21. Métricas de desempeño aplicadas.	55
3.22. Ejemplo de resultado con alta variabilidad en predicciones.	56
3.23. Esquema de modelo PD con ensamble de modelo ARIMA.	57
3.24. Variables predictoras por grupo.	58

3.25. Resultados Grupo 1.	59
3.26. Resultados Globales Grupo 1.	60
3.27. Resultados Grupo 2.	61
3.28. Resultados Globales Grupo 2.	62
3.29. Resultados Grupo 3.	62
3.30. Resultados Globales Grupo 3.	63
3.31. Resultados Grupo 4.	64
3.32. Resultados Globales Grupo 4.	64
3.33. Importancia variables predictoras.	66
3.34. Variables predictoras incorporadas al modelo.	67
3.35. MAE en Validación Cruzada.	68
3.36. Resultados modelo LGD.	69
3.37. Distribución EAD.	70
4.1. Modelo propuesto para cálculo del VaR.	73
4.2. Distribución pérdidas simuladas vs reales observadas	75
4.3. Comparación de estimaciones de PE.	76

Índice de cuadros

3.1. Fuentes de información macroeconómica.	36
3.2. Detalle de variables macroeconómicas.	38
3.3. Descripción de variables a nivel cliente.	49

Glosario

Backtesting Es un término que se usa en el contexto de elaboración de modelos predictivos para referirse a las pruebas que se aplican utilizando datos históricos. El backtesting es un tipo especial de validación cruzada aplicada a períodos de tiempo anteriores.

Disposiciones Disposiciones de Carácter General en Materia Prudencial, Contable y para el Requerimiento de Información Aplicables a la Financiera Nacional de Desarrollo Agropecuario, Rural, Forestal y Pesquero.

Ley Orgánica Ley Orgánica de la Financiera Nacional de Desarrollo Agropecuario, Rural, Forestal y Pesquero.

Rating Los ratings son evaluaciones que indican el riesgo de crédito de una compañía, administración pública o producto financiero. En muchos casos son utilizadas en los mercados de capitales como referencia a la hora de tomar decisiones de inversión.

Simulación Montecarlo El método de Simulación Monte Carlo es un método estadístico (no determinístico) que proporciona soluciones aproximadas a una gran variedad de problemas matemáticos, haciendo factible la realización de experimentos con muestreos de números pseudoaleatorios en una computadora. El método es aplicable a cualquier tipo de problema, ya sea estocástico o determinístico.

Siglas

ARIMA Auto-Regresivos Integrados de Media Móvil.

BIS *Bank for International Settlements.*

CAIR Comité de Administración Integral de Riesgo.

CCF Factor de Conversión de Crédito.

CNBV Comisión Nacional Bancaria y de Valores.

DD Distancia al Default.

EAD Exposición al Incumplimiento.

EDF Frecuencia de Default Esperada.

FND Financiera Nacional de Desarrollo Agropecuario, Rural, Forestal y Pesquero.

INEGI Instituto Nacional de Estadística y Geografía.

IV *Information Value.*

KDD *Knowledge Discovery in Databases.*

LGD Severidad de la Pérdida.

MiPyMEs Micro, Pequeñas y Medianas Empresas.

PD Probabilidad de Incumplimiento.

PE Pérdida Esperada.

PiP Proveedor Integral de Precios.

SMN Servicio Meteorológico Nacional.

UAIR Unidad para la Administración Integral de Riesgo.

VAR Vectores Auto-Regresivos.

VaR Valor en Riesgo.

Introducción

La Financiera Nacional de Desarrollo Agropecuario, Rural, Forestal y Pesquero (FND) es un organismo descentralizado de la Administración Pública Federal, sectorizado en la Secretaría de Hacienda y Crédito Público, que impulsa el desarrollo del medio rural a través de financiamiento incluyente para productores y Micro, Pequeñas y Medianas Empresas (MiPyMEs). Su misión es impulsar el desarrollo del medio rural y de las actividades del sector primario, a través del crédito y servicios financieros accesibles a productores, intermediarios financieros rurales y otros agentes económicos, con la finalidad de elevar la productividad y contribuir a mejorar el nivel de vida de la población.

Al tratarse de una institución financiera, la FND se encuentra supervisada y regulada por la Comisión Nacional Bancaria y de Valores (CNBV) mediante su Ley Orgánica [DOF, 2002], así como las Disposiciones [CNBV, 2006]. En este sentido, las Disposiciones establecen que la FND debe conformar al Comité de Administración Integral de Riesgo (CAIR) y a la Unidad para la Administración Integral de Riesgo (UAIR), así mismo, determina las funciones y competencias de dichos órganos dentro de la misma FND, entre las que se destacan la propuesta y aprobación de metodologías, modelos y parámetros para identificar, medir, vigilar, limitar, controlar, informar y revelar los distintos tipos de riesgos a que se encuentra expuesta la FND.

En particular, dada la naturaleza de sus operaciones y de su población objetivo, la FND se encuentra altamente expuesta al riesgo de crédito, el cual, de acuerdo con [Ken Brown, 2014], se puede definir como «la posibilidad de que una de las partes de un contrato falle en el cumplimiento de sus obligaciones de acuerdo con los términos pactados», o bien, para el caso específico de las instituciones financieras, como es la FND, [Bart Baesens, 2008] indica que se puede definir como «el riesgo de que un prestatario incumpla y no honre su obligación de hacer frente a la deuda».

Aunado a lo anterior, [Bart Baesens, 2008] establece que el riesgo de crédito es el tipo de riesgo que mayores pérdidas potenciales puede generar a las instituciones financieras,

por lo que la normativa mexicana emitida por la CNBV, así como la emitida por distintos organismos internacionales, como el *Bank for International Settlements* (BIS) [BIS, 2010], instan a los distintos organismos financieros a mantener una medición y control sobre el nivel de riesgo de crédito que asumen, con la finalidad de reducirlo.


De manera puntual, la CNBV permite a las instituciones financieras el uso de modelos de elaboración interna para la medición del riesgo de crédito de sus carteras, abriendo la posibilidad de adaptarlos a los requerimientos de cada entidad. En esta línea, se ha observado que el sector financiero cuenta con distintos enfoques y modelos para la medición de este tipo de riesgo, resaltando aquellos compilados y contrastados en los artículos de [Michel Crouhy, 2000] y [Onmus-Baykal, 2010], así como los enfoques más recientes recopilados por [Rogojan et al., 2023].

De esta manera, se ha advertido que, los modelos de riesgo de crédito utilizados por la FND no utilizan las técnicas y herramientas actuales de ciencia de datos y aprendizaje computacional. Por lo que en este trabajo, se pretende desarrollar un nuevo modelo de medición de riesgo de crédito que permita mejorar la estimación de las pérdidas esperadas mediante la incorporación de diferentes técnicas de aprendizaje computacional, robusteciendo el cálculo del riesgo de crédito de la FND, utilizando conjuntos de datos tanto internos como externos, aplicando métodos de preprocesamiento y análisis exploratorio de datos para identificar patrones y correlaciones clave.

El documento está estructurado de la siguiente manera: en el Capítulo 1, se lleva a cabo una revisión exhaustiva de la literatura existente, enfocándose en particular en los modelos para la estimación de componentes de riesgo y el cálculo del Valor en Riesgo (VaR) de crédito. El Capítulo 2 detalla de manera exhaustiva la metodología empleada, abarcando tanto la arquitectura del modelo propuesto como la descripción del proyecto para la implementación del VaR. En el Capítulo 3, se analizan detalladamente los modelos específicos generados para los componentes de riesgo y su aplicación dentro del contexto de la FND.

Finalmente, el Capítulo 4 detalla la integración de los modelos de componentes de riesgo para realizar la estimación del VaR de crédito y muestra los resultados obtenidos.

Además, se incluye una sección de trabajos futuros, donde se esbozan las direcciones para investigaciones futuras, destacando áreas de oportunidad para el desarrollo continuo y la mejora de las metodologías, así como las conclusiones del presente trabajo, donde se resumen los resultados clave obtenidos, en particular, se destaca que la incorporación de técnicas avanzadas de ciencia de datos ha resultado en una mejora significativa en la precisión de la evaluación del riesgo de crédito de la FND respecto del modelo vigente, y cómo esta precisión mejorada facilita la toma de decisiones más fundamentadas y contribuye a la mitigación efectiva de los riesgos asociados, evidenciando el impacto positivo y práctico de la investigación realizada.

The background features a complex arrangement of light gray geometric elements. On the left, there are concentric circular patterns with various line styles (solid, dashed, dotted) and small rectangular segments. Scattered throughout are various line segments, some horizontal, some diagonal, and some forming larger shapes like hexagons. Small arrows and dots are also present, adding to the technical or architectural feel of the design.

Capítulo 1

Trabajos Previos

1 Trabajos Previos

Como se mencionó en la Introducción, la FND opera como un organismo financiero descentralizado y sectorizado que impulsa el desarrollo del medio rural a través de esquemas de financiamiento, por lo que se cataloga como una institución financiera y, como tal, es regulada por la CNBV, quien instan a mantener una medición y control sobre el nivel de riesgo de crédito asumido.

En este sentido, la CNBV permite a las instituciones financieras el uso de modelos de elaboración interna para la medición del riesgo de crédito, abriendo la posibilidad de desarrollar modelos que se adapten de mejor manera a los requerimientos de cada entidad.

Actualmente, el modelo utilizado por la FND para la gestión del riesgo de crédito tiene un enfoque de estimación de pérdidas máximas potenciales, calculadas mediante el VaR de la cartera. Algunos modelos con características similares son descritos en el trabajo de [Michel Crouhy, 2000] así como en el artículo de [Onmus-Baykal, 2010]. Estos modelos se discuten en detalle en la Sección 1.2, y se revisarán en el contexto del nuevo modelo propuesto en la Sección 2, donde se recuperan algunos aspectos a partir de los modelos presentes en la literatura.

Pero antes de adentrarnos en estos modelos, es esencial tener una comprensión sólida de los componentes fundamentales del riesgo de crédito, ya que constituyen la base para cualquier modelo relacionado. La Sección 1.1 ofrece una exploración exhaustiva de estos componentes y examina los enfoques existentes.

1.1. Componentes del Riesgo de Crédito

El riesgo de crédito es una consideración esencial en el ámbito financiero, especialmente para las instituciones que otorgan créditos y préstamos. Este se refiere a «el riesgo de que un prestatario incumpla y no honre su obligación de hacer frente a la

deuda» [Bart Baesens, 2008], lo que puede resultar en pérdidas financieras para la entidad crediticia. Para gestionar y mitigar eficazmente este riesgo, es crucial entender sus componentes fundamentales y cómo interactúan entre sí.

En este apartado, se exploran en detalle los tres componentes clave del riesgo de crédito: la Probabilidad de Incumplimiento (PD), la Exposición al Incumplimiento (EAD) y la Severidad de la Pérdida (LGD). Cada uno de estos elementos juega un papel crítico en la determinación del nivel de riesgo asociado a un crédito y, por ende, en la evaluación global del riesgo de crédito de una cartera. De acuerdo con [de Lara Haro, 2019], estos componentes se pueden resumir de la siguiente manera:

- Probabilidad de Incumplimiento (*Probability of Default*): La PD se define como la probabilidad de que un deudor incumpla con sus obligaciones de pago derivadas del otorgamiento de un crédito, generalmente dentro de un periodo anual.
- Exposición al Incumplimiento (*Exposure at Default*): La EAD se refiere al monto o saldo de la deuda que un cliente deberá al momento de caer en incumplimiento de pago.
- Severidad de la Pérdida (*Loss Given Default*): La LGD se define como la proporción de un crédito en incumplimiento que ya no será recuperado en el futuro, el cual generalmente es expresado como fracción de la EAD.

En conjunto, estos componentes conforman lo que se conoce como Pérdida Esperada (PE), la cual es un indicador que se puede entender como el nivel de pérdidas (en unidades monetarias) en las que una institución espera incurrir derivado del riesgo inherente en la actividad de otorgamiento de créditos. La relación de la PE con las componentes mencionadas anteriormente es descrita mediante la siguiente expresión [de Lara Haro, 2019]:

$$PE = PD \times LGD \times EAD \quad (1.1)$$

Esta ecuación subraya la necesidad crítica de desarrollar modelos robustos para esti-

mar cada componente del riesgo de crédito, pues cada factor juega un papel crucial en la determinación precisa de la PE. En las subsecciones siguientes, se exploran en detalle los modelos propuestos por diversos autores, ofreciendo una visión integral de las metodologías existentes para estimar cada componente del riesgo de crédito.

1.1.1. Modelos de Probabilidad de Incumplimiento

Una parte fundamental en la elaboración de los modelos de VaR de crédito, es la estimación de la PD. Esta estimación se puede realizar mediante diversos enfoques, por ejemplo, con el uso de información histórica y matrices de transición, tal como propone el modelo CreditMetrics [[RiskMetrics Group, 1997](#)]; utilizando modelos que relacionan los activos y el balance financiero de un cliente con su PD, como en el caso del modelo KMV [[Merton, 1974](#)]; o bien, mediante regresiones logísticas que incorporan información de indicadores macroeconómicos (variables que representan la condición económica general de un país, como el producto interno bruto, la tasa de desempleo, la inflación, entre otros) a la estimación, como en el modelo CreditPortfolioView [[Wilson, 1997](#)]. Todos estos enfoques se examinan con mayor detalle en la sección 1.2.

Sin embargo, existe un enfoque adicional para el cálculo de la PD, aunque aplicable en un contexto ligeramente distinto. En particular, los modelos expuestos previamente se enfocan en la gestión y cálculo de PD para los créditos ya otorgados por la institución, mientras que el segundo enfoque es más utilizado para la evaluación de solicitudes de créditos que aún no han sido otorgados, a este último tipo de herramientas se les conoce en la jerga financiera como modelos de *scoring*.

En particular, en el artículo de [[Paleologo et al., 2010](#)] se presenta una metodología aplicable para la elaboración de este tipo de modelos, basada en una muestra de clientes italianos de IBM *Global Financing Services*, haciendo hincapié en los procesos de validación de los modelos y en los criterios de selección de los mismos.

Por su parte, en el artículo de [[Dassatti, 2019](#)] también se realiza una revisión de distintos modelos de *scoring*, así como de la metodología empleada para su elaboración, lo cual incluye las métricas que permiten medir el desempeño de los modelos y realizar

comparativas entre ellos. Adicionalmente, este trabajo incluye una evaluación del grado de implementación de modelos de *score* en Uruguay, la cual muestra que un 57 % de las empresas financieras entrevistadas en dicho país cuentan con, al menos, un modelo de este tipo, en contraste, apenas un 14 % de las empresas dijeron que cuentan con un modelo que permita dar seguimiento al riesgo de crédito de los créditos ya otorgados.

En resumen, la estimación de la PD resulta un elemento crítico en la gestión del riesgo de crédito y se puede abordar desde múltiples perspectivas. La elección del modelo adecuado dependerá en gran medida del contexto específico y de los datos disponibles para cada institución financiera.

1.1.2. Modelos de Severidad de la Pérdida

La literatura de administración de riesgos suele prestar mayor atención a la estimación de la PD que al cálculo de la LGD, sin embargo, este último componente también es un factor de suma importancia en lo que respecta a la estimación del riesgo de crédito.

En general, la LGD suele estar relacionada con los distintos tipos de garantías o colaterales asociados a un crédito, así mismo, esta componente puede presentar variaciones en función de las condiciones de ciertos factores macroeconómicos y estar correlacionada con el comportamiento de la PD, sin embargo, en la práctica, generalmente se asume que la PD y LGD tienen comportamientos independientes.

