



Universidad de
SanAndrés

Universidad de San Andrés
Escuela de Administración y Negocios
Magister en Finanzas

Previsiones por Incobrabilidad

“Impacto del Modelo NIIF 9”

Autor: Farías López, Noelia

DNI: 32.994.329

Director de Trabajo Final de Graduación: Basaluzzo, Gabriel

Buenos Aires, Agosto 2020.

1. INTRODUCCIÓN.....	4
2. REVISIÓN BIBLIOGRÁFICA	8
3. MARCO NORMATIVO	14
3.1. Lineamientos del BCRA	14
3.2. Lineamientos de la NIIF 9.....	16
4. METODOLOGÍA	20
4.1. Probabilidad de <i>Default</i> (PD).....	20
4.1.1. Regresión Logística.....	22
4.1.2. Regresión de Cox.....	24
4.1.3. Validación de Regresiones	28
4.2. Exposición al <i>Default</i> (EAD)	30
4.3. Pérdida dado el <i>Default</i> (LGD).....	31
4.4. Pérdida Crediticia Esperada (ECL)	34
5. VARIABLES Y DATOS UTILIZADOS.....	35
5.1. Modelo de <i>scoring</i> de admisión.....	35
5.2. Modelo de <i>scoring</i> de comportamiento.....	37
5.3. Modelo de <i>scoring lifetime</i>	39
5.4. Cálculo de la LGD.....	41
5.5. Cálculo de previsiones.....	41
6. RESULTADOS E INTERPRETACIÓN	42
6.1. Modelo de <i>scoring</i> de admisión.....	42
6.2. Modelo de <i>scoring</i> de comportamiento.....	44
6.3. Modelo de <i>scoring lifetime</i>	46
7.7. Cálculo de la LGD.....	49
7.8. Cálculo de Previsiones.....	50
7. CONCLUSIÓN.....	53
8. BIBLIOGRAFÍA.....	56
9. ANEXOS.....	58

Abstract

En el presente trabajo se desarrolla una propuesta metodológica de cálculo de provisiones contables bajo lineamientos de las Normas Internacionales de Información Financiera 9, basada en pérdidas crediticias esperadas sobre una cartera de préstamos personales de una entidad financiera, con el objetivo de comprender el posible impacto económico que generaría dicho cambio respecto al modelo tradicional de provisiones mínimas por riesgo de incobrabilidad establecido por el Banco Central de la República Argentina.

Mediante modelos de regresión logística y modelos de supervivencia se estimaron las probabilidades de default y, considerando la posible exposición a riesgo, se comprobó que las provisiones contables bajo los lineamientos referidos se incrementan en un 30%, generando un impacto negativo en los estados financieros de la entidad.



1. INTRODUCCIÓN

La crisis financiera de 2007/2009 puso de manifiesto los costos sistémicos que surgen al reconocer de forma insuficiente y/o tardía las provisiones contables por incobrabilidad. Además, ha generado dudas acerca de si los modelos de provisionamiento vigentes contribuían a la prociclicidad, estimulando una actividad de colocación de préstamos personales excesiva durante la fase de auge y provocando una contracción en la fase de desaceleración posterior.

Luego de esta situación, los líderes del G-20, inversores y reguladores fomentaron a los organismos de normalización contable a mejorar las normas y las prácticas en materia de provisiones. En respuesta a este pedido, el Consejo Internacional de Normas de Contabilidad ("IASB", por sus siglas en inglés) publicó en 2014 una nueva Norma Internacional de Información Financiera "NIIF 9. Instrumentos Financieros", que incluye una nueva metodología para la dotación de provisiones por incobrabilidad basadas en las pérdidas crediticias esperadas (ECL).

Argentina, como miembro del G-20 y del Consejo para la Estabilidad Financiera ("FSB", por sus siglas en inglés) asumió el compromiso de converger hacia estándares internacionales en materia de normas de información financiera. Por lo tanto, en el marco del cumplimiento de los "Principios básicos para una supervisión bancaria eficaz"¹ del Comité de Basilea, el Banco Central de la República Argentina ("BCRA") se encargó de satisfacer que las entidades mantengan registros de acuerdo con políticas y prácticas contables con amplia aceptación internacional.

El BCRA ha decidido la convergencia hacia las NIIF emitidas por el IASB para la confección de los estados financieros de las entidades alcanzadas por la Ley de Entidades Financieras (N° 21.526) correspondientes a los ejercicios anuales iniciados a partir de enero de 2018. Sin embargo, resolvió postergar la

¹ BCBS (2012) - Principios Básicos para una supervisión bancaria eficaz.

implementación de la sección de deterioro, entendiendo el fuerte impacto que podría generar² y estableció su comienzo para los ejercicios de 2020³.

Las entidades financieras se fueron preparando para implementar esta nueva metodología que requiere de un desarrollo complejo en modelos predictivos, una estrecha coordinación entre importantes áreas de la organización (como son tecnología, riesgos y contabilidad) y afrontar la complejidad habitual e inquietud organizacional que provocan los proyectos de estas características.

Este nuevo esquema tiene una visión prospectiva *-forward looking-*, de tal forma que ya no es necesario que se produzca un evento activador para que se declaren pérdidas crediticias y *-en consecuencia-* un incremento en las provisiones, si no que anticipa el comportamiento en función a la Pérdida Crediticia Esperada ("ECL", por sus siglas en inglés) desde la originación de la obligación.

En noviembre de 2016, la Autoridad Bancaria Europea ("ABE") publicó un informe sobre el progreso en la aplicación de la NIIF 9 de más de 50 instituciones financieras y mencionó que se estimaba un incremento del 18% promedio en los valores a provisionar y que su máximo podría alcanzar valores cercanos de hasta un 30%. No obstante, cabe mencionar que no es el mismo riesgo que gestionan las entidades argentinas, sobre las cuales aún no hay datos estadísticos publicados.

En el presente trabajo se propondrá desarrollar una metodología de cálculo de provisiones basadas en pérdidas esperadas y aplicarla a una cartera de préstamos personales de una entidad financiera, con el objetivo de comparar los resultados contra la normativa de provisionamiento tradicional. Adicionalmente,

² "A" 6114 Circular CONAU 1-1191 Convergencia del Régimen Informativo y Contable hacia las Normas Internacionales de Información Financiera.

³ "A" 6430 Circular CONAU 1-1262. Plan de implementación para la convergencia hacia las Normas Internacionales de Información Financiera.

se analizará el posible impacto económico, como así también repercusiones en la forma de gestionar el riesgo de crédito.

En el capítulo 2 se comenzará por realizar una revisión bibliográfica a fin de comprender en detalle el alcance de la nueva normativa y los principales efectos sobre la gestión de riesgo de las entidades financieras. Para ello, se tomarán como base los principios de las buenas prácticas establecidas por el Comité de Basilea, así como también, el criterio de experto de diversos autores que abordan el cálculo de parámetros para tomar como base en el desarrollo metodológico.

A continuación, en el capítulo 3, se realizará un recorrido del marco normativo para comprender cómo han surgido las NIIF 9 y se desarrollará el contenido de dicha norma con la intención de detectar los lineamientos a ser considerados en la estimación de cada uno de los parámetros de pérdida esperada. Asimismo, se analizarán las principales diferencias con el marco tradicional establecido por el BCRA, entre las cuales destacan la clasificación en 3 fases (*stages*) de las normas NIIF respecto a las 5 clasificaciones del BCRA; y la visión prospectiva versus la retrospectiva. Por otro lado, se aclara que no se tendrán en cuenta las últimas medidas dictadas por el BCRA como consecuencia de la pandemia COVID-19.

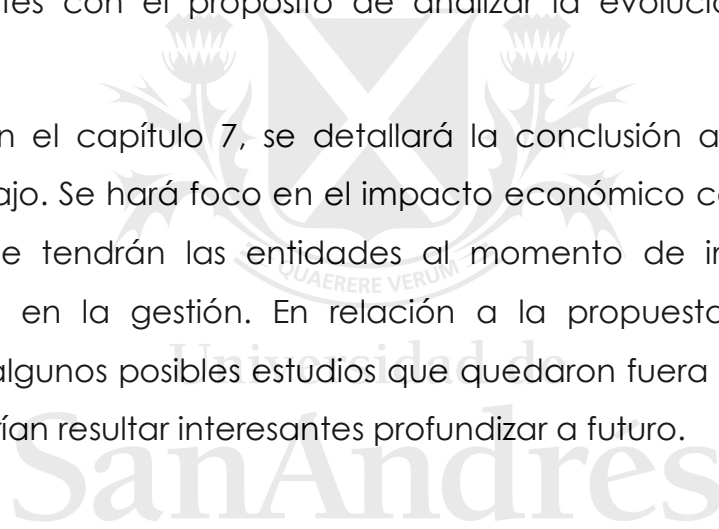
En el capítulo 4 se hará un abordaje más detallado, y se pondrán de resalto ciertos conceptos preliminares que ayudarán a comprender el alcance de los parámetros que conforman la función de pérdida. Se presentarán las propuestas metodológicas para obtener cada uno de ellos: la probabilidad de default ("PD", por sus siglas en inglés), la Pérdida dado el Default ("LGD", por sus siglas en inglés) y la exposición en el momento del incumplimiento ("EAD", por sus siglas en inglés). En cuanto a la estimación de la PD se propondrá utilizar modelos de regresión logística y modelos de supervivencia de Cox. Para la estimación de la LGD, se propondrá utilizar una metodología conocida como "Chain Ladder", frecuentemente considerada en la estimación de reservas de las compañías

aseguradoras. Por último, para la estimación de la EAD se propondrá considerar la exposición a riesgo al momento de valorar la previsión.