En esta línea, los artículos de [Bellotti and Crook, 2012] y de [Yashkir and Yashkir, 2013] describen una metodología para la elaboración de un modelos de predicción de LGD, así mismo, comparan el desempeño obtenido por estos modelos, aplicándolos a los datos de tarjetas de crédito minoristas del Reino Unido y el conjunto de S&P LossStats (2011), respectivamente. Así mismo, en el trabajo de [Bellotti and Crook, 2012] se propone e incorpora una relación entre la evolución de ciertas variables macroeconómicas y la predicción de la LGD.

En síntesis, aunque la LGD ha sido históricamente menos enfatizada en comparación con la PD, su importancia en la evaluación integral del riesgo de crédito es innegable,

contribuyendo significativamente a la robustez de su gestión.

1.1.3. Modelos de Exposición al Incumplimiento

Por su parte la EAD es, posiblemente, el componente del riesgo de crédito que cuenta con menor análisis teórico. Sin embargo, forma parte crucial del cálculo de la PE y su estimación ha tomado mayor relevancia en los últimos años, luego de su incorporación en los requerimientos de Basilea II [[Janet Zhao, 2019](#)].

De manera general, la EAD se puede entender como el monto que se espera que un cliente deba al banco al momento de caer en incumplimiento. Este indicador puede contemplar montos aún no dispuestos por el cliente, pero que podrían incrementar su deuda antes de caer en incumplimiento.

En este sentido, la literatura muestra que se han desarrollado algunos modelos para la estimación de la EAD, donde se hace especial énfasis en aquellos productos con una exposición que varía en el tiempo. Un ejemplo de lo anterior es el modelo descrito en el trabajo de [[Gürtler et al., 2018](#)], quien emplea enfoques teóricos y empíricos para la estimación de la EAD a partir de grandes bases de datos correspondientes al portafolio minorista de un banco europeo, sugiriendo, empíricamente, que el uso del Factor de Conversión de Crédito (CCF) tiene ventajas sobre la EAD al momento de analizar los mejores desempeños de los modelos resultantes.

Por el contrario, en el trabajo de [[Tong et al., 2016](#)] se explora la alternativa de modelar la EAD ignorando la formulación del CCF, a partir de un conjunto de datos de tarjetas de crédito de un banco del Reino Unido, concluyendo que el uso de este tipo de modelos son una buena alternativa a los basados en el CCF, o bien, que ambos tipos de modelos pueden ser combinados para obtener mejores desempeños.

1.2. Modelos de VaR de Crédito

Tras la revisión de los componentes que constituyen el riesgo de crédito, nos adentramos en los modelos especializados en la cuantificación de pérdidas potenciales esperadas, en particular modelos de VaR.

De manera general, en el trabajo de [Linsmeier and Pearson, 2000] se describe el VaR como un estadístico que mide las pérdidas asociadas al movimiento «típico» de determinados factores de riesgo, limitado a un periodo de tiempo y un nivel de confianza definidos anticipadamente. Particularmente, en el contexto de riesgo de crédito, el VaR se calcula como el percentil 95 o 99 de la distribución de pérdidas anuales de la cartera crediticia, las cuales suelen estimarse en función de ciertos factores macroeconómicos, la solidez financiera y/o del historial de pago de los clientes.

Siguiendo esta línea, la literatura muestra que existen distintos enfoques y modelos que permiten estimar la distribución de pérdidas de la cartera, así como el VaR correspondiente. En particular, [Michel Crouhy, 2000] realiza una compilación de los principales modelos de VaR para riesgo de crédito, mediante la cual describe y compara las principales características de estos. En las siguientes secciones se recuperan brevemente las descripciones realizadas, mismas que se complementan con ideas extraídas desde las fuentes originales correspondientes de cada modelo.

1.2.1. CreditMetrics

El modelo CreditMetrics es un modelo propuesto inicialmente por J.P. Morgan [Risk-Metrics Group, 1997], cuya metodología permite relacionar la distribución de pérdidas de una cartera de créditos con las tasas de migración asociadas a la calidad crediticia mostrada por los deudores durante un periodo anual.

En primera instancia, la aplicación de este modelo requiere la especificación de un sistema de calificaciones o Rating, el cual incluye sus respectivas categorías y la matriz de probabilidades de transición asociada a dichas calificaciones. Algunos de los siste-

mas de calificaciones más conocidos y utilizados se corresponden a los desarrollados por empresas calificadoras como Moody's o Standard & Poor's. Dicha información, en conjunto con las tasas de descuento correspondientes, se traduce en la estimación de cambios futuros sobre el valor de una cartera de crédito.

Por su parte, el cálculo del VaR de la cartera requiere la aplicación de técnicas de Simulación Montecarlo, con las cuales se proyecta la distribución de pérdidas futuras asociadas a los cambios en la calidad crediticia de la cartera.

Una de las mayores debilidades de este modelo, es que basa sus cálculos en dos supuestos críticos. En primera instancia, asume que los deudores con las mismas calificaciones tienen la misma probabilidad de incumplimiento, sin considerar situaciones particulares de estos. Por otro lado, el modelo también asume que las probabilidades de migración y, en particular, la probabilidad de incumplimiento, es igual a la frecuencia histórica de migraciones e incumplimientos, lo cual implica que dichas probabilidades se mantiene constantes en el tiempo.

1.2.2. Modelo KMV

KMV (Kecholfer, McQuown y Vasicek) es un modelo con una aproximación estructural, el cual lleva a cabo la estimación de la PD o Frecuencia de Default Esperada (EDF) mediante la implementación del modelo de valuación de activos propuesto inicialmente por [Merton, 1974], el cual, de manera general, se basa en el calculo de la Distancia al Default (DD), la cual es un índice, medido en unidades de desviación estándar, que permite estimar el riesgo o probabilidad de bancarrota de las instituciones. Este indicador es propio de cada contraparte y se calcula en función de la estructura de capital, la volatilidad y el valor de los activos de los deudores evaluados. Posteriormente, mediante el uso de datos históricos, se realiza una mapeo entre la DD y el nivel de la EDF. De esta manera, el modelo permite calcular una distribución analítica de las pérdidas crediticias del portafolio.

Una de las mayores desventajas de este modelo es que el cálculo del riesgo requiere tener acceso a información que no siempre es pública, en particular, información fi-

nanciera específica de las entidades a evaluar, como son el valor del capital y el nivel de activos que se mantienen en balance.

1.2.3. CreditRisk +

El modelo CreditRisk+ mantiene un enfoque actuarial, el cual fue propuesto por Credit Suisse Financial Products en colaboración con CreditRisk+ [Suisse, 1997]. Este modelo no requiere supuestos acerca de las razones del incumplimiento de la contraparte, sino que se basa en la estimación del número de incumplimientos observados en un intervalo de tiempo dado, lo cual es modelado mediante una función de distribución de Poisson.

De manera general, la aplicación de este modelo requiere que el portafolio de crédito sea dividido en grupos o «bandas», de acuerdo con el nivel de exposición o saldo de cada cliente. De esta manera, se asume que el nivel de incumplimiento de cada banda es independiente de las otras, con lo cual, el modelo permite calcular la distribución de pérdidas de manera analítica, mediante el uso de la función generadora de momentos de la distribución de Poisson correspondiente a cada banda.

Una de las debilidades del modelo es que se asume que el nivel de exposición se mantiene constante en el tiempo, además de ser la única variable involucrada en la estimación de la probabilidad de incumplimiento, dejando fuera factores que también pueden influir en el comportamiento de los clientes.


1.2.4. CreditPortfolioView

Por su parte, CreditPortfolioView es un modelo multifactorial desarrollado por [Wilson, 1997], utilizado para estimar la distribución conjunta de la probabilidad de incumplimiento de varios grupos o segmentos de un portafolio crediticio, cuya evolución es relacionada con el comportamiento de ciertos factores macroeconómicos mediante una regresión logística.

A su vez, este modelo asume que cada factor macroeconómico sigue un proceso auto-

regresivo univariado, el cual puede ser estimado de manera independiente mediante modelos macroeconómicos del tipo Vectores Auto-Regresivos (VAR).

El modelo CreditPortfolioView tiene la fortaleza de reconocer cambios en el nivel de riesgo de las contrapartes, en línea con la evolución y la situación macroeconómica vigente, permitiendo generar estimaciones más dinámicas de la probabilidad de incumplimiento.



Capítulo 2

Metodología Propuesta

2 Metodología Propuesta

En este capítulo se presenta la metodología propuesta como alternativa para la evaluación y gestión del riesgo de crédito de la FND. Esta propuesta surge a partir de la revisión del modelo de VaR de crédito vigente, cuyas limitaciones y áreas de oportunidad se han hecho evidentes a través de las pruebas de Backtesting aplicadas. Dado lo anterior, la UAIR ha tomado la iniciativa de abordar estas limitaciones, emprendiendo un proyecto para desarrollar e implementar un modelo más robusto y preciso que pueda adaptarse de manera efectiva a las dinámicas cambiantes del entorno crediticio.

A continuación, se detallan los objetivos, el alcance y los componentes específicos de la metodología propuesta, proporcionando una visión integral de cómo se espera que esta nueva aproximación mejore la gestión del riesgo de crédito en la FND.

2.1. Objetivos y Alcance

La FND, a través de la UAIR, ha reconocido la necesidad de revisar y actualizar la metodología actual del VaR de crédito. Las pruebas de Backtesting realizadas mensualmente han indicado una descalibración en el modelo vigente, señalando así la urgencia de una revisión exhaustiva y una reestructuración completa del modelo. Este proceso tiene como meta no solo corregir las deficiencias actuales, sino también mejorar la precisión y la fiabilidad del VaR para reflejar mejor el riesgo de crédito bajo las condiciones cambiantes del mercado.

En este contexto, se ha iniciado el presente proyecto con la finalidad de desarrollar e implementar una metodología avanzada para la estimación del VaR de crédito. Para lograr este fin, se propone la aplicación de técnicas de vanguardia en ciencia de datos, que incluyen el aprendizaje automático y métodos estadísticos sofisticados como son las técnicas de agrupación o *clustering*, modelos de clasificación basados en árboles, ensambles y redes neuronales, entre otros, con el propósito de desarrollar un modelo más preciso y eficiente. Este modelo está diseñado para mejorar significativamente

la evaluación y gestión del riesgo de crédito en la FND, abordando directamente las deficiencias identificadas en los métodos vigentes y alineándose con las necesidades actuales y futuras de la institución.

La metodología propuesta se fundamenta en un examen exhaustivo de los modelos y enfoques previos, que se han analizado y compilado detalladamente en la sección 1, pero aplicando técnicas más recientes, como las descritas por [Rogojan et al., 2023]. Este análisis ha permitido identificar las fortalezas y debilidades de los métodos existentes, así como las áreas susceptibles de mejora. Basándose en estos hallazgos, se ha desarrollado un nuevo modelo con el siguiente objetivo principal:

«Elaborar un modelo de VaR de crédito que se adapte al contexto único de la FND, incorporando técnicas de ciencia de datos para incrementar significativamente la precisión en las estimaciones de las pérdidas potenciales de la cartera de créditos de la institución»

Además, el alcance de este trabajo incluye la estimación detallada de cada componente del riesgo de crédito, abarcando la PD, LGD y la EAD. Estos componentes son esenciales para calcular las pérdidas máximas potenciales que podría enfrentar la cartera de crédito de la FND. Sin embargo, el presente trabajo pondrá un énfasis particular en el desarrollo y la mejora de los modelos para la predicción de la PD. Este enfoque se justifica por la relevancia crítica de la PD en la estructura de los modelos de VaR, ya que constituye la base para la estimación del riesgo de crédito. Los modelos mejorados de PD permitirán no solo una predicción más precisa de los posibles incumplimientos, sino también una integración más efectiva de estas estimaciones en el cálculo del VaR, mejorando así la capacidad de la FND para gestionar y mitigar los riesgos asociados con su cartera de créditos.

2.2. Descripción del Modelo Propuesto

Actualmente, la FND, a través de la UAIR, realiza la medición del riesgo de crédito de su cartera mediante la implementación de una metodología de VaR. Dicha medición

se realiza de manera mensual, por medio de un sistema informático, el cual aplica modelos VAR para predecir variables macroeconómicas que, a su vez, permiten proyectar la PE de la cartera dentro de un periodo de 12 meses, de manera similar a lo propuesto por el modelo de CreditPortfolioView descrito en la Sección 1.2.4.

El desempeño de este modelo es puesto a prueba por la UAIR de manera mensual, comparando las predicciones realizadas previamente contra los datos realmente observados, en lo que se conoce como pruebas de Backtesting. En particular, la UAIR utiliza la prueba y el estadístico de Kupiec [Zhang and Nadarajah, 2017] para determinar si el modelo se encuentra calibrado o no. Las últimas pruebas han mostrado que el modelo de VaR vigente se encuentra descalibrado, es decir, que sus proyecciones muestran desviaciones significativas respecto de los datos reales, por lo que resulta necesario la actualización de los parámetros del modelo actual o la implementación de nuevos modelos de predicción.

Derivado de lo anterior, la UAIR optó por emprender el proyecto para la elaboración e implementación de un nuevo modelo de VaR, el cual toman como base lo expuesto en las Secciones 1.2 y 1.1, pero incorporando innovaciones en el campo de la ciencia de datos para mejorar la precisión de las estimaciones del riesgo de crédito, además de algunas adaptaciones específicas que posibilitarán su correcta implementación dentro del contexto de la FND.

El modelo propuesto retoma el concepto de probabilidades de transición utilizado en el modelo de CreditMetrics (1.2.1) para la definición y cálculo de la PD histórica. En este sentido, se plantea una analogía entre la transición de calificaciones crediticias y el cambio de la situación contable que muestran los clientes de la FND.

Así mismo, el modelo propuesto incorpora la idea del modelo CreditPortfolioView (1.2.4), el cual relaciona el comportamiento de la PD con la evolución de distintos factores macroeconómicos, sin embargo, al contrario que CreditPortfolioView, la propuesta considera un enfoque a nivel cliente, no por carteras, por lo que resulta adecuado incorporar información específica de cada cliente, en conjunto con técnicas de *scoring* como las descritas en la Sección 1.1.1. Aunado a lo anterior, el modelo propuesto también con-

sidera las ideas expuestas en las Secciones 1.1.2 y 1.1.3 para la estimación de la LGD y EAD.

De esta manera, el cálculo conjunto de la PD, LGD y EAD de cada cliente permitirá llevar a cabo un proceso de Simulación Montecarlo para proyectar incumplimientos individuales, lo cual posibilitará la aproximación de la distribución de la PE y el cálculo del VaR correspondiente para la cartera de crédito, proyectada en un periodo de 12 meses en el futuro.

El siguiente diagrama resume el modelo propuesto para la estimación de la distribución de pérdidas y, en particular, el cálculo del VaR de crédito de la cartera de la FND:




Figura 2.1: Modelo propuesto para implementación y cálculo del VaR.

Fuente: Elaboración propia.

A diferencia de los modelos compilados en la sección 1.2, que estiman el VaR únicamente para aquellas carteras que hayan sido definidas a priori, esta propuesta generará una estimación de PE específica y diferenciada para cada cliente, lo que a su vez permitirá agrupar y presentar los resultados, incluido el VaR, al nivel deseado, segmentando por variables de interés como son los estados de la república, tipo de producto crediticio, plazos, etc. Esto posibilitará un análisis más profundos y a demanda sobre el riesgo de distintas carteras de clientes de la FND

2.3. Proyecto para la Implementación del Modelo

El proyecto planteado para el desarrollo e implementación del modelo propuesto contempla cuatro fases principales, cada una de ellas compuesta por distintas actividades y procesos específicos. El plan de trabajo trazado considera que cada etapa se abordará de manera secuencial, en línea con el siguiente esquema:




Figura 2.2: Etapas proyectadas del proyecto.

Fuente: Elaboración propia.

Implicítamente cada etapa del proyecto considera la implementación de la metodología *Knowledge Discovery in Databases* (KDD), aplicando las cuatro fases correspondientes: preparación, exploración, minería y evaluación. En las siguientes subsecciones se detallan cada una de las etapas descritas en el diagrama de la Figura 2.2.

2.3.1. Adquisición de Información

La primera etapa del proyecto, esencial para el desarrollo e implementación del modelo propuesto, se enfoca en la adquisición de información. Este paso inicial es crítico, ya que la calidad, precisión y relevancia de los datos recopilados influirán directamente en la efectividad de los modelos que se desarrollarán en las etapas posteriores.

La diversidad y complejidad de los datos requeridos exigen una estrategia bien planificada para la adquisición de información. Esta estrategia se basa en la integración de datos provenientes de fuentes internas y externas, cada una con sus características, ventajas y limitaciones específicas, como se describe a continuación:

- Fuentes internas: Se refiere a toda la información que es generada y/o administrada por la misma FND, como pueden ser las bases de datos institucionales, que

albergan los datos históricos de los clientes, así como el comportamiento de pago mostrado por estos a lo largo del tiempo. Estas bases incluyen ciertas variables asociadas a los créditos y clientes, como puede ser el estado de la república en el que se otorgó el crédito, el tipo de producto financiero del que se trata, etcétera.

- Fuentes externas: Estas fuentes se corresponden a aquella información generada por entidades externas a la FND, mismas que deberán tener un carácter oficial para considerar su uso dentro del proyecto. Algunas de las entidades que se consideran como fuentes externas son: Instituto Nacional de Estadística y Geografía (INEGI), Servicio Meteorológico Nacional (SMN), Atlas Nacional de Riesgos, Proveedor Integral de Precios (PiP) e Investing.

2.3.2. Modelos de Componentes de Riesgo

La segunda etapa del proyecto tiene como finalidad elaborar los modelos que permitan predecir los componentes de la pérdida asociada al riesgo de crédito: PD, LGD y EAD. De manera general, el siguiente diagrama (2.3) muestra las actividades previstas dentro de esta etapa.




Figura 2.3: Actividades del proyecto previstas.

Fuente: Elaboración propia.

Para esta etapa, se debe considerar que la elaboración de los modelos de predicción requieren del uso de datos históricos para su entrenamiento. En este sentido, la información de los clientes de la FND se extraerá a partir de la explotación de las bases de datos instituciones. Así mismo, los datos de los factores macroeconómicos se obtendrán a partir de fuentes oficiales, en línea con lo descrito en la Sección 2.3.1.

Por otro lado, como puede observarse en la Figura 2.2, el desarrollo de los modelos requerirá utilizar diversas técnicas de aprendizaje no supervisado, particularmente de *clustering* o agrupamiento, esto para identificar grupos de clientes y actividades económicas con comportamientos de pagos bien diferenciados a lo largo del tiempo, los cuales deberán ser modelados de manera separada.

Como resultado de esta etapa, se espera obtener un conjunto de modelos que permitan predecir las componentes de la PE, utilizando variables propias de los clientes, pero también incorporando información de factores macroeconómicos y modelando por separando los grupos con comportamientos bien diferenciados.

2.3.3. Implementación Cálculo del VaR


La tercera etapa del proyecto consiste en implementar el mecanismo que permita integrar los modelos de predicción de PD, LGD y EAD, para generar una aproximación de la distribución de pérdidas de la cartera, que a su vez, permitirá estimar el VaR de crédito y otros estadísticos adicionales asociados a la cartera de créditos de la FND.

Como ya se mencionó en la Sección 2.2, el cálculo conjunto de los componentes de riesgo de cada cliente permitirá llevar a cabo un proceso de Simulación Montecarlo para proyectar sus incumplimientos, lo cual posibilitará la aproximación de la distribución de la PE y el cálculo del VaR (véase Sección 2.1).

2.3.4. Elaboración del Aplicativo

Finalmente, el proyecto contempla una etapa final, la cual considera la elaboración de una aplicación que facilite la ejecución del modelo de manera recurrente, permitiendo

que la FND, lleve a cabo las estimaciones y reportes requeridos por los reguladores. Sin embargo, la elaboración del aplicativo queda fuera del alcance de este trabajo, por lo que únicamente se describen los aspectos generales en la Sección 4.3.

The background features a complex, abstract design. On the left, there are several overlapping circular and semi-circular patterns, some with dashed lines and others with solid lines. These patterns resemble stylized gears or architectural elements. Scattered throughout the background are various geometric shapes, including rectangles, triangles, and hexagons, some of which are dashed. There are also several sets of arrows: a vertical column of three downward-pointing triangles, a horizontal row of eight rightward-pointing triangles, a horizontal line with a dot at its left end, and a series of four upward-pointing triangles. The overall aesthetic is technical and modern.

Capítulo 3

Modelos de Componentes de Riesgo

3 Modelos de Componentes de Riesgo

En este capítulo se describe el proceso de desarrollo, evaluación y validación de los modelos propuestos para la estimación de los componentes de la PE asociada al riesgo de crédito de la FND. Se incluyen tres secciones, una por cada componente, donde se detallan los métodos y herramientas que se han empleado para construir los modelos, así como las fuentes de información y técnicas de procesamiento utilizadas para el tratamiento de los datos.

3.1. Modelo de Probabilidad de Incumplimiento

La componente que posiblemente conlleva una mayor complejidad en la determinación de un modelo predictivo es la PD, aunado a esto, las características particulares de las operaciones de la FND agregan dificultades adicionales. Por lo anterior, se consideró adecuado que el primer modelo abordado como parte de este proyecto fuera el relacionado a esta componente.

3.1.1. Definición de Probabilidad de Incumplimiento

Al desarrollar una modelación matemática, es crucial definir con precisión la variable objetivo. Esta definición es la base para garantizar la consistencia y coherencia de los resultados obtenidos. En este sentido, la elaboración de los modelos para predicción de la PD requieren que se defina claramente el concepto de «probabilidad de incumplimiento», la cual es la variable que se desea predecir.

Según [Bart Baesens, 2008] se puede definir un incumplimiento, en el contexto del riesgo de crédito, como la situación donde el prestatario no cumple y no honra su obligación de hacer frente a la deuda adquirida. Es decir, un cliente incumple cuando no efectúa o se retrasa en los pagos de su deuda.

En el mismo sentido, las instituciones financieras cuentan con una clasificación contable para sus carteras de créditos, en función del nivel de atraso de los créditos, estos se pueden clasificar como cartera vigente o vencida. Particularmente, la FND, considera que un crédito es cartera vencida si un cliente tiene un retraso de 90 días o más en sus pagos.

En el contexto de este trabajo, se entenderá que un crédito es *malo* durante el mes i , si este se encuentra clasificado contablemente como cartera vencida al cierre del mes i . Por el contrario, si el crédito se encuentra dentro de la cartera vigente al cierre del mes i , o bien fue liquidado satisfactoriamente antes o durante el mes i , se etiquetará como un crédito *bueno*.

Sin embargo, se identificó que la definición anterior generaba un sesgo para los clientes que contaban con dos o más créditos al mismo tiempo, generando que se subestimara el riesgo correspondiente, puesto que un cliente sería marcado como *malo* únicamente cuando se incumpliera con todos sus contratos asociados. Por ello, se propone una definición de incumplimiento aplicable a nivel cliente, en lugar de hacerlo únicamente a nivel crédito, de tal forma que, un cliente se clasificará como *malo* durante el mes i , si cualquiera de sus créditos asociados es *malo* durante ese mes. Por el contrario, si todos los créditos asociados al cliente son clasificados como *buenos*, entonces el cliente también será clasificado como *bueno*.

De esta manera, si se cuenta con una cartera de clientes en el cierre del mes i , se pueden definir los siguientes conjuntos:

- $B_i = \{x: \text{clientes } \textit{buenos} \text{ en el mes } i \in I\}.$
- $M_i = \{x: \text{clientes } \textit{malos} \text{ en el mes } i \in I\}.$

donde I es un conjunto de índices asociados a un mes específico en el tiempo, siendo $i = 1$ la información relacionada con enero 2009, $i = 2$ la información de febrero 2009, y así sucesivamente.

A partir de estos conjuntos, se puede definir la PD del mes i para una cartera de clientes como:

$$PD_i = \frac{|B_i \cap M_{i+12}|}{|B_i|} \quad (3.1)$$

donde $|\cdot|$ denota el número de elementos del conjunto, mientras que i representa un mes cualquiera y la expresión $i + 12$ se refiere al mismo mes, pero del siguiente año.

La ecuación (3.1) se interpreta como la proporción de clientes *buenos* durante el mes i , que estarán etiquetados como *malos* en el mes $i + 12$ (un año después). Esta proporción estima la probabilidad de que un cliente *bueno* incumpla en los próximos 12 meses, es decir, la PD anual de una cartera en el mes i , siendo esta la variable que se desea modelar.

3.1.2. Generación de Series Históricas

Tras definir la PD estimada en cualquier mes i , se aplicó este cálculo iterativamente sobre los datos mensuales de la FND. Esta aplicación dio lugar a una serie temporal, reflejando la evolución de la PD desde diciembre de 2009 hasta abril de 2021. El diseño del proceso permite además calcular la PD para cualquier segmento o subdivisión de la cartera que se requiera.

La Figura 3.1 muestra la serie de PD resultante al aplicar los cálculos a la cartera de la FND, misma que se contrasta con los resultados que serían obtenidos en caso de que el cálculo se aplicara únicamente a nivel crédito, evidenciando la subestimación del riesgo comentada en la sección 3.1.1.



Figura 3.1: Series históricas de PD.

Calculadas a nivel de cliente y crédito, donde se observa una subestimación del riesgo a nivel de crédito.

Fuente: Elaboración propia.

3.1.3. Segmentación de Población

Una vez obtenida la serie histórica de la PD, se procedió a explorar el comportamiento de esta para algunos segmentos de cartera, los cuales *a priori* se sabe cuentan con características y tratamientos distintos dentro de la FND. En particular, se consideraron las siguientes variables segmentadoras:

- Tipo de Crédito: Distintos productos tienen plazos y condiciones de garantías diferentes (avio, reporto, prendario, etc.), por lo que su segmentación ayuda a diferenciar la PD por estas variables.
- Actividad Económica: Cada crédito tiene asociada una actividad (ganadería, agricultura, acuicultura, etc.), las cuales son afectadas por distintos factores macroeconómicos, por lo que su comportamiento difiere entre sí.
- Agencia: La FND cuenta con distintas agencias (sucursales) a lo largo de varias ciudades del país, lo cual permite identificar comportamientos influidos por va-

riables geográficas, tales como el clima, sequías y declaratorias de emergencias.

Los resultados obtenidos con estas segmentaciones mostraron que las series de PD también mantenían comportamientos diferenciados entre sí.

De manera general, se pretendía obtener una serie de PD correspondiente a cada combinación de variables, por ejemplo, se podría tener la combinación AVIO-AGRICOLA-SINALOA. Sin embargo, dado que cada variable cuenta con un número significativo de etiquetas, se obtenía un alto número de combinaciones (alrededor de 5,200), resultando en series altamente volátiles dada la alta pulverización de la población, es decir, algunas combinaciones no tendrían los suficientes registros asociados como para generar series de PD estables. Para resolver este problema, se realizó una reducción del número de etiquetas de cada variable, con lo que se reduce también el número de combinaciones posibles. Esto se llevó a cabo mediante la aplicación de una técnica de agrupación o *clustering*.

Este *clustering* se realizó mediante un algoritmo jerárquico aglomerativo con las siguientes características:

- Criterio de Enlace: Completo (Máxima distancia entre elementos).
- Métrica de Similitud: Distancia de Canberra [Community, 2024].
- Número de Grupos: Coeficiente de Silueta [scikit-learn community, 2024b], Calinski [scikit-learn community, 2024a] y Criterio experto.

De esta manera, la reducción de las etiquetas resultó en las siguientes agrupaciones:

Tipo de Producto

Se conservaron cuatro etiquetas. Los Avíos y créditos Simples quedan agregados en un solo grupo, dada la similitud del comportamiento de PD, como puede observarse en la Figura 3.2




Figura 3.2: Series de PD por grupos de productos.

Se observan diferencias en el comportamiento y los niveles de incumplimiento de cada grupo.

Fuente: Elaboración propia.

Tipo de Actividad

El número de etiquetas se redujo de once a tres. El comportamiento y composición de los grupos resultantes se muestra en la gráfica de la Figura 3.3.




Figura 3.3: Series de PD por grupo de actividad.

Cada grupo engloba aquellas actividades que presentan comportamientos y niveles de riesgo similares.

Fuente: Elaboración propia.

Agencia

Para este caso, se redujo considerablemente el número de etiquetas, pasando de 94 agencias individuales a únicamente 3 grupos geográficos. El comportamiento de los grupos resultantes se muestra en la Figura 3.4.




Figura 3.4: Series de PD por grupo de agencias.

Cada grupo engloba distintas agencias que, por su ubicación geográfica, comparten comportamientos y niveles de incumplimiento.

Fuente: Elaboración propia.

Los segmentos resultantes fueron analizados, con el objetivo de identificar características propias de cada grupo. En primera instancia, la ubicación de las agencias parece ser un factor importante en la segmentación, sin embargo, no es determinante, pues como se observa en la gráfica de la Figura 3.5, las regiones resultantes se superponen entre sí.



Figura 3.5: Distribución geográfica de las agencias.

Diferenciadas por el grupo de PD obtenido.

Fuente: Elaboración propia.

Además, análisis complementarios, en los que se superpusieron diversos mapas que muestran variables climatológicas y sociodemográficas del país, sugieren que los grupos obtenidos pueden diferenciarse también por factores climáticos, como la temperatura y las precipitaciones promedio, así como por variables sociales, como la densidad de población y, además, por el uso del suelo en la región.

Grupos Finales

Una vez realizada la reducción de etiquetas, se procedió a generar las combinaciones de la forma TIPO CRÉDITO – ACTIVIDAD – AGENCIA, obteniendo $4 \times 3 \times 3 = 36$ series de PD distintas, de las cuales 4 resultaron vacías. A estas series les fue aplicado nuevamente el algoritmo de agrupación descrito al inicio de la sección 3.1.3. Como resultado de este proceso se obtuvieron 4 grupos finales, con series de PD bien diferenciadas entre sí, como puede observarse en la Figura 3.6.




Figura 3.6: Series de PD de los grupos finales.

Cada grupo engloba distintas combinaciones de tipo de producto, actividad y agencia con comportamientos y niveles de riesgo similares.

Fuente: Elaboración propia.

Además, cada grupo muestra poblaciones de distintos tamaños y diferentes composiciones, lo que también influye en su comportamiento y caracterización, como se muestra en la Figura 3.7




Figura 3.7: Caracterización de los grupos finales.

A) Volumetría promedio mensual; B) Composición porcentual por tipo de actividad; C) Composición porcentual por región; y D) Composición porcentual por tipo de producto crediticio.

Fuente: Elaboración propia.

A continuación se presenta una descripción de cada grupo, donde se realtan las principales características de cada uno:

- Grupo 1: Este grupo está compuesto por pocos clientes (figura 3.7-A), lo que genera que la serie de PD correspondiente tenga una alta volatilidad. Su población se encuentra concentrada en la región Norte (figura 3.7-C). Y es el único grupo que engloba productos de Comercialización (figura 3.7-D).
- Grupo 2: Es el grupo con mayor población de clientes (figura 3.7-A). La serie de PD muestra un comportamiento más estable que el resto de los grupos, con un crecimiento modesto durante el último año. Se compone principalmente de clientes con actividad Agrícola (figura 3.7-B) de la región Centro y Noroeste (figura 3.7-C),
- Grupo 3: Es el segundo grupo con mayor población (figura 3.7-A). La serie de PD muestra un alto crecimiento durante el último año y, en general, niveles más altos que los otros grupos. Se compone de clientes con actividades Agrícolas y

Ganaderas (figura 3.7-B). La mayor parte de su población se corresponde con créditos de Avíos y Refaccionarios (figura 3.7-D).