En el capítulo 5 se detallarán las variables y bases de datos utilizadas para las estimaciones. Cabe destacar que las mismas estarán basadas en la información interna de una entidad financiera, tomando en consideración la profundidad histórica y la materialidad de la cartera de análisis.

Como corolario, en el capítulo 6, se expondrán e interpretarán los resultados de cada uno de los parámetros y del cálculo de provisiones, considerando ambas metodologías. Si bien estas últimas se calcularon sobre un mes base, sobre el cuál se analiza con profundidad los resultados, también se calcularon para los 11 meses siguientes con el propósito de analizar la evolución de los ratios de coberturas.

Finalmente, en el capítulo 7, se detallará la conclusión arribada a partir del presente trabajo. Se hará foco en el impacto económico como así también en el desafío que tendrán las entidades al momento de implementación y/o consideración en la gestión. En relación a la propuesta metodológica, se comentarán algunos posibles estudios que quedaron fuera de alcance de este trabajo y podrían resultar interesantes profundizar a futuro.



2. REVISIÓN BIBLIOGRÁFICA

Se expondrán a continuación los principales trabajos que abordan el tema objeto de estudio y han sido consultados o tomados como base para desarrollar la propuesta metodológica. Si bien existen numerosos trabajos que analizan el cálculo de pérdidas esperadas y parámetros de riesgo de crédito, se han encontrado escasos abocados al cambio normativo. Aquellos referentes a la NIIF 9 realizan interpretaciones de las normas, pero no proponen una metodología de cálculo en sí.

El Comité de Supervisión Bancaria de Basilea ha publicado en 2015 un documento de "Orientaciones sobre la contabilidad de las pérdidas crediticias esperadas" donde establece 11 principios de buenas prácticas para aplicar la ECL. Incluye directivas sobre los procesos, documentación, políticas y divulgación. Asimismo, establece que los supervisores bancarios deben evaluar periódicamente la eficacia de las prácticas de riesgo de crédito de las entidades. Varios de estos puntos serán analizados en el apartado de conclusiones como principales desafíos para las entidades financieras que convergen a este nuevo esquema de provisionamiento.

Las principales consultoras internacionales han realizado valiosos trabajos de interpretación que han sido analizados. Deloitte (2016) realiza una revisión normativa y explica a detalle qué activos son alcanzados por el modelo de deterioro. Menciona que se introduce un nuevo enfoque de clasificación, basado en dos conceptos: las características de los flujos de efectivo contractuales de los activos y el modelo de negocio de la entidad. En función a esta interpretación, será posible validar la correcta implementación del modelo sobre la cartera de préstamos utilizada ya que la misma se encuentra valuada a costo amortizado por ser un activo cuyo objetivo final es cobrar los flujos contractuales.

El documento de Deloitte compara el modelo prospectivo con el retrospectivo de la NIC 39, lo cual se utilizará como base para efectuar la misma comparación, pero con la normativa BCRA. Asimismo, amplía el alcance de cada clasificación (*stage*) del modelo destacando los plazos de estimación de parámetros para cada uno de ellos. En este sentido, aclara que en *stage* 1 las pérdidas crediticias deben ser estimadas a 12 meses y que en *stage* 2 y 3 deben ser estimadas durante toda la vida del crédito. Se retomará este tema en la siguiente sección.

KPMG (2016) agrega que, si bien la incobrabilidad histórica es una base importante para la medición de las pérdidas crediticias esperadas, no es el único factor a tener en cuenta. Se espera que la entidad considere adicionalmente las condiciones macroeconómicas actuales y las que se esperan que se presenten en el futuro previsible, por ejemplo, las que hayan sido consideradas en el plan de negocios. Si bien en este trabajo no se aplicará un modelo macroeconómico, quedará para profundizar a futuro el desarrollo de un ajuste sobre los parámetros por posibles cambios en los escenarios. Asimismo, remarca la importancia de tener en cuenta el valor tiempo del dinero, tal como indica la norma, a fin de determinar el valor actual de la pérdida por incobrabilidad futura. En esta línea, se definirá en el apartado de EAD una actualización financiera de la pérdida considerando la tasa efectiva de cada préstamo de la base valuada.

Cohen y Edwards (2017) también analizan los principales aspectos de la nueva norma. Realizan una reseña de cómo ha surgido esta propuesta de tener un modelo prospectivo, luego de la crisis financiera de 2007/2009 donde quedó de manifiesto la insuficiencia de provisiones y la necesidad de transparencia en los estados financieros. Asimismo, agregan que puede ocurrir que los precios de los préstamos no reflejen los riesgos como consecuencia de condiciones de mercado transitorias, por lo cual refuerzan la importancia de tener una previsión que refleje el verdadero riesgo crediticio para mantener la solvencia y no tener un impacto en capitales. En virtud de la NIIF 9, mencionan que la relación entre las ECL durante toda la vida del activo y las ECL de 12 meses depende de

numerosos factores, incluido el vencimiento del préstamo y la evolución prevista de los riesgos de impago y los valores de recuperación durante su vida. En este trabajo, se podrá observar un incremento significativo en la valuación de la PD *lifetime* respecto de la PD a 12 meses dado que los plazos promedios de originación se encuentran en 24 meses, es decir, en algunos casos se duplica la ventana observada para identificar el default.

Los autores reconocen que los bancos pueden tener modelos bien establecidos para el cálculo de las pérdidas esperadas con fines de capital regulador. Sin embargo, aunque pueden usarse como un importante punto de partida para estimar las ECL con fines contables, los modelos de capital regulador pueden no ser utilizados directamente, sin ajustes, para calcular las ECL con fines contables debido a diferencias entre los objetivos y los datos utilizados para cada uno de estos fines. En este sentido, si bien no se han encontrado trabajos metodológicos abocados a NIIF 9, se puede verificar cierta relación con los modelos de capital económico conocidos. Adicionalmente, mencionan la diferencia de utilizar un ciclo completo versus un período más reciente para ajustar los parámetros. Dicha recomendación será tenida en cuenta al momento de seleccionar las muestras de modelado, incluyendo bases de datos más cercanas a la actualidad de la entidad.

PwC (2018) también realiza una interpretación de la normativa NIIF y aporta, respecto a los trabajos de las otras consultoras, algunos ejemplos de lo que podría ser considerado como "aumento significativo del riesgo". Si bien este punto será ampliado en la siguiente sección, menciona que además de basarse en los días de atraso superiores a 30 días, las entidades podrían definirlo en función a la variación del rating entre el momento de valuación y su reconocimiento inicial, la evaluación de la contraparte, el riesgo máximo que se quiere asumir, cambios en indicadores externos de mercado, cambio en indicadores internos de precio u otros aspectos cualitativos. Dichas consideraciones serán omitidas para la

definición de *stage 2* por no ser objetivo de estudio, pero resultan interesantes de profundizar a futuro.

Adicionalmente, Novotny-Farkas (2016) examina las diferencias entre el modelo NIIF versus el modelo vigente en la Unión Europea y analiza el impacto en el capital regulatorio. Aquí se presenta la fórmula de pérdida esperada bajo lineamientos NIIF 9 partiendo de los parámetros: PD-LGD-EAD que será considerada para la propuesta metodológica y ampliada en la sección 4.4. Si bien no presentan resultados numéricos, intuyen que la previsión posiblemente genere un incremento significativo al pasar de *stage 1* a *stage 2*. En este trabajo, esto se podrá validar en términos relativos de cobertura, pero no es donde se encontrará el mayor impacto económico respecto a la normativa BCRA. Se ampliará a ese punto cuando se expongan los resultados.

En cuanto a la estimación de parámetros, Hand y Henley (1997) profundizan en posibles técnicas de *credit scoring* para clasificar a los clientes entre buenos y malos pagados y, en consecuencia, obtener una probabilidad de default asociada. En esta línea, se considerará la misma metodología que mencionan para obtener las PDs mediante el valor del score a obtener a partir las regresiones logísticas. Por otro lado, comentan que con la información contenida en las solicitudes de crédito y en otras fuentes, el scoring permite tomar la decisión de otorgar o no un crédito (es el caso del *application scoring*) o realizar el seguimiento del deudor (*behavioral scoring*). En esta línea, se definirá generar dos modelos diferenciados: uno para clientes nuevos y otro para clientes con historial crediticio, debido a que para este último grupo se cuenta con más información que podría permitir una mejor precisión en la estimación de la probabilidad de default.