- Grupo 4: El número de clientes es modesto pero significativo (figura 3.7-A). La serie de PD muestra un crecimiento moderado en el último año y, en general, su nivel se mantiene por arriba del observado por el grupo 2, pero debajo del grupo 3. La actividad más relevante es la Ganadería (figura 3.7-B) de las regiones Centro y Sur (figura 3.7-C). Los créditos asociados son del tipo Refaccionario, Avío y Cuenta Corriente (figura 3.7-D).

Como puede observarse, cada grupo muestra características y comportamientos bien diferenciados, lo que sugiere que cada segmento es sensible a distintas variables, por lo que la idea de generar modelos independientes para cada segmento toma mayor relevancia.

3.1.4. Identificación de Predictores

La siguiente etapa del proyecto consiste en identificar aquellas variables macroeconómicas y datos específicos de los clientes que permitan modelar y predecir el comportamiento de la PD. Este paso no solo abarca la recopilación de datos, sino también su limpieza y normalización, asegurando la coherencia y compatibilidad necesarias para el análisis.

Fuentes Externas (Factores Macroeconómicos)

En primera instancia, se propone el uso de factores macroeconómicos como herramientas predictivas del comportamiento de pago de los clientes (PD). Sin embargo, se debe señalar que estas variables por sí solas no son capaces de discriminar entre clientes individuales, dado que el valor de un indicador es el mismo para toda la cartera de clientes en un mismo mes. A pesar de esta limitación, estos factores son valiosos para modelar el comportamiento promedio de las carteras de clientes y evaluar cómo las dinámicas económicas influyen el comportamiento de pago de los clientes.

Con base en lo anterior, se estableció como criterio para la recopilación de la información macroeconómica que esta debe realizarse únicamente a partir de fuentes oficiales, confiables y verificables, mismas que deberán actualizarse periódicamente, garantizando la integridad y la actualización periódica de los datos. De esta manera, se seleccionaron seis fuentes de información distintas, consideradas idóneas por cumplir con estos estándares antes mencionados.

En la siguiente tabla se detallan las fuentes de información utilizadas, se incluye la liga de acceso y una pequeña descripción de estas.

Fuentes de Información para Factores Macroeconómicos		
Nombre	Fuente	Descripción
Tablero de Indicadores Económicos INEGI	https://www.inegi.org.mx/app/tablero/	El tablero de indicadores económicos del INEGI proporciona, en forma rápida y fácil, un panorama de la evolución de variables fundamentales que interactúan en la economía mexicana, así como de otras externas que tienen influencia significativa en ella. Este tablero incluye variables del sector real y del mercado laboral, variables financieras y los llamados indicadores de opinión o de sentimiento.
Banco de Información Económica (BIE)	https://www.inegi.org.mx/app/indicadores/?tm=0&ind=436140#divFV444557436140#D436140	El BIE contiene más de 150,000 series históricas actualizables con información económica de México. La actualización de esta información se realiza en forma periódica y oportuna, con base en el Calendario de difusión de información estadística y geográfica y de Interés Nacional del INEGI.
Investing	https://mx.investing.com/	Investing es una plataforma financiera y un sitio web de noticias; uno de los tres sitios web financieros más importantes del mundo. Ofrece cotizaciones de mercado, información sobre acciones, futuros, opciones, análisis y materias primas.
Información Financiera de Banca Múltiple (CNBV)	https://portalfoiinfo.cnbv.gob.mx/Paginas/Contenidos.aspx?ID=40&Contenido=Series%20Hist%C3%B3ricas&Titulo=Banca%20M%C3%Baltiple	Conjunto de reportes publicados por la CNBV que muestran la información financiera de las instituciones de Banca Múltiple, con el objetivo de proporcionar indicadores estadísticos que reflejen adecuadamente la evolución de su condición financiera y operativa.
Monitor de Sequías (SMN)	https://smn.conagua.gob.mx/es/climatologia/monitor-de-sequia/monitor-de-sequia-en-mexico	El Servicio Meteorológico Nacional (SMN) es la dependencia oficial del gobierno mexicano encargada de proporcionar información meteorológica (estado del tiempo) y climatológica. Uno de los fenómenos climáticos que más afecta a las actividades económicas del país es la sequía, el SMN se encarga de detectar el estado actual y la evolución de este fenómeno.
Atlas Nacional de Riesgos	http://www.atlasnacionalderiesgos.gob.mx/apps/Declaratorias/	La ocurrencia de fenómenos de origen natural que afectan el país, hace necesario el monitoreo permanente. A partir de información publicada por el Centro Nacional de Prevención de Desastres, el Servicio Sismológico Nacional, el Laboratorio de Observación de la Tierra (LANOT) y la Administración Nacional Oceánica y Atmosférica (NOAA), se integra en el Atlas Nacional de Riesgos un sistema que permite su visualización dinámica en un tablero único.

Cuadro 3.1: Fuentes de información macroeconómica.

Fuente: Elaboración propia.

La información obtenida de las fuentes mencionadas permitió construir 94 series históricas de indicadores macroeconómicos, sin embargo, algunas de estas mostraron características que las hacían inadecuadas para los análisis y usos que se les pretende dar, por lo que se procedió a eliminarlas. Algunas de las características que derivaron en la omisión de algunas series fueron:

- Rezago en su actualización mayor a tres meses.
- Información insuficiente (al menos a partir de 2008) o con datos faltantes.

- Poca o nula variabilidad (datos que no cambian en el tiempo).
- Actualización con frecuencia mayor a la mensual (trimestral, anual, etc.).
- Alta correlación positiva o negativa (se elige una serie representativa del grupo).
- Series con poca relevancia de acuerdo con el criterio experto (no relacionadas con el sector agrícola).

Así, se logró una reducción del conjunto de series a 32 indicadores macroeconómicos. La tabla 3.2 presenta un listado detallado de estas variables, incluyendo tanto sus descripciones como las categorías macroeconómicas correspondientes a cada una.

Tema	Variable	Descripción
Indicadores de Demanda	Inversión Fija Bruta	Información que permite un amplio conocimiento sobre el comportamiento de la inversión en el corto plazo, misma que está integrada por los bienes utilizados en el proceso productivo durante más de un año y que están sujetos a derechos de propiedad.
Indicadores de EUA	S&P500	El S&P500 es uno de los índices bursátiles más importantes de Estados Unidos. Se lo considera el índice más representativo de la situación real del mercado. Este indicador es deflactado por el INPC para obtenerlo en términos reales.
	Tasa De Bonos Del Tesoro De Eua	Se refiere a la tasa de interés que el gobierno de los Estados Unidos pagará a los tenedores de bonos, una vez que han pasado 10 años.
Indicadores de Opinión	Indicador De Confianza Empresarial	Es un índice compuesto que agrega cinco variables respecto de la percepción que tienen los directivos empresariales del sector manufacturero sobre la situación económica presente y futura en el país.
	Indicador De Confianza Del Consumidor	Mide la percepción actual y las expectativas a futuro que tiene la población acerca de la situación económica familiar y la del país, así como las posibilidades de compra de bienes de consumo duradero.
Indicadores de Precios	Índice Nacional De Precios Al Consumidor	Indicador cuya finalidad es la de estimar la evolución de los precios de una canasta de bienes y servicios que en promedio consumen las familias mexicanas en un periodo determinado.
	Inflación Anual	
	Indicadores De Precios Productor	Indicador cuyo objetivo es medir las variaciones en los precios de los bienes y servicios de una canasta fija representativa de la producción de la economía.
	Índice Nacional De Precios Productor Actividades Primarias	
	Inflación Productor Anual	
	Inflación Productor Primario Anual	
Indicadores de Producción	Indicador Global De Actividad Económica	Permite conocer y dar seguimiento a la evolución del sector real de la economía, en el corto plazo, proporcionando valiosa información para la toma de decisiones.
	Indicador Actividades Primarias	Permite conocer y dar seguimiento a la evolución del sector primario, en el corto plazo, proporcionando valiosa información para la toma de decisiones.
Indicadores del Mercado Financiero	IPC Bmv	Indicador de la evolución del mercado accionario en su conjunto. Se calcula en función de las variaciones de precios de una selección de acciones representativas de todas las acciones cotizadas en la Bolsa Mexicana de Valores. Este indicador es deflactado por el INPC para obtenerlo en términos reales.
	Bmv Mining & Agriculture	El BMV Extractiva (Minería y Agricultura) es uno de los siete índices que forman parte de la serie de Índices de Actividad Económica de S&P/BMV. Estos índices buscan medir diferentes sectores económicos del mercado bursátil mexicano. Este indicador es deflactado por el INPC para obtenerlo en términos reales.
	Tipo De Cambio Real	Se define como el cociente de los precios de los bienes internacionales (expresados en moneda doméstica), divididos entre los precios de los bienes nacionales. El tipo de cambio real multilateral es una medida ponderada de los tipos de cambio reales bilaterales con varios países.
	TIIE	La TIIE es una tasa representativa de las operaciones de crédito entre bancos calculada por el Banco de México. Esta tasa se usa como referencia para establecer algunas tasas comerciales a nivel bancario.
Indicadores del Mercado Laboral	Población Ocupada	Con base en la Encuesta Nacional de Ocupación y Empleo (ENOE) que levanta el INEGI en todo el país, se presenta información sobre población económicamente activa, tasa de ocupación, tasa neta de participación y población subocupada entre otros.
Indicadores del Sector Externo	Precio Petróleo Crudo	Es el precio promedio de exportación de petróleo crudo. En México es el promedio ponderado de tres tipos de petróleo que se produce y exporta. El precio es transformado a pesos y deflactado por el INPC para obtener su valor en términos reales.
	Exportaciones Totales	Es el total de las ventas de mercancías, que salen del territorio nacional de forma definitiva o temporal, mediante un pedimento aduanero y cumpliendo con las disposiciones de la ley y normatividad aduanera vigentes. El monto es transformado a pesos y deflactado por el INPC para obtener su valor en términos reales.
Índice de Morosidad	IMOR Total	Índice de Morosidad (IMOR) representativo de la Banca Múltiple correspondiente a distintos segmentos de cartera.
	IMOR Entidades Financieras	
	IMOR Tarjetas Crédito	
	IMOR ABCD	
Indicadores de Sequía	Sequia 1	Indicador de Sequía para los municipios que integran las regiones de cada grupo de PI. El indicador se construye mediante el agregado del nivel de sequía de los municipios que componen la región de cada grupo de población.
	Sequia 2	
	Sequia 3	
	Sequia 4	
Declaratorias de Emergencia y Desastre	Declara 1	Indicador de Declaratorias para los municipios que integran las regiones de cada grupo de PI. El indicador se construye mediante el conteo de los municipios con declaratorias activas que componen la región de cada grupo de población.
	Declara 2	
	Declara 3	
	Declara 4	

Cuadro 3.2: Detalle de variables macroeconómicas.

Fuente: Elaboración propia.

Tras la consolidación y depuración de la base de datos de indicadores macroeconómicos, se procedió a realizar un análisis exploratorio de las series obtenidas. Este análisis incluyó la visualización gráfica de las series para identificar patrones de comportamiento, en particular tendencias, el cálculo de estadísticas descriptivas básicas, tales

como medias y desviaciones estándar, así como un análisis de correlación entre estos factores y la PD de los distintos grupos de población.

Este análisis reveló la existencia de varios indicadores con una tendencia positiva sostenida durante el periodo analizado. Entre estos, destacan los índices de precios al productor y al consumidor, junto con el índice S&P 500. La evolución de estos indicadores se ilustra claramente en la Figura 3.8, evidenciando su tendencia ascendente a lo largo del tiempo.




Figura 3.8: S&P500.

Fuente: Elaboración propia.

Por otro lado, las series restantes de la base de datos exhiben patrones heterogéneos. Estas series se caracterizan por mostrar una diversidad de tendencias, ciclos, estacionalidades y diferentes niveles de volatilidad. Un caso destacado de este grupo es la serie de la inversión fija bruta, cuyo comportamiento se visualiza en la Figura 3.9.




Figura 3.9: Inversión Fija Bruta.

Fuente: Elaboración propia.

Posteriormente, se procedió a examinar las posibles relaciones que pudieran existir

entre los distintos factores macroeconómicos y las series de PD de los distintos grupos de población. Para ello, se realizó un cálculo de correlaciones.

Dada la naturaleza exclusivamente numérica de todas las variables en estudio, se optó por aplicar la correlación de Pearson. Esta metodología es idónea para medir la relación lineal entre variables cuantitativas. La fórmula del coeficiente de correlación de Pearson se define como:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (3.2)$$

donde r representa el coeficiente de correlación, X_i y Y_i son los valores de las variables en estudio, y $\bar{X}$ y $\bar{Y}$ son las medias de las variables X y Y , respectivamente.

Para un análisis más profundo, también se implementaron rezagos de hasta 24 meses en los factores macroeconómicos, examinando también su correlación con las series de PD.

Los resultados obtenidos se presentan mediante mapas de calor para los diferentes grupos (figuras 3.10, 3.12, 3.14 y 3.16), los cuales muestran el valor absoluto de las correlaciones obtenidas entre cada serie de PD y los distintos factores macroeconómicos, incluidos sus respectivos rezagos. Además, se incluye la etiqueta con la correlación máxima observada para cada indicador y el rezago en el que se encontró. Los indicadores marcados con asteriscos (***) corresponden a los que mostraron una correlación mayor al 70% para alguno de sus rezagos.

Grupo 1: El comportamiento de la PD de este grupo mantiene una alta correlación con la TIIE (71 % sin rezago), el IMOR de la cartera de ABCD (79 % con rezago de 17 meses), así como con el IPC de la BMV (78 % con rezago de 8 meses).




Figura 3.10: Correlaciones observadas entre predictores y la PD del Grupo 1.

Fuente: Elaboración propia.

Esta alta correlación con el IPC BMV se puede explicar por la diversidad de actividades y mercados en los que se involucra el Grupo 1, cuyas demandas y precios pueden verse influenciados por la dinámica general del mercado nacional. La correlación con el IMOR de la cartera ABCD sugiere una similitud en el comportamiento de pago entre los productos y destinos de este grupo y los de la cartera de consumo duradero de la Banca Múltiple. Finalmente, la correlación con la TIIE indica un impacto directo de las tasas de interés en el comportamiento de pago de este grupo de clientes.




Figura 3.11: Composición porcentual del Grupo 1.

De acuerdo con la actividad, producto crediticio y región geográfica asociada a los clientes.

Fuente: Elaboración propia.

Grupo 2: La serie de PD de este grupo mantiene altas correlaciones con distintas variables macroeconómicas, sin embargo, resaltan aquellas asociadas con el comportamiento de la economía de EUA, como su Tasa de Bonos del Tesoro (73 % con rezago de 15 meses) y el S&P500 (74 % con rezago de 12 meses), así como resultado obtenido para el IPC BVM (82 % con rezago de 9 meses).




Figura 3.12: Correlaciones observadas entre predictores y la PD del Grupo 2.

Fuente: Elaboración propia.

Para este caso, las correlaciones se pueden explicar considerando que la actividad principal del Grupo 2 es la agrícola, que se caracteriza por ser particularmente sensible a las variaciones en los precios de los insumos y los productos de venta. Esta sensibilidad se refleja en la alta correlación entre la PD y los Indicadores de Precios al Productor y Consumidor. Además, el maíz, que es el principal producto asociado a este grupo, tiene precios fuertemente influenciados por los mercados internacionales de futuros, lo que explica la correlación con los indicadores económicos de Estados Unidos.