Bolton (2009) desarrolla la aplicación de la regresión logística en *credit scoring* y enumera una serie de pasos que recomienda seguir para obtener un modelo robusto que serán considerados en este trabajo: entendimiento del problema,

definición de variable objetivo, data histórica, variables, bivariados y partición de muestra. Estos pasos serán ampliados en la sección 5 dentro de cada modelo de regresión.

Asimismo, recomienda utilizar el índice KS y la curva ROC como medidas estadísticas para medir la performance de los modelos, que serán considerados en la sección 4.1.3. Bolton menciona que un modelo cuyo KS obtenido sea menor a 20 puntos no es lo suficientemente bueno y que para valores por encima de 70, probablemente el modelo sea demasiado bueno para ser verdad. En este sentido, luego de recalibrar cada regresión se calcularán los KS con el objetivo de validar dichos intervalos. Los resultados obtenidos se expondrán en el apartado 6.

Hosmer y Lemeshow (2013) también abordan la aplicación de regresiones logísticas e incluyen un apartado de interpretación de coeficientes para entender cómo afecta cada una de las variables seleccionadas sobre la variable objetivo. Cuando se amplíen los resultados de los modelos se mostrará con algunos ejemplos cómo afecta el signo y el valor del coeficiente sobre la probabilidad de default, siguiendo la misma dirección que este *paper*.

Sepanova y Thomas (1999) demuestran que es posible aplicar modelos de supervivencia al riesgo de crédito y realizan un ajuste sobre una cartera de préstamos. Generan un modelo estático de Cox y lo comparan con el modelo tradicional de regresión logística, obteniendo resultados similares, por lo cual llegan a la conclusión de que es posible considerar este tipo de modelos en la gestión crediticia. Luego validan los mismos resultados incluyendo una variable dinámica y obtienen mejores resultados en la regresión de Cox respecto a la logística inicial. En este trabajo se ajustará un modelo con variables estáticas, sin embargo, si se quisiera incluir en el mismo una variable macroeconómica dinámica, resulta relevante considerar este tipo de modelos por sobre las regresiones logísticas.

Por último, respecto a la estimación de LGD, Merz y Wuthrich (2007) aplican la metodología de Chain Ladder sobre una cartera de siniestros con el objetivo de obtener el valor a reservar en concepto de futuros pagos al asegurador. Esta metodología es una de la más utilizadas en la literatura actuarial para la estimación de reservas patrimoniales por su simplicidad y eficacia. Los autores consideran una base de estimación anual, a diferencia de la aplicación en este trabajo que se realizará de forma mensual, para proyectar los pagos futuros en concepto de siniestros. El monto a reservar lo obtienen calculando la diferencia entre los pagos totales estimados y los pagos incurridos. En términos de LGD, se buscará el ratio entre pagos totales estimados y monto de deuda en default, que se ampliará en la sección 4.3



3. MARCO NORMATIVO

En enero de este año entraron en vigor para la banca argentina las Normas Internacionales de Información Financiera⁴. Desde su inicial comunicación, el BCRA ha establecido una hoja de ruta para que las entidades vayan transitando de la mejor manera posible la convergencia. En esta línea, ha solicitado que se adelanten datos cualitativos a fines de 2018 y datos cuantitativos preliminares a inicios del 2019. Mientras tanto, continuaron aplicándose las especificaciones detalladas en el texto ordenado de Previsiones Mínimas por Riesgo de Incobrabilidad⁵, con última actualización al 26 de mayo del corriente. Dicha norma establece las pautas mínimas de provisionamiento por riesgo de incobrabilidad que deben aplicarse sobre las financiaciones comprendidas por las normas sobre clasificación de deudores, emitidas también por el BCRA.

Cabe destacar que, dado el contexto de pandemia COVID-19, el BCRA dispuso una flexibilización, de manera transitoria, en los parámetros con los que son clasificados los deudores que no será considerada en este trabajo por ser una medida provisoria⁶.

3.1. Lineamientos del BCRA

La normativa del BCRA establece ciertos niveles de clasificación de los deudores a partir de los cuales exige a las entidades la constitución de provisiones contables por incobrabilidad.

⁴Exigidas para entidades de grupo "A", para las entidades de grupo "B" se ha vuelto a prorrogar su implementación. Las tipo "A" son aquellas en la cuales el valor total de sus activos es mayor o igual al 1% del total de activos del sistema financiero.

⁵ Texto ordenado al 26/05/20 de "Previsiones Mínimas por Riesgo de Incobrabilidad" -Última comunicación incorporada: "A" 7024.

⁶ Con vigencia hasta el 30/09/20, deberán incrementar en 60 días los plazos de mora admitida para los niveles 1, 2 y 3, tanto para la cartera comercial como para la de consumo o vivienda y, oportunamente, se dará a conocer un cronograma para retomar a los valores preexistentes. Para mayor detalle ver COM "A" 6938.

Categoría	Detalle	Cobertura	
		Con garantías preferidas	Sin garantías preferidas
1	En situación normal	1%	1%
	(puntos 6.5.1. y 7.2.1. de las normas sobre "Clasificación de deudores")		
2	a) En observación y de riesgo bajo	3%	5%
	b) En negociación o con acuerdos de refinanciación (2.b. para cartera comercial)	6%	12%
	c) En tratamiento especial (2.c. para cartera comercial; 2.b. para cartera de consumo o vivienda)	8%	16%
3	Con problemas y de riesgo medio	12%	25%
4	Con alto riesgo de insolvencia y de riesgo alto	25%	50%
5	Irrecuperable	50%	100%

Tabla 1: Porcentajes de cobertura por situación del deudor

Más allá de los ponderadores detalladas en la Tabla 1, establece que las entidades pueden efectuar provisiones por importes superiores a los mínimos establecidos, si así lo juzgaran razonable.

En cuanto a la definición de la categoría, se define en base a los días de atraso del cliente (de la cartera de consumo o vivienda) con los siguientes rangos: 1: hasta 30 días de atraso, 2: entre 31 y 90 días, 3: entre 91 y 180 días, 4: entre 181 y 365 días y 5: más de 365 días.

Asimismo, establece dos conceptos de reclasificación obligatoria: el "arrastre interno", para aquellos clientes con más de un producto en la misma entidad indica considerar la peor situación individual, y el "arrastre externo", para aquellos clientes con más de un producto en el sistema financiero, exige el incremento de la clasificación en función a la situación externa, tomando en cuenta a la composición de deuda⁷.

Puede advertirse que dicho esquema no anticipa comportamientos si no que espera a que se efectivice el incumplimiento del cliente para incrementar la previsión contable, a diferencia del enfoque de deterioro de valor de la NIIF 9

⁷ Texto ordenado al 27/05/20 de "Clasificación de Deudores" -Última comunicación incorporada: "A" 7024-

donde -como se profundizará más adelante- ya no es necesario que ocurra un suceso relacionado con el crédito antes de que se reconozcan las pérdidas crediticias, y en su lugar exige contabilizar con el criterio de lo esperado.

3.2. Lineamientos de la NIIF 9

El marco de la NIIF 9 tiene su origen en abril de 2001 cuando el IASB adoptó la NIC 39 Instrumentos Financieros: Reconocimiento y Medición, que había sido originalmente emitida por el Comité de Normas Internacionales de Contabilidad en marzo de 1999, debido a que numerosos usuarios y otras partes interesadas manifestaron dificultad de comprensión, aplicación e interpretación. En tal sentido, fue creando capítulos que sustituyeron los requerimientos correspondientes de la NIC 39, hasta julio de 2014 en donde emitió la versión completa.

La NIIF 9 -Instrumentos Financieros- establece los requerimientos para el reconocimiento y medición de los activos financieros, pasivos financieros y algunos contratos de compra o venta de partidas no financieras. Las tres fases principales del proyecto del IASB fueron:

- a. Fase 1: Clasificación y medición de los activos financieros y pasivos financieros (noviembre 2009).
- b. Fase 2: Metodología de deterioro del valor (julio 2014).
- c. Fase 3: Contabilidad de coberturas (noviembre 2013).

La fase 2 incluyó dentro de la sección 5.5⁸ los requerimientos de deterioro de valor relacionados con la contabilidad de las pérdidas crediticias, cuyo contenido será foco de estudio en este trabajo y se ampliará a continuación.

Se introduce un nuevo enfoque de clasificación, basado en dos conceptos: las características de los flujos de efectivo contractuales de los activos y el modelo de negocio de la entidad.

⁸ International Accounting Standards Board (2014^o) – NIIF 9 Instrumentos Financieros.

Establece tres categorías de valoración: (i) costo amortizado, (ii) valor razonable con cambios en otro resultado integral (patrimonio) y (iii) valor razonable con cambios en pérdidas y ganancias.

En cuanto a la clasificación, dependerá del modelo de negocios, es decir, del modo en que la entidad gestiona sus instrumentos financieros y la existencia o no de flujos de efectivo contractuales de los activos financieros específicamente definidos:

- Si el objetivo del modelo de negocio es mantener un activo financiero con el fin de cobrar flujos de efectivo contractuales, según las condiciones del contrato, se reciben flujos de efectivo en fechas específicas que constituyen exclusivamente pagos del principal más intereses sobre dicho principal, el activo financiero se valorará a costo amortizado.
- Si el modelo de negocio tiene como objetivo tanto la obtención de flujos de efectivo contractuales como su venta, los activos financieros se valorarán a valor razonable con cambios en otro resultado integral.
- Fuera de estos escenarios, el resto de los activos se valorarán a valor razonable con cambios en pérdidas y ganancias.

La NIIF 9 propone un nuevo modelo de deterioro basado en pérdida esperada aplicable a los activos financieros valorados a costo amortizado y a los activos financieros de deuda a valor razonable con cambios en otro resultado integral.

A diferencia de las 5 clasificaciones del BCRA, el enfoque general se estructura a través de 3 fases (*stages*) en las que se puede encontrar el instrumento financiero desde su reconocimiento inicial, que se basan en el grado del riesgo de crédito y en la circunstancia en la que se haya producido un aumento significativo del mismo.

- a. Stage 1: Corresponde a aquellos instrumentos cuyo riesgo crediticio no aumentó desde el reconocimiento inicial y se requiere una estimación de las ECL para los próximos 12 meses.

- b. Stage 2: Corresponde a aquellos instrumentos sobre los cuales se ha incrementado significativamente el riesgo crediticio desde el reconocimiento inicial y se requiere constituir una previsión para las ECL de toda su vida remanente.⁹
- c. Stage 3: Corresponde a aquellos instrumentos con evidencia de deterioro, por lo que se estiman las ECL para toda su vida remanente. Hace referencia a las operaciones con un atraso mayor a 90 días.¹⁰

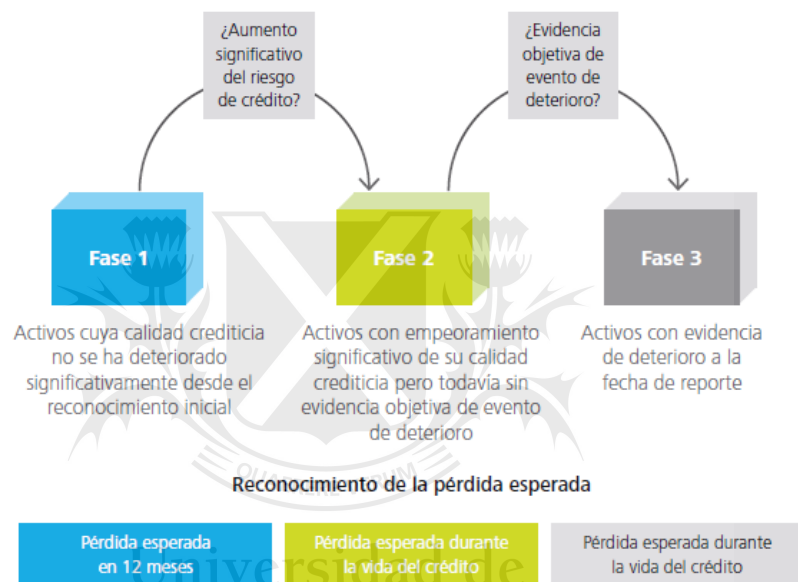


Figura 1: Las tres fases del modelo general de deterioro.

Fuente: Deloitte España

⁹ "(...) en cada fecha de presentación, una entidad medirá la corrección de valor por pérdidas de un instrumento financiero por un importe igual a las pérdidas crediticias esperadas durante el tiempo de vida del activo, si el riesgo crediticio de ese instrumento financiero se ha incrementado de forma significativa desde su reconocimiento inicial". Sección 5.5.3, Reconocimiento de las pérdidas crediticias esperadas. NIIF 9 Instrumentos Financieros

¹⁰ "(...) hay una presunción refutable de que un incumplimiento no ocurrirá después de que un activo financiero esté en mora 90 días, a menos que una entidad tenga información razonable y sustentable que un criterio de incumplimiento más aislado es más apropiado". Sección B5.5.36, Definición de incumplimiento. NIIF 9 Instrumentos Financieros

Cabe destacar que, si el activo se recupera de su estado de deterioro, la entidad puede volver a constituir provisiones con la metodología del *stage 1*.

En cuanto al “aumento significativo” del riesgo, la norma no da una definición puntual a aplicar, solo menciona qué ocurre si se ha producido un aumento significativo en el riesgo de crédito desde su reconocimiento inicial, de tal forma que va a depender de las políticas y prácticas de gestión de la entidad. Sí incluye una presunción refutable de que el riesgo de crédito aumenta significativamente cuando los pagos contractuales están vencidos en más de 30 días. Dicho criterio será el único a considerarse en este trabajo para la clasificación en *stage 2*.

Adicionalmente, si la información con vistas al futuro razonable y sustentable está disponible sin costos o esfuerzos desproporcionados, las entidades no deben confiar únicamente en información sobre morosidad para determinar si se ha incrementado o no el riesgo crediticio de forma significativa desde el reconocimiento inicial. Podrían considerarse, por ejemplo, modelos macroeconómicos para complementar dicha estimación. Estos modelos, conocidos como “*Forward Looking*” permiten ajustar la estimación de la pérdida esperada a las condiciones futuras. Queda fuera de alcance de este trabajo la estimación de un modelo con dichas características, pero resulta fundamental realizar un ajuste en los parámetros con dicho modelo, principalmente en este contexto. En resumen, establece que la estimación de pérdidas esperadas debe basarse en la experiencia histórica de la incobrabilidad y las condiciones macroeconómicas actuales y futuras.

4. METODOLOGÍA

En función a lo establecido en la NIIF 9, se propone una metodología de provisiones estadísticas que permita calcular el importe total a computar mensualmente en los balances de las entidades financieras y que considere un enfoque prospectivo: “Modelo *forward looking*”.

El cálculo de ECL se basa en los parámetros de riesgo establecidos por el Comité de Basilea¹¹ para obtener el capital mínimo regulatorio por riesgo de crédito (Pilar I), solo que su estimación estará alineada a los lineamientos de la NIIF 9. Dichos parámetros son: PD – LGD – EAD.

Cabe destacar que las estimaciones realizadas estarán basadas en la información interna de una entidad financiera, tomando en consideración la profundidad histórica y la materialidad de la cartera de análisis.

4.1. Probabilidad de Default (PD)

La probabilidad de incumplimiento o *default* es un elemento importante en la evaluación del riesgo de crédito y su significado más utilizado es la omisión del pago de una deuda vencida en una determinada ventana temporal. Es la medida de qué tan probable un acreditado deje de cumplir con sus obligaciones contractuales y comprende analizar la capacidad de repago. El atraso de 90 días ha sido el parámetro objetivo universalmente aceptado como indicador de cartera irregular.

Las técnicas de *credit scoring* se emplean para evaluar el riesgo de crédito a nivel individual de un deudor o solicitante de crédito. Se definen como los “*métodos estadísticos utilizados para clasificar a los solicitantes de crédito, o incluso a quienes ya son clientes de la entidad evaluadora, entre las clases de riesgo ‘bueno’ y ‘malo’*”, Hand y Henley (1997).

¹¹ International convergence of capital measurement and capital standards. A revised framework, Basel Committee on Banking Supervision, junio 2004

Con la información contenida en las solicitudes de crédito y en otras fuentes, el *scoring* permite tomar la decisión de otorgar o no un crédito (es el caso del *application scoring*) o realizar el seguimiento del deudor (*behavioral scoring*). Si bien estas técnicas se aplican a clientes de todo tamaño, su uso está más difundido para la cartera minorista.

Las técnicas de *credit scoring* empleadas con este propósito expresan el resultado de su evaluación de distintas maneras: un puntaje, la asignación a un segmento o grupo determinado según el riesgo, un *rating* o una PD (como es el caso de la regresión logística). Aunque no siempre da como resultado directo una PD, obtenerla de manera indirecta es una tarea relativamente sencilla, por ejemplo, aproximándola con la tasa de *default* histórica observada en cada rango del sistema de *ratings*, puntaje o segmento al cual el *scoring* asigne al deudor¹².