Figura 3.13: Composición porcentual del Grupo 2.

De acuerdo con la actividad, producto crediticio y región geográfica asociada a los clientes.

Fuente: Elaboración propia.

Grupo 3: Este grupo muestra correlación alta con el IPC BMV (86% con rezago de 8 meses), la Inversión Fija Bruta (78% con rezago de 10 meses) y el IMOR de la cartera de ABCD (80% con rezago de 14 meses).




Figura 3.14: Correlaciones observadas entre predictores y la PD del Grupo 3.

Fuente: Elaboración propia.

El comportamiento de la PD de este grupo se relaciona con variables similares a las del Grupo 1, no obstante, resalta la correlación con la Inversión Fija Bruta. Esta correlación se puede explicar considerando la naturaleza de los créditos que predominan en este grupo, específicamente los créditos “Refaccionarios”. Estos créditos se enfocan

principalmente en la adquisición de maquinaria y activos fijos. Dado que la Inversión Fija Bruta es un indicador que refleja el gasto en bienes de capital como maquinaria y equipo, es razonable que exista una relación directa entre este indicador y la PD en un grupo donde los créditos Refaccionarios son significativos




Figura 3.15: Composición porcentual del Grupo 3.

De acuerdo con la actividad, producto crediticio y región geográfica asociada a los clientes.

Fuente: Elaboración propia.

Grupo 4: Finalmente, la PD del Grupo 4 también muestra una marcada correlación con el IPC BMV (82 % con rezago de 3 meses), el indicador correspondiente al sector de Minería y Agricultura (72 % con rezago de 24 meses), la Inversión Fija Bruta (75 % con rezago de 11 meses) y el IMOR ABCD (72 % con rezago de 12 meses).




Figura 3.16: Correlaciones observadas entre predictores y la PD del Grupo 4.

Fuente: Elaboración propia.

Las correlaciones de este grupo son similares a las mostradas por el Grupo 3. Esta similitud puede atribuirse en gran medida al predominio de la actividad “Ganadería” y a la relevancia de los créditos “Refaccionarios” en ambas poblaciones.




Figura 3.17: Composición porcentual del Grupo 4.

De acuerdo con la actividad, tipo de producto crediticio y región geográfica asociada a los clientes.

Fuente: Elaboración propia.

Complementando el análisis de correlaciones, se llevó a cabo una evaluación adicional mediante el cálculo del *Information Value* (IV) para cada uno de los indicadores macroeconómicos considerados. Esta métrica permite medir la capacidad predictiva de cada indicador macroeconómico respecto de la variable objetivo. Las fórmulas aplica-

das para la determinación IV se presentan a continuación, siendo descritas respectivamente en las ecuaciones (3.3) y (3.4).

$$WoE = \ln \left(\frac{\text{Proporción de Buenos}}{\text{Proporción de Malos}} \right) \quad (3.3)$$

$$IV = \sum (\text{Proporción de Buenos} - \text{Proporción de Malos}) \times WoE \quad (3.4)$$

donde la “Proporción de Buenos” y la “Proporción de Malos” cuantifican la proporción de observaciones con desempeño favorable y desfavorable, respectivamente, dentro de un grupo específico en relación con el total de la muestra.

Con respecto a los valores del IV obtenidos, estos se han clasificado para reflejar su poder predictivo de la siguiente manera:

- $IV < 0.1$, indica una capacidad predictiva Débil.
- $0.1 < IV < 0.3$, sugiere un poder predictivo Medio.
- $0.3 < IV < 0.5$, indica una capacidad predictiva Fuerte.
- $IV > 0.5$, se considera Sospechoso.

Esta clasificación es crucial para identificar y priorizar las variables más relevantes en el modelo de predicción de la PD. En la Figura 3.18, se muestran los resultados obtenidos para cada combinación de indicador macroeconómico y grupo de población.




Figura 3.18: Information Value por grupo.

Indica el valor informativo de cada variable en cada grupo.

Fuente: Elaboración propia.

Los resultados muestran que ciertos indicadores macroeconómicos poseen un poder predictivo de medio a fuerte. Esto sugiere una relación significativa entre los factores macroeconómicos y las decisiones de pago de los clientes.

A continuación se detallan las observaciones específicas para cada grupo de población. Estas observaciones se basan en los análisis realizados y reflejan cómo diferentes indicadores macroeconómicos afectan a distintos segmentos de la población en términos de su comportamiento de pago.

Grupo 1: Varios indicadores muestran un IV mayor a 0.5, por lo cual fueron catalogados como sospechosos, lo cual significa que la relación con la PD pudiera ser espuria. En general, los resultados concuerdan con lo obtenido en el análisis de correlación, sin

embargo, nuevas variables se suman a los candidatos de predictores, por ejemplo, el indicador de Sequías que muestra un IV Fuerte.

Grupos 2 y 3: Los indicadores que mostraron un IV más alto concuerdan con los resultados obtenidos del análisis de correlación, por ejemplo, en ambos casos el IMOR ABCD tiene un IV de valor Medio, así como el IPC BMV. Sin embargo, de manera general, los IV obtenidos para estos grupos son más bajos que los observados en los otros dos.

Grupo 4: Los resultados obtenidos para este grupo muestran que, algunos indicadores tienen un poder de predictibilidad de Fuerte a Medio, los cuales también son consistentes con el análisis de correlación. Adicionalmente, los indicadores de Sequía y Declaratorias muestran un IV Medio.

Este mismo análisis fue aplicado a las series de cambios porcentuales de los indicadores, calculados en función de la última fecha de dispersión para cada cliente. De esta manera se obtuvieron algunas candidatas de predictoras macroeconómicas adicionales.

En resumen, estos análisis sugieren nuevas relaciones entre los indicadores macroeconómicos y el comportamiento de la PD a nivel cliente, lo cual, aunado al análisis de correlación, constituye el punto de partida para establecer de forma precisa el conjunto de las llamadas características de los modelos predictivos descritos en las siguientes secciones.

Fuentes Internas (Nivel Cliente)

Como se discutió en la subsección anterior, si bien las variables macroeconómicas aportan información valiosa, por sí solas no son capaces de discriminar comportamientos a nivel de clientes individuales. Esto se debe a que el valor de un indicador macroeconómico es uniforme para toda la cartera de clientes en un determinado mes.

Dado lo anterior, resulta necesario integrar al modelo variables a nivel individual que puedan capturar de manera más precisa y detallada las características intrínsecas de

los clientes a lo largo del tiempo. Estas variables serán cruciales para complementar los factores macroeconómicos ya analizados.

El uso de las variables a nivel cliente se hace de manera análoga a lo que se haría en un modelo de *scoring* [Dassatti, 2019]. Esto permitiría calcular una PD para cada cliente de manera mensual, la cual se actualizaría en función de los cambios en el comportamiento del cliente y se vería afectada por la evolución del entorno macroeconómico.

En particular, para el presente trabajo, la información de los clientes se extrae directamente de las bases de datos de la institución. El cuadro 3.3 detalla la propuesta de variables para incorporar al modelo. Se incluye el nombre que se maneja internamente, así como una breve descripción.

VARIABLE	NOMBRE	DESCRIPCIÓN
sldo_cont_rem	Proporción de Saldo Contable Remanente	Proporción que guarda la suma del saldo contable remanente de los créditos, respecto de la suma de monto otorgado de los mismos.
sldo_cont_rem_pon	Promedio Ponderado de la Proporción de Saldo Contable Remanente	Promedio ponderado de las proporciones de saldo contable remanente de cada uno de los créditos asociados a un cliente específico.
dias_vennopag_max	Máximos Días de Atraso de los Créditos	Número máximo de días de atraso presentados por los créditos asociados a un cliente particular.
dias_vennopag_pon	Promedio Ponderado de los Días de Atraso de los Créditos	Promedio ponderado del número de días de atraso presentados por los créditos asociados a un cliente particular.
plazo_total_rem	Plazo Remanente Total	Plazo remanente, en meses, desde la fecha de observación hasta el último vencimiento de los créditos asociados a un cliente específico.
porc_plazo_dis_tot	Porcentaje de Plazo Remanente	Plazo remanente total de un cliente específico, expresado como proporción del plazo total del mismo.
indice_compor	Índice de Comportamiento de Pago a Nivel Cliente	Proporción de meses en que un cliente se ha mantenido como "bueno", calculado dentro de una ventana de 36 meses.
indice_compor_cred	Índice de Comportamiento de Pago a Nivel Crédito	Proporción de créditos que un cliente se ha mantenido como "buenos", calculado dentro de una ventana de 36 meses.
indice_vennopag	Índice de Días de Atraso	Promedio de los días máximos de atraso dentro del periodo de los últimos 36 meses.

Cuadro 3.3: Descripción de variables a nivel cliente.

Fuente: Elaboración propia.

Al igual que se hizo con las variables macroeconómicas, se calculó el IV para las variables de nivel cliente, con la finalidad de obtener un estimado del poder predictivo de cada una de ellas. Los resultados obtenidos, segmentado por grupos poblacionales, son los siguientes:




Figura 3.19: Information Value por grupo (Interno).

Indica el valor informativo de cada variable en cada grupo.

Fuente: Elaboración propia.

Estos resultados mostraron que las variables de nivel cliente cuentan con poder predictivo de Medio a Fuerte, con excepción de aquellas relacionadas con el saldo remanente de los clientes, cuyo poder predictivo se estimó como Débil para todos los grupos.

3.1.5. Modelado de la PD

Como ya se detalló en la Sección 2.2, se ha elegido un enfoque de predicción de la PD a nivel cliente, análogo a la implementación de un modelo de *scoring*. Este modelo permitiría calcular una PD para cada cliente de manera mensual, la cual se actualizaría en función de los cambios en el comportamiento del cliente y se vería afectada por la evolución del entorno macroeconómico.

Estos modelos de predicción se construyen tomando como punto de partida aquellas variables, tanto de nivel cliente como macroeconómicas, que muestran un poder predictivo Medio o Fuerte (en caso de no existir, se incluyen también los Débiles) y/o aquellas con correlación alta (mayor al 70 % en cualquier rezago).

Conjunto de Entrenamiento y de Pruebas

En el contexto de los modelos de clasificación, es común separar el conjunto de datos en dos partes: entrenamiento y pruebas. Generalmente, esta división se realiza mediante muestras aleatorias del conjunto de datos original (*out of sample*). Sin embargo, en nuestro caso, dada la naturaleza temporal de los datos, se optó por un enfoque diferente, considerando más adecuado dividir los datos en períodos específicos (*out of time*).

- Entrenamiento: Información desde enero 2015 hasta diciembre 2019 (5 años).
- Pruebas: Datos de enero 2020 hasta diciembre 2020 (1 año).

Esta división de la información permite que los modelos sean evaluados poniendo a prueba su capacidad de predecir los datos más recientes, similar a lo que se realiza en una prueba de *backtesting*. Este enfoque busca replicar un escenario más realista donde los modelos deben predecir comportamientos futuros basados en datos históricos.

Tratamiento de Valores Vacíos

Una vez definido el conjunto de entrenamiento, se procedió al tratamiento de valores vacíos en las variables. Es importante abordar adecuadamente los valores nulos, ya que pueden afectar significativamente el rendimiento del modelo. En nuestro caso, se adoptó una metodología de reemplazo, la cual consistió en sustituir los valores nulos por la media de la variable correspondiente, calculada utilizando únicamente los datos del conjunto de entrenamiento.

La elección de utilizar la media para la imputación se fundamenta en su eficacia para mantener la distribución general de la variable, evitando distorsiones significativas que podrían surgir al utilizar otros métodos, como la mediana o valores fijos. Este enfoque permite que el tratamiento de valores vacíos se base en una estimación robusta y representativa, minimizando así el impacto de los valores vacíos en el entrenamiento posterior del modelo.

Estandarización de Variables

Dada la sensibilidad de algunos de los modelos evaluados a las escalas y varianzas de las variables, se identificó la necesidad de aplicar un proceso de estandarización para minimizar posibles sesgos en los resultados. Por lo que, se realizó una normalización sobre las variables predictoras, utilizando la media y varianza de acuerdo con la fórmula (3.5).

$$z = \frac{x - \bar{\mu}}{\bar{\sigma}} \quad (3.5)$$

donde x es el valor original de la variable, $\bar{\mu}$ es la media de la variable, y $\bar{\sigma}$ es la desviación estándar.

Esta transformación permite que las variables tengan una media de cero y una varianza de uno, evitando sesgos por la escala o varianza de las variables. Cabe resaltar que también fueron considerados otros métodos de estandarización, sin embargo, el método anterior fue el que mejores resultados mostró.

Modelos Evaluados y Optimización de Hiperparámetros

La tarea de predecir la PD a nivel cliente implica la selección y aplicación de modelos de clasificación adecuados. Cada modelo posee características únicas y ofrece distintas ventajas y desventajas, lo que requiere una cuidadosa consideración para su selección.

Por su parte, cada modelo cuenta con distintos hiperparámetros, que los definen y deben ser establecidas antes del entrenamiento influyendo significativamente en el rendimiento del modelo. A diferencia de los parámetros del modelo, los hiperparámetros, como la profundidad en un árbol de decisión, deben ser definidos manualmente, lo que en algunos casos puede llevar a un modelo sub-ajustado o sobre-ajustado si no se eligen adecuadamente.

Dado lo anterior, se optó aplicar una metodología de *grid search* (búsqueda en malla), la cual consiste en entrenar distintos modelos, aplicando variaciones en los principales

hiperparámetros y comparando los desempeños obtenidos sobre el conjunto de pruebas, con el objetivo de identificar el modelo más efectivo para la predicción de la PD y determinar la configuración óptima de los hiperparámetros.

La tabla 3.20 muestra un resumen de los modelos considerados, así como los hiperparámetros que fueron considerados. Además, también se ofrece una breve descripción y algunas de las ventajas y desventajas de cada modelo evaluado. Para un análisis más detallado sobre estos modelos y otros adicionales, se recomienda consultar el libro de [Raschka, 2020], que proporciona una explicación exhaustiva y profunda de los mismos.

Modelo	Descripción	Hiperparámetros	Ventajas	Desventajas
K-Vecinos más Cercanos	Modelo de clasificación que asigna a un nuevo punto de datos la categoría más común entre sus K vecinos más cercanos, basándose en una medida de distancia, como la distancia euclidiana.	- Número de vecinos. - Criterio de pesado.	- Fácil de interpretar. - Rápido de entrenar. - Muestra buen rendimiento en conjuntos pequeños.	- La predicción requiere de mucho tiempo para llevarse a cabo. - Suele tener problemas de rendimiento cuando se incorporan muchas variables predictoras.
Bosques Aleatorios	Modelo de aprendizaje ensemble que construye múltiples árboles de decisión y promedia sus resultados para mejorar la precisión y controlar el sobreajuste.	- Número de árboles (estimadores) en el bosque. - Tamaño de hoja en árboles. - Criterio de división.	- Uno de los métodos más usados. - No requiere estandarización de los datos.	- Su interpretabilidad es más compleja vs árboles simples. - Reducción de desempeño con conjuntos de datos de alta dimensionalidad.
Regresión Logística	Modelo estadístico para modelar la probabilidad de un resultado binario en función de variables independientes. Utiliza la función logit para asegurar que las predicciones estén en el rango de 0 a 1.	Tasa de regularización.	- Rápido de entrenar. - Fácil de interpretar. - Buen rendimiento en conjuntos de gran tamaño.	Se pueden generar sesgos por existencia de correlación en las variables predictoras.
Redes Neuronales	Modelos de aprendizaje inspirados en el funcionamiento del cerebro humano, compuestos por capas de "neuronas" interconectadas, cada una recibe entradas, las procesa mediante una función de activación y transmite la salida a la siguiente capa.	- Arquitectura de la red. - Función de activación. - Tasa de regularización.	- Capaces de capturar información de conjuntos de datos de gran tamaño. - Se pueden generar modelos muy complejos.	- Requieren gran cantidad de tiempo y datos para su entrenamiento. - El ajuste de los hiperparámetros resulta muy complejo.

Figura 3.20: Modelos e hiperparámetros evaluados.

Fuente: Elaboración propia.

Métricas de Desempeño

Como se mencionó anteriormente, resulta necesario llevar a cabo una comparación del rendimiento obtenido por distintos modelos, sin embargo, las métricas de desempeño usuales no resultan adecuadas para este fin, dado que el conjunto de datos con

el cual se está trabajando tiene un alto índice de desbalanceo.

Se dice que un conjunto de datos es desbalanceado cuando una de las clases objetivo tiene mayor representación que su contraparte. En nuestro caso particular, el número de clientes “buenos” representa entre un 90 %-95 % de las observaciones (dependiendo el grupo poblacional), mientras que los clientes “malos” tienen una representación de alrededor del 5 %-10 %.

Este desbalanceo ocasiona que métricas bien conocidas, como el *Accuracy*, tengan sesgos al representar el rendimiento de un modelo. Por ejemplo, si consideramos un conjunto de datos como el nuestro, donde la representación de los clientes “buenos” alcanza un 95 %, entonces un modelo que pronostica que la totalidad de los clientes son “buenos”, mostraría un *Accuracy* del 95 %, sugiriendo un buen desempeño, aun cuando este no tiene ningún poder predictivo.

La literatura sugiere distintos enfoques y métodos para tratar el problema del desbalanceo de datos, algunos de los principales son los siguientes:

- Obtener más observaciones de la clase infrarrepresentada.
- Aplicar técnicas de sobremuestreo sobre la clase con menos representación.
- Utilizar otras métricas para medir el desempeño de los modelos.

La primera opción no resulta factible para nuestro caso, por lo cual se descartó. En cuanto a la segunda opción, se realizaron pruebas utilizando varias técnicas de sobremuestreo, sin embargo, los resultados obtenidos derivaron en una sobreestimación de la PD, por lo cual, el método no se consideró adecuado. Finalmente, se optó por adoptar la técnica del punto tres y utilizar otras métricas para medir el desempeño de los modelos de clasificación.

En la tabla 3.21 se muestran las métricas consideradas para la evaluación de los modelos, se incluye una breve descripción de estas y los valores objetivo establecidos por el CAIR como criterios para la aprobación de los modelos:

Métrica	Descripción	Valores Objetivo
Accuracy	Porcentaje de observaciones clasificadas de manera correcta.	Mayor a 90%**
AUC ROC	Área bajo la curva ROC. Se puede interpretar como la probabilidad de que el modelo le asigne una mayor PI a un cliente "malo" que a uno "bueno".	Mayor al 65%
KS	Estadístico Kolmogorov-Smirnov, que representa la máxima distancia entre las distribuciones acumulativas de los clientes "buenos" y los "malos".	Mayor al 20%
Gini	Índice Gini, equivalente al área bajo la Curva de Lorenz.	Mayor al 10%

Figura 3.21: Métricas de desempeño aplicadas.

Fuente: Elaboración propia.

Cabe mencionar que el valor objetivo de la métrica *Accuracy* (marcada con **) pudiera no alcanzarse, dado el alto sesgo generado por el desbalanceo de los datos y la alta dependencia que tiene con los puntos de corte de la clasificación (por defecto, si la PD es mayor al 50% se considera al cliente como “malo”, en caso contrario se clasifica como “bueno”).

Por otro lado, también se propone el uso de métricas para medir el ajuste de los modelos a nivel de grupo poblacional, las cuales permitirán comparar las series reales de PD (generadas a partir de la proporción de clientes “malos”), *versus* la serie estimada con el promedio de la PD predicha por los modelos. De tal manera que, el ajuste se medirá comparando la similitud de dos series temporales. Para este caso, las métricas propuestas son:

- Error Absoluto Medio (MAE).
- Error Porcentual Absoluto Medio (MAPE).
- Máximo Error Absoluto.

Incorporación de la PD como Predictora

Tras las primeras pruebas de desempeño, se observó que la PD estimada por los modelos generaba inconsistencias temporales cuando se observaba el comportamiento promedio de cada grupo, con variaciones significativas que se desviaban de los promedios reales en el conjunto de pruebas, como se muestra en la Figura 3.22. Este com-

portamiento es indeseable, ya que podría generar impactos adversos en las reservas de créditos de la FND, lo que resultaría en efectos negativos sobre los estados financieros.




Figura 3.22: Ejemplo de resultado con alta variabilidad en predicciones.

Fuente: Elaboración propia.

Para corregir este comportamiento, se decidió incorporar la PD media de cada grupo como una variable predictora en los modelos de clasificación. Este enfoque permite estabilizar la media de la PD predicha en cada grupo, lo que genera estimaciones más consistentes a lo largo del tiempo; es decir, las variaciones mensuales en las predicciones son menores. Sin embargo, esta estrategia requiere la predicción de los valores futuros de la PD media de cada grupo antes de estimar la PD de cada individuo

Para llevar a cabo lo anterior, se propone incorporar un modelo de tipo Auto-Regresivos Integrados de Media Móvil (ARIMA), especializado en el análisis de series temporales, el cual permitirá pronosticar la PD media de cada grupo, que a su vez servirá como insumo para los modelos de clasificación. Este esquema se ilustra en la Figura 3.23.




Figura 3.23: Esquema de modelo PD con ensamble de modelo ARIMA.

Fuente: Elaboración propia.

Además de corregir el problema de consistencia temporal en las predicciones de la PD grupal, este esquema ofrece la ventaja adicional de permitir la realización de análisis de escenarios de sensibilidad y estrés. Estos análisis son de gran utilidad y, además, son exigidos normativamente a instituciones financieras como la FND. Por lo tanto, el ensamble del modelo ARIMA con los modelos de clasificación no solo mejora la precisión de las predicciones, sino que también resulta beneficioso para cumplir con estos requisitos.

Modelos Obtenidos

De esta forma, los modelos de clasificación correspondientes a cada grupo de población se entrenan utilizando las variables predictoras que se detallan en la Tabla 3.24. Estas variables fueron seleccionadas siguiendo los criterios y análisis presentados en el capítulo 3.1.4.

TIPO DE VARIABLE	GRUPO 1	GRUPO 2	GRUPO 3	GRUPO 4
PI Grupal	PI Grupo 1	PI Grupo 2	PI Grupo 3	PI Grupo 4
Variables del Cliente	plazo_total_rem	dias_vennopag_max	dias_vennopag_max	dias_vennopag_max
	dias_vennopag_max	indice_vennopag	indice_vennopag	indice_vennopag
	indice_compor_cred			
	indice_vennopag			
Entorno Macroeconómico	Confianza Consumidor	TIIE	Confianza del Consumidor	Confianza del Consumidor
	Tipo de Cambio Real	IMOR Total	TIIE	Tipo de Cambio Real
	Ipc Bmv	Sequía Total	Ipc Bmv	TIIE
	IGAE	Declaraciones Total	IMOR ABCD	Ipc Bmv
	Bmv Mining & Agriculture		Sequía Total	IMOR ABCD
	TIIE		Declaraciones Total	Sequía Total
	IMOR Total			Declaraciones Total
	Sequía Total			
Variación Macroeconómica	Δ Tasa de Bonos EUA	Δ Ipc Bmv	Δ Ipc Bmv	Δ Ipc Bmv
	Δ Ipc Bmv	Δ TIIE	Δ TIIE	Δ TIIE
	Δ TIIE			

Figura 3.24: Variables predictoras por grupo.

Fuente: Elaboración propia.

Estas variables predictoras se pueden clasificar en distintos bloques, en función del tipo de información que aportan a los modelos de clasificación. Cabe reiterar que, los modelos de clasificación incorporan las series de PD grupales como uno de los elementos predictores.

Tomando en cuenta todo lo expuesto anteriormente, se procedió a entrenar 4 tipos de modelos (KNN, bosques aleatorios, regresión logística y redes neuronales), variando algunos de los hiperparámetros principales para un total de 63 modelos distintos para cada grupo poblacional.

El desempeño de cada modelo resultante se midió sobre los datos del conjunto de prueba correspondiente, dando especial atención al índice de la ROC AUC. Así se obtuvieron los modelos con mejores desempeños de cada grupo, observándose que, en tres de los cuatro casos, los modelos que mostraron mejor rendimiento se correspondían con bosques aleatorios.

Sin embargo, con la finalidad de mantener consistencia entre los modelos seleccionados para cada grupo, así como para facilitar la implementación del futuro sistema, se optó por elegir el mismo tipo de modelo en todos los casos, de esta manera, se seleccionó el modelo de bosques aleatorios que mostrara mejor desempeño, aún cuando para el caso del Grupo 1, este no se correspondiera con el mejor modelo de todos (el

bosque aleatorio era el tercer mejor modelo).

De esta manera, el tipo de modelo de clasificación propuesto para todos los grupos es de bosques aleatorios, con el mismo criterio de pesado (Gini), pero con ligeras variaciones en los tamaños de hojas. El detalle de estos modelos, así como el desempeño mostrado por cada uno de ellos se detalla en los siguientes puntos:

• Grupo 1

Se propone utilizar un modelo de Bosque Aleatorio con 200 estimadores, criterio de división Gini y un tamaño de hoja del 0.1 %, el cual muestra el siguiente desempeño:




Figura 3.25: Resultados Grupo 1.

Fuente: Elaboración propia.

De manera general, las gráficas de la Figura 3.25 muestran que el modelo asigna una mayor probabilidad de incumplimiento a los clientes “Malos” que a los “Buenos”, generando una separación adecuada de las poblaciones. Lo anterior se ve reforzado por los resultados de las métricas de desempeño, las cuales alcanzan sus valores objetivo, con excepción del *Accuracy*, dado el desbalanceo de los datos ya mencionado previamente.




Figura 3.26: Resultados Globales Grupo 1.

Fuente: Elaboración propia.

Aunado a lo anterior, en la Figura 3.26 se observa que las predicciones globales del modelo también mantienen consistencia temporal, aunque se ha identificado una leve sobreestimación en el nivel de la PD grupal. Sin embargo, este resultado se ha considerado adecuado, dado que el Grupo 1 se corresponde con el grupo poblacional de menor tamaño y mayor volatilidad, por lo cual la PD estimada resulta conservadora y no afectaría demasiado a los resultados globales de la cartera.

• Grupo 2

Para este grupo también se propone utilizar un modelo de Bosque Aleatorio con 200 estimadores, criterio de división Gini y un tamaño de hoja del 0.1 %. El desempeño de este modelo se muestra a continuación:




Figura 3.27: Resultados Grupo 2.

Fuente: Elaboración propia.

Los resultados de las gráficas de la Figura 3.27 muestran que el modelo propuesto asigna una mayor probabilidad de incumplimiento a los clientes “Malos” que a los “Buenos”, generando una separación de poblaciones adecuada. Adicionalmente, este modelo cumple con los valores objetivo de todas las métricas de desempeño.

Por otro lado, como puede observarse en la gráfica 3.28, las predicciones del modelo también mantienen una consistencia temporal, dado que se observa que la PD grupal estimada se mantiene con la misma tendencia y en niveles cercanos a la PD grupal real.




Figura 3.28: Resultados Globales Grupo 2.

Fuente: Elaboración propia.

Considerando los puntos anteriores, se considera que este modelo propuesto resulta adecuado para la proyección de la PD.

• Grupo 3

El modelo propuesto para este grupo se corresponde con un Bosque Aleatorio de 500 estimadores, criterio de división Gini y un tamaño de hoja del 0.1 %.




Figura 3.29: Resultados Grupo 3.

Fuente: Elaboración propia.

Este modelo también muestra una separación adecuada de las poblaciones de clientes, lo cual es apoyado por los resultados de los índices de desempeño mostrados en la Figura 3.29, que cumplen con los valores objetivos (excepto el *Accuracy* dado el desbalanceo).




Figura 3.30: Resultados Globales Grupo 3.

Fuente: Elaboración propia.

Así mismo, el modelo mantiene la consistencia temporal en sus predicciones de la PD grupal, mostrando una tendencia y niveles similares a los reales. Dado lo anterior, el modelo se considera adecuado.

• Grupo 4

Para este grupo poblacional se propone utilizar un modelo de Bosque Aleatorio con 200 estimadores, criterio de división Gini y un tamaño de hoja del 0.1 %.




Figura 3.31: Resultados Grupo 4.

Fuente: Elaboración propia.

La separación de las poblaciones generada por el modelo se considera adecuada, dado que asigna una mayor probabilidad de incumplimiento a los clientes “Malos” que a los “Buenos”, lo cual se refuerza con los resultados de los índices de desempeño, que cumplen con los valores objetivos.




Figura 3.32: Resultados Globales Grupo 4.

Fuente: Elaboración propia.

De igual forma, este modelo mantiene la consistencia temporal en sus predicciones, manteniendo una tendencia y niveles similares a los realmente observados en la PD

grupal.

3.2. Modelo de Severidad

De acuerdo con el plan establecido, una vez concluida la elaboración de los modelos de PD, la siguiente actividad consiste en la construcción de un modelo para la estimación de la LGD, aplicable a aquellos créditos que hayan entrado en estatus de incumplimiento.

Para llevar a cabo esto, se propone el uso de modelos de árboles de regresión, los cuales son herramientas que permiten mapear el valor de una variable objetivo mediante la aplicación de reglas concurrentes. En nuestro caso específico, la variable objetivo es el parámetro de LGD y su mapeo se realiza mediante reglas que se aplican sobre un conjunto de variables que permiten construir perfiles de distintos grupos de clientes, de acuerdo con sus características y las de sus créditos.

En particular, las variables consideradas para el entrenamiento del modelo se obtuvieron a partir de la base de datos histórica de créditos que mantiene la UAIR. Dicha base contiene el registro de la LGD observada para aquellos créditos en incumplimiento, sin considerar el beneficio obtenido por garantías líquidas de primeras pérdidas.

Para la estimación del modelo sólo se consideran aquellas operaciones o créditos directos y con montos menores a los 3 millones de UDI's. Así mismo, también se tomó en cuenta el efecto de la madurez de la LGD, entendiendo como madurez al número de meses que un crédito lleva en estatus de incumplimiento.

En este sentido, se observó cuando un crédito cae en incumplimiento, su LGD es de 100%, por definición, sin embargo, conforme su madurez aumenta el valor de la LGD se reduce, de acuerdo con los pagos sobre vencido realizados por el cliente. De esta manera se determinó que, incorporar al análisis a aquellos créditos con una madurez menor a 12 meses, pudiera generar sesgos en el modelo, causando que la severidad se vea sobrestimada. Dado lo anterior, se optó por omitir del conjunto de datos a aquellos créditos cuya madurez fuera menor o igual a los 12 meses.

Por otro lado, en lo que respecta a las variables predictoras, la selección de estas se llevó a cabo mediante la aplicación de un análisis de importancias, el cual, a grandes rasgos, consiste en el entrenamiento de distintos árboles de regresión, los cuales son alimentados con diferentes subconjuntos de variables, permitiendo identificar aquellas con mayor poder predictivo, el cual es medido como el promedio de la reducción de varianza que genera cada variable en los distintos árboles entrenados. Los resultados obtenidos con este análisis se muestran en la gráfica de la Figura 3.33.




Figura 3.33: Importancia variables predictoras.

Fuente: Elaboración propia.