En línea a lo requerido en NIIF 9, para la estimación de la probabilidad de *default* del *stage 1*, se estimarán probabilidades a 12 meses y se realizarán dos modelos de *credit scoring*: uno para clientes con historial crediticio dentro de la entidad (modelo de comportamiento) y otro para clientes nuevos (modelo de admisión), utilizando la metodología de regresión logística. Para la estimación de la probabilidad de *default* del *stage 2*, se estimarán probabilidades para toda la vida remanente (*PD lifetime*) considerando la metodología de regresión de Cox, usualmente utilizada en modelos de supervivencia orientados a seguros de vida. Ambas metodologías serán detalladas más adelante.

En *stage 3* la probabilidad de *default* ya es conocida y toma el valor 1, por lo cual no requiere de modelado.

¹² Estudio de los sistemas de información requeridos para la medición y administración del riesgo crediticio. Gerencia de Investigación y Planificación Normativa y Gerencia de Régimen Informativo1 Banco Central de la República Argentina – octubre 2006

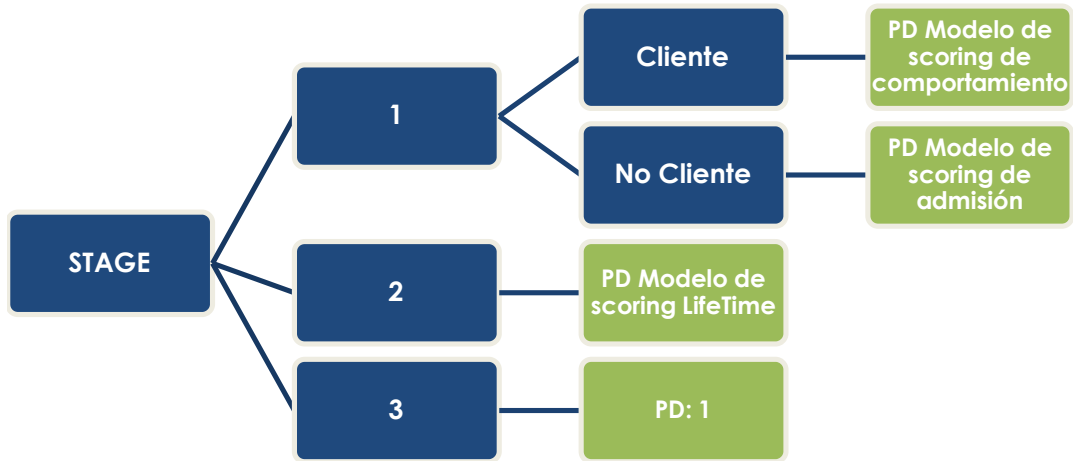


Figura 2: Selección de Modelo de PD

A continuación, se amplían cada una de las metodologías seleccionadas.

4.1.1. Regresión Logística

La regresión logística es un modelo supervisado en el cual existe una variable dependiente o variable objetivo y un conjunto de variables independientes, que mediante la asignación de pesos a las variables independientes intenta predecir a la variable dependiente.

Se denomina Y a la variable dependiente que refleja la ocurrencia del suceso estudiado. En este caso, se la define como una variable dicotómica en la cual toma los siguientes valores:

$$\begin{cases} Y = 1 & \text{si ocurre el evento} \\ Y = 0 & \text{si no ocurre el evento} \end{cases}$$

Como el objetivo es modelar el parámetro PD, se considera como evento a que el cliente incumpla en sus obligaciones y alcance un atraso mayor a 90 días en una ventana temporal de 12 meses.

Se evalúa la influencia de un conjunto de variables independientes sobre la variable dependiente Y. Estas variables se denotan x_1, x_2, \dots, x_k y la influencia se puede modelar por la siguiente probabilidad:

$$P(Y = 1 | X_1, X_2, \dots, X_k)$$

Cada una de estas variables es ponderada por un coeficiente, que determina la influencia sobre la variable Y. Dichos coeficientes se denotan $\beta_1, \beta_2, \dots, \beta_k$ y un término independiente β_0 que son estimados mediante máxima verosimilitud. Con estos coeficientes, la función logística calcula la probabilidad que el suceso estudiado ocurra dados ciertos valores de las variables independientes:

$$P(Y = 1 | X_1, X_2, \dots, X_k) = \frac{1}{1 + e^{-\beta_0 - \beta_1 x_1 - \dots - \beta_k x_k}}$$

Para seleccionar las posibles variables a considerar en el modelo se utilizan los análisis bivariados que permiten detectar relaciones entre una variable explicativa y una variable explicada, como en este caso sería la marca de default. Son de gran utilidad para realizar un filtro inicial y además permiten entender si el comportamiento esperado respecto al default tiene o no lógica económica. Una vez seleccionadas las variables con poder predictivo, se valida que no exista correlación entre las mismas y, en caso de ser así, se descartan las menos significativas.

Dado que la cartera a valorar presenta clientes con historial crediticio dentro de la entidad considerada y otros nuevos sin historial, se define realizar dos modelos para optimizar la predicción: una regresión logística para clientes sin comportamiento y otra regresión logística para clientes con comportamiento.

Se define como cliente con comportamiento si presenta una permanencia en la entidad de al menos 4 meses.

Por otro lado, dado que las probabilidades obtenidas en ambos modelos son a 12 meses, para las operaciones cuyos plazos remanentes desde el momento de valuación sean menores a 12, se establece un supuesto de proporcionalización a fin de no sobreestimar la previsión:

$$PD_{prop} = \text{Max} \left[\frac{PD}{12} * \text{Vida remanente}; \frac{PD}{12} * 3 \right]$$

4.1.2. Regresión de Cox

Dentro del campo de estudio del riesgo crediticio, no solo es importante contar con modelos que permitan estimar la frecuencia del evento default si no también conocer el tiempo de permanencia de los individuos en la cartera antes de incurrir en dicho estado. En tal sentido, es posible aplicar modelos de supervivencia para resolver esta problemática.

El análisis de supervivencia es una técnica inferencial que tiene como objetivo esencial modelizar el tiempo que se tarda en que ocurra un determinado suceso. Estas técnicas son frecuentemente utilizadas en el campo actuarial y medicinal, sin embargo, es posible aplicarlas a otras áreas de conocimiento. Para dicho análisis es necesario contar con una muestra de seguimiento de una serie de individuos desde el inicio del estudio hasta su final, como por ejemplo podría aplicarse desde el momento de la originación de un préstamo hasta que dicho cliente incumple o bien hasta que paga completamente su obligación.

Es decir, dado un individuo en estudio, es posible que el mismo alcance el estado que se pretende analizar o bien que nunca lo alcance. En esta línea surge el concepto de “datos censurados” para aquellos que nunca alcanzan dicho estado.




Figura 3: Situaciones de supervivencia

La figura 3 representa distintas situaciones que ocurren en el análisis de supervivencia, donde E representa la ocurrencia del evento, que podría ser el impago. Se observa que los individuos no ingresan al estudio al mismo tiempo y cuando el estudio termina algunos no tuvieron el evento, estos son conocidos como “datos censurados”, es decir el individuo no pudo ser observado hasta su potencial fecha de impago.

Estos modelos se basan en una función de supervivencia que permite calcular la probabilidad de que cierto individuo permanezca hasta un momento determinado (t), o bien que el tiempo transcurrido hasta el evento (variable T) sea superior o igual que t :

$$S(t) = P(T \geq t) = 1 - F(t)$$

Donde:

$S(t)$: Probabilidad de supervivencia hasta el momento t

$F(t)$: Función de distribución acumulada de alcanzar el evento antes del momento t

Adicionalmente, contemplan una tasa instantánea de salida, conocida como *Hazard Rate*, que se define como la probabilidad de alcanzar el evento en el

momento $t + \Delta t$ dado que se sobrevivió hasta el momento t y siendo Δt un valor muy chico:

$$h(t) = \lim_{\Delta t \rightarrow 0} \frac{\Pr(t \leq T < t + \Delta t | T \geq t)}{\Delta t}$$

La misma podría interpretarse como la fuerza con la cual un individuo en un determinado momento es empujado hacia el *default*.

Si se reemplaza la función de supervivencia en esta última fórmula, es posible obtener la siguiente relación:

$$h(t) = -\frac{1}{S(t)} \frac{dS(t)}{dt}$$

Despejando es posible ver la supervivencia en función a la *Hazard Rate*:

$$S(t) = e^{-\int_0^t h(u) du}$$

Entonces, es posible utilizar el Modelo de Riesgos Proporcionales de Cox (1972) cuyo concepto fundamental a modelar va a ser entonces el denominado *Hazard Rate* o tasa instantánea de salida de los individuos.

Para aplicar el análisis de supervivencia al riesgo de crédito es necesario contar con información particular de cada individuo, por ejemplo: edad, antigüedad del cliente, situación en el sistema financiero, ingresos, endeudamiento, entre otros, y así armar una matriz de covariables "X".