De esta manera, se seleccionaron las 10 variables que mostraron la mayor importancia estimada, las cuales se considera pueden generar una correcta segmentación de la población, permitiendo predecir el nivel de la LGD de acuerdo con el perfil de los créditos y de los clientes mismos. En este sentido, la Tabla 3.34 recopila las variables incorporadas al modelo, así como una pequeña descripción de estas.

Variable	Nombre	Descripción
porc_adeudo	Porcentaje de Adeudo	Proporción que guarda el saldo observado al momento del incumplimiento respecto del adeudo original (monto otorgado).
tipo_cred2	Tipo de Crédito	Tipo de producto crediticio asociado (Avío, Refaccionario, Comercialización, etcétera).
LGD_CTE	Severidad del Cliente	Severidad promedio mostrada por el cliente de manera histórica en operaciones previas.
anios_exper	Años de Experiencia	Años de experiencia del cliente con la Financiera desde la primera dispersión realizada.
region	Región	Región a la que se encuentra asociado el crédito (Norte, Sur, Sureste, etcétera).
des_productor	Descripción del Productor	Clasificación del diente de acuerdo con el tamaño de las operaciones que realiza (grande, mediano, pequeño, etcétera).
plazo2	Plazo	Plazo de vencimiento total del crédito medido en días.
monto_exp_udis	Monto Expuesto en UDI's	Saldo del crédito al momento del incumplimiento, dado en UDI's.
id_compor	Identificador de Comportamiento	Identifica si un cliente es nuevo o no.
niv_cobertura	Nivel de Cobertura	Nivel de garantías que mantiene el crédito de acuerdo con niveles del 1 al 3, siendo 3 el nivel más alto de cobertura.

Figura 3.34: Variables predictoras incorporadas al modelo.

Fuente: Elaboración propia.

Una vez determinadas las variables predictoras que se incluirán en el modelo, se procedió a realizar la segmentación de la base de datos, obteniendo un conjunto de entrenamiento y otro de pruebas. Dichos conjuntos guardan una proporción del 75 % y 25 % en relación con el conjunto de datos total, el cual consta de 31,784 registros.

De esta manera, el conjunto de entrenamiento fue utilizado para generar distintos modelos de árboles de clasificación. Los árboles generados están limitados a una profundidad máxima de 5 niveles, sin embargo, se varía el número de elementos mínimos que se puede tener en cada nodo hoja, lo que deriva en la poda de distintas ramas y genera modelos diferentes.

Dado lo anterior, los modelos resultantes fueron comparados mediante la implementación de una validación cruzada de 100 iteraciones, utilizando como medida de desempeño el Error Absoluto Medio (MAE). Los resultados obtenidos con este proceso se muestran en la Figura 3.35.




Figura 3.35: MAE en Validación Cruzada.

Se muestra la distribución de los MAE's obtenidos con distintos número de hojas en el modelo de predicción.

Fuente: Elaboración propia.

De manera general, el análisis de validación cruzada no mostró diferencias significativas entre el MAE obtenido por los distintos modelos, sin embargo, se optó por elegir el árbol que tiene más de 500 observaciones por hoja, dado que este es el que muestra un desempeño (MAE) más parecido entre el conjunto de entrenamiento (35.9%) y el de pruebas (35.6%), lo cual sugiere una mejor generalización del conocimiento, es decir, que no existe un sobreajuste sobre el conjunto de entrenamiento, permitiendo que las proyecciones de LGD realizadas sean adecuadas.

Así, el modelo seleccionado para la estimación de la LGD se corresponde con un árbol de regresión con una profundidad máxima de 5 niveles y hojas con al menos 500 observaciones, lo cual da como resultado un conjunto de 17 nodos con hojas o grupos de población bien diferenciados por nivel promedio de LGD, como puede observarse en la Figura 3.36.




Figura 3.36: Resultados modelo LGD.

Se muestra la distribución de la LGD real, respecto de los valores predichos por el modelo; se observa que el promedio real se corresponde con el valor predicho.

Fuente: Elaboración propia.

De manera general, se puede concluir que este modelo para predicción de severidad es adecuado, toda vez que realiza una segmentación de la población de acuerdo con su nivel promedio de LGD en función de las características de cada crédito y cliente asociado.

3.3. Modelo de Exposición

Dada la estructura de financiamiento de la FND, que se caracteriza por ofrecer créditos con esquemas de amortización que oscilan entre periodos trimestrales y anuales, se presenta una dinámica financiera particular, donde los saldos muestran poca variabilidad durante el año. Además, se observa que la entidad maneja un número limitado de líneas de crédito revolventes. Dicha configuración específica de los productos financieros implica consideraciones únicas en términos de modelado de riesgo crediticio.

En este contexto, se ha evaluado la necesidad de desarrollar un modelo específico para pronosticar la EAD de los clientes. Sin embargo, se ha llegado a la conclusión de que tal modelo no es imprescindible. El motivo de esta decisión radica en la posibilidad de

determinar el monto de la EAD de manera directa y eficiente, utilizando únicamente los calendarios de amortización ya establecidos para cada cliente.

Por tanto, la EAD se define de una manera más simplificada y directa. Se conceptualiza como el saldo promedio del cliente durante un periodo proyectado de los siguientes 12 meses. Esta aproximación asegura una estimación precisa del riesgo, al tiempo que simplifica el proceso de modelado y análisis financiero. En la gráfica 3.37 se muestra un histograma con la distribución que tendría la EAD bajo esta determinación.





Figura 3.37: Distribución EAD.

Muestra los distintos valores que toma la EAD estimada como el promedio del saldo proyectado a 12 meses.

Fuente: Elaboración propia.

The background features a complex, abstract design. On the left, there are concentric circular patterns with various line styles (solid, dashed, dotted) and small rectangular segments. To the right, there are several horizontal and diagonal lines, some with small circles or dots at their ends. A series of small, light-gray triangles points downwards in the upper right, and a series of small circles is arranged horizontally in the lower right. The overall aesthetic is technical and architectural.

Capítulo 4

Implementación del Cálculo VaR

4 Implementación del Cálculo VaR

4.1. Integración de Modelos

La implementación efectiva del cálculo del VaR para la cartera de créditos comenzó con una etapa crucial: la definición precisa de los modelos para predecir los componentes de riesgo. Esta fase, fundamental para la fiabilidad del cálculo del VaR, implicó una meticulosa selección y ajuste de modelos que pudieran estimar de manera efectiva la PD, la LGD y la EAD para cada cliente, lo cual se describe a detalle en el Capítulo 3.

Específicamente, los modelos propuestos para la estimación de la PD consisten en cuatro modelos de bosques aleatorios de clasificación, implementados para cada grupo o cartera de clientes, los cuales fueron identificados y diferenciados mediante análisis de segmentación. Estos modelos permiten estimar la PD individual de cada cliente, considerando ciertas características específicas del cliente y ajustando por efectos de factores macroeconómicos.

La estimación de la EAD se realiza mediante la implementación de un modelo de árbol de regresión, que predice la EAD de los clientes basándose en un perfil construido a partir de distintas variables propias de los clientes.

En cuanto a la LGD, debido a la dinámica particular de financiación de la FND, especialmente en términos de plazos otorgados y el limitado uso de líneas revolventes, se optó por utilizar como estimación el saldo promedio del cliente durante un periodo proyectado de los próximos 12 meses.

Posteriormente, estos modelos correspondientes a las componentes de riesgo fueron integrados conforme al esquema de implementación detallado en la sección 2.2 y visualizado en la figura 4.1. Esta integración permitió realizar el cálculo del VaR de crédito de forma individualizada, así como agrupada por carteras, facilitando así una gestión de riesgo más granular y ajustada a las necesidades específicas de la FND.




Figura 4.1: Modelo propuesto para cálculo del VaR.

Fuente: Elaboración propia

De manera general, este esquema de cálculo consiste en utilizar la PD estimada de cada cliente, para realiza una serie de 2,000 simulaciones mediante el método Simulación Montecarlo. Este número de simulaciones ha sido seleccionado para asegurar la estabilidad de las estimaciones y reducir la variabilidad inherente a la simulación, al mismo tiempo que se conserva la viabilidad de los cálculos en un tiempo razonable (alrededor de 2 horas en un equipo con procesador AMD Ryzen 5 3500U a 2.10 GHz, 12 GB de RAM).

Este procedimiento implica simular el incumplimiento de cada cliente utilizando una distribución de *Bernoulli*:

$$P(X = k) = \begin{cases} p & \text{si } k = 1, \\ 1 - p & \text{si } k = 0. \end{cases} \quad (4.1)$$

Donde el parámetro p corresponde a la PD estimada. Así, la ocurrencia de un evento de incumplimiento en un escenario simulado se interpreta como la realización efectiva de dicho incumplimiento por parte del cliente. Este enfoque no solo proporciona una base estadística sólida para modelar la ocurrencia aleatoria de incumplimientos, sino que también es crucial para capturar de manera eficaz la incertidumbre y la va-

riabilidad asociadas al comportamiento de incumplimiento en la cartera de créditos y los clientes individuales.

Posteriormente, para cada escenario simulado, se procedió al cálculo de la pérdida potencial, la cual define como el producto de la LGD y la EAD estimadas en aquellos casos donde la simulación indica la realización de un incumplimiento. Para los escenarios que no resultan en un incumplimiento, se asignó un valor de cero a la pérdida potencial, es decir:

$$PE = \begin{cases} EAD \times LGD & \text{si } k = 1, \\ 0 & \text{si } k = 0. \end{cases} \quad (4.2)$$

Finalmente, los resultados de estas simulaciones individuales se consolidan para formar una distribución de pérdidas simuladas de la cartera de créditos. Esta distribución constituye la base para el cálculo del VaR de crédito, proporcionando una medida cuantitativa del riesgo de pérdida bajo diversos escenarios.

Esta metodología no solo permite una evaluación detallada y rigurosa del riesgo de crédito, sino que también ofrece ventajas significativas sobre los métodos actualmente empleados por la FND. A diferencia de las técnicas previas, este enfoque posibilita agrupar y calcular el VaR para grupos de clientes o carteras de crédito de manera discrecional. Esta capacidad de realizar análisis detallados y focalizados sobre segmentos específicos mejora sustancialmente la toma de decisiones en la gestión de riesgos. Esta innovación representa una mejora significativa, al permitir un manejo más eficaz y adaptado de las estrategias de mitigación de riesgos, adecuado a las dinámicas y necesidades específicas de la FND, como se muestra con los resultados obtenidos en la siguiente sección.

4.2. Resultados Obtenidos

El esquema descrito anteriormente se aplicó específicamente a la cartera de créditos vigentes de la FND correspondiente a diciembre de 2021. Esta fecha fue seleccionada

estratégicamente para evaluar el rendimiento del esquema propuesto en un periodo que permite una oportunidad única para probar la robustez y la eficacia del nuevo enfoque en condiciones reales y no manipuladas. La elección de este punto temporal también fue crucial para permitir un contraste entre el desempeño del modelo propuesto en comparación con el modelo vigente, aprovechando la disponibilidad de datos reales sobre pérdidas correspondientes a esa fecha específica. Este análisis comparativo era esencial para entender las mejoras y las limitaciones del modelo introducido.

La eficacia del nuevo enfoque se evidencia con la comparación entre la distribución de pérdidas simuladas y las pérdidas reales observadas en la cartera de créditos analizada. Esta comparación actúa como una herramienta de validación empírica poderosa y esencial para el modelo y sus predicciones, proporcionando evidencia concreta de la capacidad del modelo para simular escenarios de riesgo cercanos a la realidad.

La gráfica 4.2 ilustra la comparación entre las estimaciones del modelo y las pérdidas reales observadas para diciembre de 2021:




Figura 4.2: Distribución pérdidas simuladas vs reales observadas

Fuente: Elaboración propia.

El gráfico 4.2 y a tabla 4.3 proporcionan evidencia de que la efectividad y precisión del modelo propuesto representan una mejora significativa frente al modelo vigente,

especialmente en términos de precisión y reducción del error en la estimación del riesgo de crédito. Este hallazgo es de particular importancia, ya que confirma que uno de los objetivos de este trabajo, el de mejorar la capacidad de anticipación y reflejo de la realidad del riesgo de crédito mediante un modelo más avanzado y preciso, ha sido alcanzado.

En particular, se observa una similitud significativa entre la estimación de la pérdida potencial media, calculada a partir de la distribución de pérdidas generada mediante el modelo propuesto, y la pérdida realmente observada para el mes de diciembre de 2021, con un error absoluto de apenas 0.9 %, en contraste con el error del 3.88 % mostrado por el modelo vigente.

Comparación de Estimaciones de PE (cientos de mdp)			
Modelo	PE Estimada	Error Absoluto (%)	VaR 95%
Vigente	1.47	3.88%	1.71
Nuevo	1.42	0.09%	1.58

Figura 4.3: Comparación de estimaciones de PE.

Fuente: Elaboración propia.

Esta proximidad en los resultados obtenidos no solo es deseable, sino que también valida la eficacia de los modelos implementados, sugiriendo una correcta estimación de la distribución de pérdidas potenciales.

Adicionalmente, se observa cómo los modelos permiten calcular el VaR, considerando la distribución de las pérdidas simuladas. Esta capacidad es crucial para prever pérdidas potenciales en situaciones extremas, cumpliendo así con la función principal del VaR de crédito, que es proporcionar una medida cuantitativa y confiable del riesgo de pérdida en condiciones adversas. En este punto, se destaca que el VaR estimado por el modelo propuesto es más conservador que el generado por el modelo vigente, llegando a ser hasta un 7.5 % menor.

La relevancia de este hallazgo radica en que, al generar predicciones que se acercan más a las observaciones reales en comparación con el modelo vigente, el cual tiende a sobrestimar las pérdidas, se puede obtener un impacto positivo sobre las reservas

de riesgo de crédito de la institución. Este efecto también podría trasladarse favorablemente sobre el estado de resultados de la institución, con la liberación de dichas reservas, beneficiando notablemente las finanzas de la FND.

No obstante, antes de implementar cambios en la estimación de reservas, es crucial realizar pruebas adicionales sobre el modelo. Esto incluye verificar la correcta estimación de las pérdidas en carteras específicas de especial interés para la FND, así como validar la estabilidad temporal del modelo para asegurar su fiabilidad y eficacia a lo largo de periodos prolongados. Estas evaluaciones son fundamentales, dado que las repercusiones de cualquier ajuste pueden ser significativas para la gestión de riesgos y las finanzas de la entidad.

4.3. Trabajos Futuros

Hasta este punto, se ha establecido un esquema robusto para la estimación de la distribución de las pérdidas por riesgo de crédito en la FND. Sin embargo, aún persisten diversas áreas de oportunidad que, de ser explotadas, podrían significar una mejora sustancial del modelo, integrándolo de manera más efectiva en la gestión diaria de riesgos y asegurando que este cumpla exhaustivamente con todas las necesidades de la FND, así como con los rigurosos requerimientos impuestos por las normativas de riesgo vigentes. Con el objetivo de avanzar hacia una práctica de gestión de riesgos más dinámica y adaptativa, se identifican los siguientes puntos clave para el desarrollo futuro:

- **Modelos ARIMA para complementar la predicción de PD:** La integración de modelos ARIMA se ha identificado como una necesidad crítica para la estimación efectiva del VaR en periodos futuros, en línea con el desarrollo metodológico discutido en la sección 3.1.5. La implementación de estos modelos presenta desafíos significativos, ya que requiere un análisis exhaustivo del comportamiento de las series temporales de PD para cada grupo de riesgo identificado. Es esencial identificar no solo los patrones recurrentes sino también posibles estacionalidades que podrían influir en el comportamiento del riesgo de crédito de estos gru-

pos. Además, se sugiere explorar la implementación de modelos del tipo VAR, que ofrecen la capacidad de modelar las series temporales de todos los grupos de riesgo de manera simultánea. Esta aproximación facilita la incorporación de correlaciones entre los diferentes grupos de riesgo, mejorando así nuestra comprensión de las interacciones y las influencias recíprocas entre ellos. La adopción de modelos VAR podría revelar dinámicas complejas y sutiles entre las categorías de riesgo, proporcionando una herramienta poderosa para la predicción más precisa y la gestión más efectiva del riesgo global.