Para determinar la relación existente entre dichas covariables y el tiempo hasta el default, Cox (1972) propone el siguiente modelo:

$$h(t; X_i(t)) = h(t)e^{\beta' X_i(t)}$$

Donde:

t : Momento en el tiempo

β : Vector de parámetros desconocidos

h_0 : Función que describe la tasa instantánea de salida base, sin importar las características del individuo

X : Matriz de características del cliente

Si se reemplaza esta última fórmula sobre la función de supervivencia en función a la *Hazard Rate*, se obtiene:

$$S_i(t) = S_0(t)e^{\beta'X_i(t)}$$

Es decir, la función de supervivencia puede descomponerse entre la "Supervivencia Base" y el "Riesgo Relativo" individual. La supervivencia base va a ser la misma para todos los individuos para un momento de tiempo determinado y el riesgo relativo será propio de cada uno, en función a las variables consideradas en el modelo.

Se lo denomina de "Riesgos Proporcionales" debido a que conlleva el supuesto de que la salida de un individuo con características X es proporcional a la tasa de salida base y el cociente entre el riesgo para dos individuos con el mismo vector de covariables es constante en el tiempo, es decir:

$$\frac{h(t; X_i(t))}{h(t; X_j(t))} = \frac{h_0(t)e^{\beta'X_i(t)}}{h_0(t)e^{\beta'X_j(t)}} = \frac{e^{\beta'X_i(t)}}{e^{\beta'X_j(t)}}$$

Suponiendo que el evento ha ocurrido en el tiempo t^* , entonces la verosimilitud de que el evento le ocurra al individuo i -ésimo y no a otro individuo es:

$$L_i(\beta) = \frac{h_0(t^*)r_i(t^*)}{\sum_j Y_j(t^*)h(t^*)r_j(t^*)} = \frac{r_i(t^*)}{\sum_j Y_j(t^*)r_j(t^*)}$$

El producto de los términos de la expresión anterior $L(\beta) = \prod L_i(\beta)$ se denomina verosimilitud parcial permitiendo la estimación de los β sin necesidad de estimar el riesgo base $h_0(t)$.

Con el objetivo de estimar la PD de *stage* dos para toda la vida remanente del crédito, se utilizará dicha metodología tomando como base una cartera de préstamos de distintos plazos otorgados y distintos plazos remanentes y se observará el comportamiento hasta el final de la vida del producto. Si el cliente alcanza un atraso superior a 90 días se lo marca como "ocurrencia del evento" y se deja de observar al mismo registrando el momento de ocurrencia (delay: momento de default). En caso de que nunca ocurra el *default* (dato censurado), se observa el cliente hasta el momento que cancela totalmente su obligación, registrando el mismo como momento final del estudio.

4.1.3. Validación de Regresiones

Para elegir la regresión con mayor poder predictivo, tanto en la metodología Cox como en la Logística, además de validar que los coeficientes sean significativos, se consideran los siguientes indicadores comúnmente utilizados en *credit scoring*:

- Kolmogorov-Smirnov

La curva e índice de Kolmogorov-Smirnov (KS) es una forma de representación de las distribuciones de frecuencias acumuladas de buenos y malos contra el score y, la máxima diferencia entre ambas.

Según las mejores prácticas, para valores de índices KS menores a 20 el modelo debe ser cuestionado y para valores por encima de 70, probablemente el modelo es demasiado bueno para ser verdad. De todos modos, también debe tenerse en cuenta la dificultad del problema a modelar, con cuánta información se cuenta y la calidad de la misma, finalmente definir cuál es un KS adecuado pasa a ser una elección más objetiva.

- Curva ROC y AUC

La curva ROC (*Receiver Operating Characteristic*) es una representación de la exactitud de la clasificación otorgada y una medida de comparación entre distintos modelos. Para representar la curva ROC, se definen dos conceptos fijado un punto de corte determinado:

- Sensibilidad: Es la probabilidad de que el modelo clasifique correctamente a una operación no morosa.
- Especificidad: Es la probabilidad de que el modelo clasifique correctamente a una operación morosa.

En cuanto al punto de corte, por ejemplo, si se establece al valor 0.5, se consideran operaciones morosas todas aquellas cuya puntuación otorgada por el modelo sea superior a 0.5 y operaciones no morosas a aquellas cuya puntuación sea inferior a 0.5. Por lo tanto, la probabilidad de que el modelo califique correctamente a las operaciones no morosas, fijado ese punto de corte, es el número de operaciones no morosas cuya puntuación es inferior a 0.5 entre el total de operaciones no morosas.

Cada punto de la curva ROC, compara distintos escenarios de aceptación o denegación de operaciones con el desempeño conocido de las mismas (morosa o no morosa). Cabe señalar que el área bajo la curva ROC (AUC), indica el poder predictivo del modelo. El modelo perfecto corresponde con un área igual a 1 y el peor de los modelos un área igual a 0.5.

La curva ROC se obtiene representando, para cada uno de los posibles puntos de corte, es decir, los pares de puntos (1 – Especificidad, Sensibilidad). Por ende, para cada valor del punto de corte (números reales entre cero y uno), se representa en el eje de abscisas el valor de “1 – Especificidad” (probabilidad de que el modelo no califique correctamente a una operación morosa) y en el eje de ordenadas el valor de “Sensibilidad” (probabilidad de que el modelo califique correctamente a una operación no morosa).

4.2. Exposición al Default (EAD)

Este parámetro corresponde al monto legalmente adeudado a la entidad financiera al momento del default. La EAD dependerá de distintos factores, como por ejemplo el tipo de producto, la calidad del cliente, la utilización media y el tipo de contrato. Para algunas financiaciones casi no existe este riesgo. Los créditos amortizables se repagan siguiendo un esquema contractual, de manera tal que los montos futuros son conocidos de antemano, excepto en los casos de prepago. En general se toma, para las partidas dentro del balance, una estimación de EAD que no puede ser inferior al valor del préstamo otorgado. Es decir, se ignoran las cancelaciones aunque éstas estén pautadas contractualmente.

Para este trabajo se considera como supuesto conservador que el monto adeudado al default será equivalente al monto adeudado al momento de calcular la previsión y, para alinearse a lo requerido en la NIIF 9, se establece una actualización financiera desde el posible momento del default al momento de valuación.

En esta línea, con el objetivo de establecer una ventana temporal de actualización, ya que al momento se desconoce cuándo el cliente incumplirá su obligación, se define un supuesto de uniformidad en donde los defaults ocurren a mitad de la vida remanente. Es decir, si se valúa una operación en *stage 1*, se utilizará una ventana de 6 meses, si se valúa una operación en *stage 2*, se utilizará el plazo remanente sobre dos y si se valúa una operación en *stage 3*, que ya se encuentra en default, no habrá actualización financiera. En este sentido, la EAD se obtendrá a nivel operación con la siguiente fórmula:

$$EAD_t = \text{Saldo de Deuda}_t * (1 + TEM)^{-m}$$

Donde:

t: mes de valuación de la previsión

$$m = \begin{cases} 6, & \text{stage 1} \\ \text{plazo}_{rem}/2, & \text{stage 2} \\ 0, & \text{stage 3} \end{cases}$$

TEM: tasa efectiva mensual del préstamo

4.3. Pérdida dado el Default (LGD)

La LGD es la proporción de la EAD que se perdería si se produjera el default. Depende de las garantías asociadas, la capacidad de recupero a partir de los otros activos del deudor, gastos asociados al proceso de recupero y ejecución de las garantías y el costo de oportunidad por los intereses perdidos.

En este trabajo, la LGD será un parámetro único para todos los *stages* y no se consideran garantías ni gastos. Para su estimación, se utilizará información histórica de la entidad financiera de análisis y se aplicará la metodología de Chain Ladder a fin de ajustar el parámetro.

En la práctica actuarial, se utilizan ciertas técnicas de estimación de siniestralidad para calcular las reservas que deben constituirse con el objetivo de garantizar la solvencia en las compañías aseguradoras. Particularmente, dentro del ramo de los seguros patrimoniales, frecuentemente se utiliza esta metodología para estimar cuánto debe reservar la compañía para poder hacer frente a futuros pagos de siniestros basándose en información empírica.

De esta forma se podría considerar que el default de un cliente es un siniestro y el monto de deuda neto de los recuperos que se consigan post evento es el monto total del mismo, de manera tal que se podría utilizar dicha metodología para la estimación del parámetro LGD.

La metodología de Chain Ladder consiste en recopilar información del pasado para predecir el futuro. En este caso, se quiere predecir cuánto será el monto de deuda no recuperada una vez que el cliente entra en default, por eso será necesario observar el comportamiento de pagos posteriores en una determinada ventana temporal.

Dicha recopilación de pagos debe alocarse bajo la estructura de una matriz. A medida que los siniestros son más recientes, se reduce la información, por lo que termina adoptando la forma de un triángulo. Se busca completar la matriz en función a cómo van evolucionando los mismos (Merz & Wüthrich, 2007).

Se denota como $c_{i,j}$ a los pagos realizados por los clientes correspondientes al siniestro del año $i \in \{0, 1, \dots, I\}$ y pagado en el año $j \in \{0, 1, \dots, J\}$.

Se denota como $C_{i,j}$ a los pagos acumulados de izquierda a derecha, correspondientes al siniestro del año $i \in \{0, 1, \dots, I\}$ hasta el año de desarrollo $j \in \{0, 1, \dots, J\}$.

Asumimos que nos encontramos en el momento $t = I$ y se cuenta con las siguientes observaciones:

$$\mathcal{D}_I = \{C_{i,j}; i + j \leq I\}$$

El objetivo es estimar para cada año de accidente i :

$$E[C_{i,J} / \mathcal{D}_I]$$




Figura 4: Matriz de pagos

Sobre la base de la representación, se asume que la evolución de los pagos cuenta implícitamente con factores de desarrollo que fluctúan en el tiempo y que a su vez tienen cierta tendencia estacional.

Es decir,

$$C_{i,t-1} = C_{i,0} * F_{i,1} * F_{i,2} * \dots * F_{i,t-1}$$

Con

$$F_{i,j} = \frac{C_{i,j}}{C_{i,j-1}}$$

Se asume que los factores $F_{i,j}$ fluctúan alrededor de un parámetro desconocido f_j . Por lo tanto, utilizando el parámetro estimado \hat{f}_j los montos no conocidos $C_{i,j}$, $t + j > I$ son calculados recursivamente

$$\hat{C}_{i,j} = \hat{C}_{i,j-1} * \hat{f}_j$$

Comenzando con el último pago conocido,

$$\hat{C}_{i,I-i} = C_{i,I-i}$$

Cabe señalar que hay diversas técnicas empleadas para estimar el parámetro \hat{f}_j , en este trabajo se utiliza como criterio simplificador el promedio observado en el último año.

En el ámbito del seguro se buscaría obtener el monto a reservar utilizando la diferencia entre $\hat{C}_{i,j}$ y $C_{i,I-i}$, en búsqueda de la estimación de LGD se obtiene para cada año de ocurrencia la suma de pagos acumulados (también conocidos como *ultimates*) y luego el ratio contra la deuda en mora.

El parámetro LGD a utilizar se obtiene con el promedio de cada uno de ellos, para la base total analizada:

$$LGD_i = 1 - \frac{\hat{C}_{i,J}}{Deuda\ Mora_i}$$

$$LGD = \sum_{i=0}^I \frac{LGD_i}{I}$$

Para este ejercicio, a diferencia de la bibliografía tomada como base, se considera una frecuencia de observación mensual.

Adicionalmente, se realiza la actualización financiera sobre los flujos de pagos para contar con información homogénea alineado a lo establecido en la normativa NIIF 9. Al igual que en la EAD, se considera como tasa de interés de actualización la tasa efectiva de cada préstamo modelado.

4.4. Pérdida Crediticia Esperada (ECL)

Como toda función de pérdida contempla un parámetro de frecuencia (PD) y otro de severidad (LGD y EAD). La pérdida esperada representa la esperanza o valor promedio de la distribución de probabilidad de las pérdidas futuras por incumplimientos. La misma es calculada en un momento t , para cada operación i , resultando la pérdida esperada total como la suma de todas las pérdidas esperadas individuales para un total de n operaciones. Considerando los parámetros detallados anteriormente:

$$PE_{t,i} = PD_{t,i} * LGD_t * EAD_{t,i}$$

$$Previsión NIIF_t = \sum_{i:1}^n PE_{t,i}$$

5. VARIABLES Y DATOS UTILIZADOS

5.1. Modelo de *scoring* de admisión

Para el modelo de *scoring* de admisión se utiliza una base de 34.549 préstamos dados de alta sobre clientes nuevos sin historial crediticio en la entidad y se sigue su comportamiento de pago desde la originación hasta y durante 12 meses posteriores. En dicha ventana temporal se observa si el cliente ha alcanzado o no un atraso superior a 90 días, generando sobre toda la base, en cada *delay*, la variable objetivo 1/0.

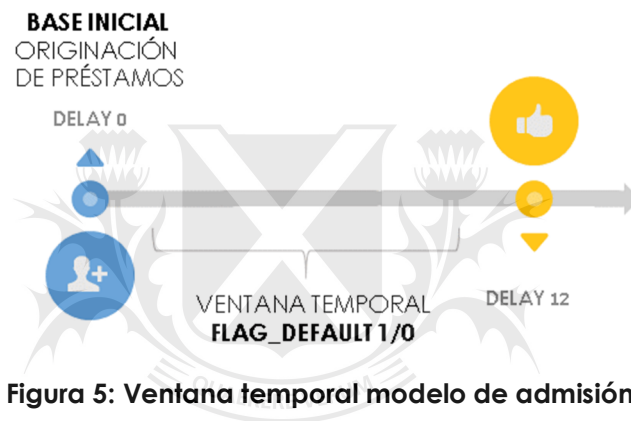


Figura 5: Ventana temporal modelo de admisión

Para el modelado se segmenta la población en dos muestras: muestra de entrenamiento y muestra de validación, en una proporción del 70% y 30% respectivamente, de manera aleatoria. Es necesario asegurarse que cada una de ellas contenga una proporción similar de buenos y malos pagadores:




Figura 6: Partición de la base modelo de admisión

Luego de los filtros de los bivariados y las correlaciones, se seleccionan las siguientes variables para modelar:

- Sexo: Variable categórica F/M
- Flag_Trabaja: Marca de si el cliente tiene un empleo formal o cobra un ingreso previsional.
- Flag_Irregular_24M: Marca de si el cliente alcanzó una situación irregular en los últimos 24 meses.
- Score Bureau: Variable categórica de rangos de score provistos por un Bureau de crédito.
- Consultas en financieras 6M: Cantidad de consultas realizadas en financieras durante los últimos 6 meses, se agrupa en categorías.
- Plazo: plazo de la operación agrupado en categorías
- Consultas en bancos 3M: Cantidad de consultas realizadas en bancos durante los últimos 3 meses, se agrupa en categorías
- Edad: Edad del cliente agrupada en categorías
- Objetivo: Valor 1 si el cliente alcanza 90 días en la ventana temporal, de lo contrario toma valor 0

5.2. Modelo de *scoring* de comportamiento

Para el modelo de *scoring* de comportamiento se utiliza el stock total de préstamos a un mes determinado, seleccionando aquellos que tengan una antigüedad de al menos 4 meses y se encuentren al día. Se sigue su comportamiento de pago desde esa fecha hasta y durante 12 meses posteriores. La base utilizada contiene un total de 37.981 préstamos.

Al igual que en modelo anterior, se marca en cada *delay* aquellos que alcanzaron un atraso superior a 90 días.



Figura 7: Ventana temporal modelo de comportamiento

Se procede a realizar la partición de la base entre entrenamiento y validación:

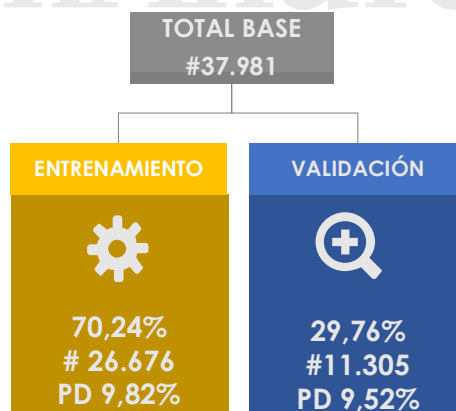


Figura 8: Partición de la base modelo de comportamiento

Luego de los filtros de los bivariados y las correlaciones, se seleccionan las siguientes variables para modelar:

- Plazo: plazo de la operación
- Sexo: Variable categórica F/M
- Amortización: Ratio entre la cantidad de meses transcurridos desde la fecha de alta hasta el mes observado sobre el total de cuotas de la operación
- Cuotas impagas máx.: Cantidad máximo de cuotas adeudadas desde la fecha de alta
- Antigüedad Sistema Financiero: Cantidad de meses desde que el cliente opera en el sistema financiero.
- Peor SITBCRA últimos 24M: Peor situación alcanzada durante los últimos 24 meses.
- Consultas en bancos 3M: Cantidad de consultas realizadas en bancos y/o financieras durante los últimos 3 meses.
- RCT Mercado: Ratio entre el endeudamiento total del cliente y su ingreso
- Tendencia deuda 6M: Ratio entre la deuda actual y la deuda que tenía hace 6 meses.
- RCI Mercado: Ratio entre el compromiso total del cliente y su ingreso
- Cantidad de SITBCRA Neto 24M: Diferencia entre la cantidad de situaciones a la fecha menos la cantidad de situaciones irregulares hace 24 meses.
- Score Bureau: Variable categórica de rangos de score provistos por un Bureau de crédito.
- Objetivo: Valor 1 si el cliente alcanza 90 días en la ventana temporal, de lo contrario toma valor 0

5.3. Modelo de *scoring lifetime*

Para el modelo de *scoring lifetime* que es ajustado con regresión de Cox se utiliza el stock total de préstamos a un mes determinado, seleccionando aquellos que se encuentren con atraso menor a 90 días. Se sigue su comportamiento de pago desde esa fecha hasta y durante 4 años posteriores. La base utilizada contiene un total de 44.901 préstamos con diferentes plazos y amortizaciones pendientes.