- **Escenarios *What If*, Estrés y Sensibilidad:** La implementación de escenarios de *What If*, pruebas de estrés y análisis de sensibilidad es fundamental para evaluar la capacidad del modelo para manejar cambios hipotéticos o extremos en las condiciones macroeconómicas y otras variables clave que afectan el riesgo de crédito. Estos análisis son cruciales para entender cómo variaciones en los factores macroeconómicos podrían impactar las predicciones de pérdidas y el comportamiento del riesgo de crédito en general. Además, estas pruebas permiten identificar y fortalecer los puntos de vulnerabilidad del modelo, proporcionando una oportunidad para calibrar y ajustar las respuestas del modelo ante situaciones económicas volátiles o inusuales. Al realizar estas pruebas regularmente, se puede asegurar que el modelo se mantenga robusto y relevante, adaptándose efectivamente a cualquier cambio en el entorno económico y financiero. Este proceso de evaluación continua es esencial para la gestión proactiva de riesgos, permitiendo a la institución anticipar problemas potenciales y tomar medidas correctivas antes de que se materialicen riesgos significativos.
- **Mejora de Modelos de EAD para créditos Revolventes:** Los créditos revolventes presentan desafíos particulares debido a su naturaleza dinámica, que implica fluctuaciones frecuentes en los saldos crediticios y patrones de uso variados por parte de los clientes. Aunque el porcentaje de estos créditos es relativamente bajo dentro del portafolio de la FND, es crucial mejorar los modelos de EAD específicamente para este tipo de productos. La mejora propuesta permitirá obtener estimaciones más precisas y realistas de las exposiciones crediticias, ajustando

mejor las reservas de capital y las estrategias de mitigación de riesgos. Actualmente, el modelo utilizado puede subestimar las pérdidas potenciales, especialmente porque no incorpora adecuadamente el comportamiento de sobreendeudamiento que es frecuente en estos productos cuando ocurre un incumplimiento. Esta deficiencia en la estimación del EAD puede llevar a una inadecuada cobertura de riesgo. Por tanto, se propone desarrollar y calibrar modelos que consideren factores específicos como el comportamiento de pago del deudor para reflejar más fielmente el riesgo asociado con créditos revolventes. Este esfuerzo mejorará la gestión del riesgo crediticio y financiero en las carteras específicas donde estos productos tienen mayor relevancia.

- **Profundización en la validación del modelo:** Es crucial realizar validaciones más exhaustivas del modelo para asegurar su robustez y fiabilidad. Es fundamental evaluar la estabilidad del modelo a lo largo del tiempo para garantizar que se mantenga preciso y relevante frente a las fluctuaciones macroeconómicas. La validación rigurosa del modelo no solo asegura su precisión en el corto plazo, sino que también fortalece su capacidad de adaptación a largo plazo, lo cual es esencial para que continúe siendo una herramienta efectiva en la gestión de riesgos. En particular, la implementación de pruebas de *backtesting* sobre el VaR es un componente crítico de esta validación. El *backtesting* proporciona una medida directa de la efectividad del modelo bajo diferentes condiciones históricas, permitiendo verificar si el VaR calculado por el modelo refleja adecuadamente el riesgo de crédito real. Este proceso es indispensable para confirmar que el VaR es un indicador confiable y que puede ser utilizado con confianza en la toma de decisiones estratégicas con un impacto profundo en las finanzas de la FND. Realizar estas pruebas con regularidad también ayudará a mantener la integridad y la confianza en el modelo, asegurando que continúe cumpliendo con los estándares de riesgo y proporcionando mejoras valiosas para la gestión efectiva del riesgo de crédito.
- **Elaboración del Aplicativo:** La propuesta de desarrollar un aplicativo dedicado para facilitar la implementación y operación diaria del modelo de gestión de ries-

go en la FND es un paso crucial hacia la modernización y eficiencia de los procesos internos. Este aplicativo no solo deberá ser intuitivo y fácil de usar para asegurar su adopción, sino que también debe ofrecer la flexibilidad necesaria para realizar ajustes y análisis en tiempo real. Importante dentro de sus funcionalidades estaría la capacidad de aplicar pruebas de sensibilidad y estrés de manera sencilla, así como la implementación del *backtesting*, elementos esenciales para monitorear y evaluar continuamente el desempeño del modelo bajo diversas condiciones de mercado. La creación de esta herramienta se visualiza como un recurso integral que facilitará la aplicación rutinaria del modelo y la toma de decisiones informadas y respaldadas por datos actualizados y pertinentes.

La ejecución de estos trabajos no solo fortalecerá la precisión y la aplicabilidad del modelo propuesto, sino que también asegurará su adaptabilidad y sostenibilidad a largo plazo en el dinámico campo de la gestión de riesgos dentro de la FND. Al abordar estas mejoras y extensiones, el modelo no solo se alinearán mejor con las necesidades y exigencias actuales, sino que también estará equipado para responder eficazmente a futuros desafíos y cambios en el entorno regulador y económico. Este enfoque proactivo en la mejora continua y en la adaptación del modelo garantiza que la FND mantenga la eficacia en la gestión de riesgos.

4.4. Conclusiones

Este trabajo ha propuesto el uso de un enfoque meticuloso en la construcción de modelos para la estimación de los componentes del riesgo de crédito, los cuales se han aplicado integralmente en la estimación de la distribución de pérdidas y el VaR de crédito. Los resultados detallados en la sección anterior (4.2) confirman que se ha alcanzado el objetivo principal de este trabajo, pues se ha desarrollado exitosamente un modelo de VaR de crédito que se adapta específicamente al contexto único de la FND, integrando avanzadas técnicas de ciencia de datos para mejorar de manera significativa la precisión en las estimaciones de las pérdidas potenciales en la cartera de créditos de la institución.

En particular, este modelo representa un avance significativo sobre el método vigente de la FND, proveyendo no solo una herramienta más precisa para la gestión del riesgo, sino también una plataforma adaptable para futuras innovaciones y mejoras conforme evolucionen las necesidades de la institución y el entorno financiero.

Además de alcanzar el objetivo principal de este trabajo, también se han derivado varias conclusiones importantes de los análisis realizados. Estas conclusiones adicionales, compiladas a continuación, reflejan las mejoras específicas logradas a través del enfoque metodológico adoptado y proporcionan una visión más completa del impacto y la eficacia del modelo propuesto:

1. **Identificación de Grupos de Riesgo:** A través de un enfoque de segmentación no supervisada, se logró identificar cuatro grupos de riesgo o subcarteras, cada uno con comportamientos y niveles de riesgo claramente diferenciados según tipos de actividad y regiones geográficas, como se detalla en la sección 3.1.3. Además, el análisis reveló que estos grupos son influenciados de manera distinta por los factores macroeconómicos, subrayando la diversidad de exposiciones a riesgos en la cartera. Esta segmentación ha proporcionado una comprensión mucho más profunda de los distintos grupos de la cartera de créditos, lo que ha resultado en mejoras significativas en la gestión de riesgos. Esta mejora no solo se ha limitado a la gestión de créditos sino que también ha impactado positivamente otras áreas operativas de la FND, facilitando una aproximación más integrada y estratégica a la gestión financiera y operativa de la institución.
2. **Precisión en la Estimación de la PD:** La implementación de un enfoque centrado en el cliente para calcular la PD ha resultado en una mejora significativa de la precisión en las estimaciones del riesgo de crédito. Este método ha permitido una evaluación más detallada y personalizada del comportamiento crediticio de los clientes, integrando variables más complejas y dinámicas que reflejan con mayor fidelidad el verdadero riesgo de incumplimiento. Este refinamiento metodológico no solo ha mejorado la precisión de las estimaciones, sino que también ha contribuido a una gestión de riesgo más efectiva dentro de la institución.

3. **Implementación Exitosa del Cálculo VaR:** La implementación del cálculo del VaR utilizando simulaciones de Simulación Montecarlo ha establecido una base robusta y flexible para modelar el riesgo de pérdidas crediticias. Este método ha demostrado una notable capacidad para adaptarse tanto a evaluaciones de riesgo individuales como globales, además, permite la realización de agregaciones y análisis detallados de subcarteras, ofreciendo posibilidades de evaluación que el modelo anterior no permitía. Esta capacidad de analizar distintos segmentos de la cartera de forma granular y en múltiples escenarios hipotéticos, ha mejorado significativamente la precisión de las predicciones de riesgo y ha enriquecido la toma de decisiones estratégicas en la gestión de riesgos.
4. **Mejoras en Precisión y Reducción del Error:** El nuevo esquema de modelado ha demostrado una mejora sustancial en la precisión y una notable reducción del error en comparación con el modelo vigente, alcanzado una reducción en términos absolutos de hasta el 76%. Tal como se discutió en la sección 4.2, estas mejoras no solo son significativas en términos metodológicos, sino que también tienen un impacto positivo directo sobre los resultados financieros de la institución. Esta elevación en la exactitud de las estimaciones permite una asignación de reservas más eficiente, contribuyendo así a una gestión de riesgo más sólida y confiable.

En conclusión, este trabajo ha realizado aportaciones significativas a la gestión de riesgo crediticio en la FND, demostrando cómo la implementación de modelos avanzados y técnicas de segmentación sofisticadas puede transformar fundamentalmente la precisión y eficacia con la que se manejan los riesgos. Las metodologías desarrolladas y los resultados obtenidos no solo refuerzan las capacidades internas de la FND, sino que también establecen un marco que puede ser adaptado y aplicado a otras instituciones financieras con necesidades similares.

La adaptabilidad del modelo propuesto permite su aplicación en diversos contextos institucionales, ofreciendo a otras entidades una valiosa herramienta para mejorar sus estrategias de gestión de riesgo. Esto es especialmente relevante en un entorno económico global que es cada vez más volátil y donde las instituciones financieras enfrentan

desafíos complejos que requieren respuestas sofisticadas y personalizadas.

Por último, los hallazgos y metodologías de este trabajo no solo tienen la capacidad de influir en las operaciones actuales de las entidades financieras, sino que también ofrecen una base sólida para futuras investigaciones en el campo del riesgo crediticio. Se anima a otras instituciones a considerar estos enfoques en sus operaciones, adaptándolos a sus propios contextos y desafíos, lo que sin duda ayudará a fomentar un entorno financiero más resiliente y adaptativo.

Bibliografía

- [Bart Baesens, 2008] Bart Baesens, T. v. G. (2008). *Credit Risk Management: Basic Concepts: Financial Risk Components, Rating Analysis, Models, Economic and Regulatory Capital*. OXFORD UNIV PR.
- [Bellotti and Crook, 2012] Bellotti, T. and Crook, J. (2012). Loss given default models incorporating macroeconomic variables for credit cards. *International Journal of Forecasting*, 28(1):171–182.
- [BIS, 2010] BIS (2010). Basilea iii: Marco regulador global para reforzar los bancos y sistemas bancarios. Technical report, Comité de Supervisión Bancaria de Basilea.
- [CNBV, 2006] CNBV (2006). Disposiciones de carácter general en materia prudencial, contable y para el requerimiento de información aplicables a la financiera nacional de desarrollo agropecuario, rural, forestal y pesquero. Publicado en el Diario Oficial de la Federación.
- [Community, 2024] Community, S. (2024). Canberra distance - scipy documentation. <https://docs.scipy.org/doc/scipy/reference/generated/scipy.spatial.distance.canberra.html>. Accessed: 2024-09-23.
- [Dassatti, 2019] Dassatti, C. (2019). Modelos de score crediticio: revisión metodológica y análisis a partir de datos de encuesta (credit score models: Methodological review and analysis based on survey data). *SSRN Electronic Journal*.
- [de Lara Haro, 2019] de Lara Haro, A. (2019). *Medición y control de riesgos financieros*.
- [DOF, 2002] DOF (2002). Ley orgánica de la financiera nacional de desarrollo agropecuario, rural, forestal y pesquero. Publicado en el Diario Oficial de la Federación. Última reforma publicada DOF 06-11-2020.
- [Gürtler et al., 2018] Gürtler, M., Hibbeln, M. T., and Usselman, P. (2018). Exposure at default modeling – a theoretical and empirical assessment of estimation approaches and parameter choice. *Journal of Banking & Finance*, 91:176–188.

- [Janet Zhao, 2019] Janet Zhao, L. Y. (2019). Usage and exposures at default of corporate credit lines. *Moody's Analytics*.
- [Ken Brown, 2014] Ken Brown, P. M. (2014). *Credit Risk Management*. Edinburgh Business School.
- [Linsmeier and Pearson, 2000] Linsmeier, T. J. and Pearson, N. D. (2000). Value at risk. *Financial Analysts Journal*, 56(2):47–67.
- [Merton, 1974] Merton, R. C. (1974). On the pricing of corporate debt: The risk structure of interest rates. *The Journal of Finance*, 29(2):449.
- [Michel Crouhy, 2000] Michel Crouhy, Dan Galai, R. M. (2000). A comparative analysis of current credit riskmodels. *Journal of Banking I& Finance*, 24(1-2):59–117.
- [Onmus-Baykal, 2010] Onmus-Baykal, E. (2010). A literature review of credit risk modeling. *Georgetown University, Washington, DC*.
- [Paleologo et al., 2010] Paleologo, G., Elisseeff, A., and Antonini, G. (2010). Subagging for credit scoring models. *European Journal of Operational Research*, 201(2):490–499.
- [Raschka, 2020] Raschka, S. (2020). *Python machine learning*. Packt Publishing, Birmingham, 3rd ed. edition. Includes bibliographical references and index.
- [RiskMetrics Group, 1997] RiskMetrics Group, I. (1997). Creditmetrics -technical document. Technical report, CreditMetrics.
- [Rogojan et al., 2023] Rogojan, L. C., Croicu, A. E., and Iancu, L. A. (2023). Modern approaches in credit risk modeling: A literature review. *Proceedings of the International Conference on Business Excellence*, 17(1):1617–1627.
- [scikit-learn community, 2024a] scikit-learn community (2024a). Calinski-harabasz index - scikit-learn documentation. https://scikit-learn.org/stable/modules/generated/sklearn.metrics.calinski_harabasz_score.html. Accessed: 2024-09-23.

- [scikit-learn community, 2024b] scikit-learn community (2024b). Silhouette coefficient - scikit-learn documentation. https://scikit-learn.org/stable/modules/generated/sklearn.metrics.silhouette_score.html. Accessed: 2024-09-23.
- [Suisse, 1997] Suisse, C. (1997). Creditrisk+: A credit risk management framework. *Credit Suisse Financial Products*.
- [Tong et al., 2016] Tong, E. N., Mues, C., Brown, I., and Thomas, L. C. (2016). Exposure at default models with and without the credit conversion factor. *European Journal of Operational Research*, 252(3):910–920.
- [Wilson, 1997] Wilson, T. (1997). Portafolio credit risk (i). *Risk Primer*.
- [Yashkir and Yashkir, 2013] Yashkir, O. and Yashkir, Y. (2013). Loss given default modeling: a comparative analysis. *The Journal of Risk Model Validation*, 7(1):25–59.
- [Zhang and Nadarajah, 2017] Zhang, Y. and Nadarajah, S. (2017). A review of back-testing for value at risk. *Communications in Statistics - Theory and Methods*, 47(15):3616–3639.