Se observa cada préstamo a lo largo de la ventana definida hasta llegar al *default*, en ese momento se genera la variable objetivo (marcando con un 1) pero adicionalmente se guarda el *delay* en que se ha producido ese *default*. En caso de que el préstamo nunca haya caído en *default*, (además de marcarlo con 0 para la variable objetivo) se guarda el *delay* máximo observado. Esta variable *delay* será el tiempo de censura, desarrollado en 4.1.2.



Figura 9: Ventana temporal modelo *lifetime*

Al igual que en las regresiones logísticas, se procede a realizar la partición de forma aleatoria de la base entre entrenamiento y validación:




Figura 10: Partición de la base modelo *lifetime*

Luego de los filtros de los bivariados y las correlaciones, se seleccionan las siguientes variables para modelar:

- Plazo: plazo de la operación
- Sexo: Variable categórica F/M
- Amortización: Ratio entre la cantidad de meses transcurridos desde la fecha de alta hasta el mes observado sobre el total de cuotas de la operación
- Cuotas impagas máx: Cantidad máximo de cuotas adeudadas desde la fecha de alta
- Antigüedad Sistema Financiero: Cantidad de meses desde que el cliente opera en el sistema financiero.
- Score Bureau: Variable categórica de rangos de score provistos por un Bureau de crédito.
- Consultas en bancos 3M: Cantidad de consultas realizadas en bancos y/o financieras durante los últimos 3 meses.
- RCT Mercado: Ratio entre el endeudamiento total del cliente y su ingreso
- Tendencia deuda 6M: Ratio entre la deuda actual y la deuda que tenía hace 6 meses.
- Tendencia deuda 12M: Ratio entre la deuda actual y la deuda que tenía hace 12 meses.

- Cantidad de SITBCRA Neto 24M: Diferencia entre la cantidad de situaciones a la fecha menos la cantidad de situaciones irregulares hace 24 meses.

5.4. Cálculo de la LGD

Para el cálculo de LGD se utiliza una base de 21 meses correspondientes a clientes en mora con un atraso de entre (90;120] días. A los mismos se los observa hacia adelante durante una ventana temporal de 9 meses en la que se van recopilando los pagos asociados.

5.5. Cálculo de provisiones

Para el cálculo de provisiones con ambas metodologías se utiliza una base de datos correspondiente a préstamos personales de cartera de consumo o vivienda de una entidad financiera argentina, considerando el stock completo a un mes determinado, que llamaremos “mes 1” a fin de preservar confidencialidad con los resultados obtenidos. Dicha base contiene un total de 19142 operaciones por un importe de deuda total de 393 millones.

6. RESULTADOS E INTERPRETACIÓN

6.1. Modelo de scoring de admisión

Se presentan a continuación los ponderadores obtenidos para cada variable del modelo de scoring de admisión y su nivel de significatividad:

Variable Modelo Admisión	B	Sig.	Exp(B)
Sexo(1)	0.312	0	1.366
Flag_Trabaja(1)	-0.289	0	0.749
Flag_Irregular_24M(1)	0.445	0	1.56
Score_Bureau_Cat		0	
Score_Bureau_Cat(1)	-0.444	0	0.641
Score_Bureau_Cat(2)	-0.69	0	0.501
Score_Bureau_Cat(3)	-1.061	0	0.346
Consultas_Financieras_6M_Cat		0	
Consultas_Financieras_6M_Cat(1)	0.39	0	1.478
Consultas_Financieras_6M_Cat(2)	0.531	0	1.701
Plazo_Cat(1)	0.56	0	1.751
Consultas_Bancos_3M		0	
Consultas_Bancos_3M(1)	-0.127	0.01	1.135
Consultas_Bancos_3M(2)	0.567	0	1.763
Cant_Sit1_24m_Cat		0	
Cant_Sit1_24m_Cat(1)	-0.557	0	0.573
Cant_Sit1_24m_Cat(2)	-0.911	0	0.402
Edad_Cat(1)	-0.476	0	0.621
Constante	-1.746	0	0.174

Tabla 2: Parámetros regresión logística admisión

Se observa que todas las variables del modelo son significativas (Sig. <0.05). En el anexo 9.1 se podrán consultar algunos ejemplos de bivariados.

Adicionalmente, observando el valor de los coeficientes beta es posible comprender cómo influyen en la ocurrencia del evento estudiado, es decir, en el *default*. Cuando los coeficientes son positivos, incrementos en la variable independiente, incrementan la probabilidad de pertenecer al grupo de interés.

Por ejemplo, considerando el Flag_Trabaja cuyo coeficiente es (-0.289), significa que cuando un cliente trabaja y el flag toma valor 1, la probabilidad de *default* disminuye respecto a otro cliente que no trabaja. Además, considerando el Exp(-0.289) – Odd Ratio – es posible observar cuánto cambia el riesgo relativo en un

cliente que pasa de no trabajar a si trabajar, manteniendo el resto de las variables constantes: la probabilidad de default disminuye un 25%:

Sexo	M	M	
Flag_Trabaja	0	1	
Flag_Irregular_24M	0	0	
Score_Bureau	250	250	
Consultas_Financieras_6M_Cat	1	1	
Plazo_Cat	24	24	
Consultas_Bancos_3M	1	1	
Cant_Sit1_24m_Cat	1	1	
Edad	40	40	
Pr Default	0.41	0.34	
Score	588	656	
P / 1-P	0.700	0.524	-25%

Tabla 3: Ejemplo cambio en riesgo relativo

Con el objetivo de validar el ajuste del modelo, se calculan las tablas de performance tanto para la base de entrenamiento como para la base de validación. Observar que las columnas de "%Bads" que corresponden al ratio de malos/total presentan un orden escalonado creciente a medida que el rango de score disminuye. Además, se observa un bajo desvío entre la PD empírica y la PD teórica obtenida desde el puntaje del score.

En cuanto al índice KS, se obtiene un valor de 25 puntos lo cual es aceptable para un modelado de clientes sin historial crediticio en la entidad.

Rango Score	Score Mín.	Score Máx.	#Total	%Portfolio +	%Portfolio -	%GoodAc +	%GoodAc -	%BadAc +	%BadAc -	%Bads	%Bads +	PD Teórica	Odds	KS
10	959	988	2492	10	100	11	100	3	100	2.77	3	3.28	35	8
9	946	958	2503	21	90	22	89	7	97	5.07	4	4.93	18	15
8	932	945	2418	31	79	33	78	13	93	6.20	5	6.21	15	20
7	919	931	2337	40	69	43	67	19	87	7.40	5	7.49	12	23
6	904	918	2663	51	60	54	57	28	81	9.16	6	8.91	9	25
5	888	903	2138	60	49	63	46	37	72	10.99	7	10.45	8	25
4	870	887	2370	70	40	73	37	47	63	11.52	8	12.15	7	25
3	841	869	2478	80	30	83	27	61	53	14.69	8	14.50	5	21
2	798	840	2356	90	20	92	17	77	39	18.08	9	17.78	4	14
1	406	797	2396	100	10	100	8	100	23	25.83	11	26.50	2	0

24151

Tabla 4: Tabla de Performance de Entrenamiento

Se obtiene un índice GINI de 37.19 y un AUC de 68.6 para la base de validación.

Rango Score	Score Min.	Score Máx.	#Total	%Porfolio +	%Porfolio -	%GoodAc +	%GoodAc -	%BadAc +	%BadAc -	%Bads	%Bads +	PD Teórica	Odds	KS
10	958	988	1078	10	100	11	100	2	100	1.95	2	3.31	50	9
9	946	957	1008	20	90	22	89	6	98	4.37	3	4.97	21	16
8	932	945	1115	31	80	33	78	12	94	6.73	4	6.21	13	20
7	919	931	1001	40	69	43	67	20	88	8.99	5	7.51	10	23
6	905	918	1026	50	60	53	57	27	80	8.28	6	8.77	11	25
5	889	904	1067	61	50	63	47	37	73	10.31	7	10.31	8	26
4	871	888	984	70	39	73	37	48	63	12.70	8	12.08	6	25
3	841	870	1044	80	30	82	27	61	52	15.04	8	14.48	5	21
2	797	840	1040	90	20	92	18	77	39	17.40	9	17.85	4	14
1	443	796	1035	100	10	100	8	100	23	25.60	11	26.70	2	0

10398

Tabla 5: Tabla de Performance de Validación

En el anexo 9.1 se puede observar el peso de cada variable para entender cuáles son más o menos importantes en la predicción, la tabla de correlaciones y la curva de ROC.

6.2. Modelo de scoring de comportamiento

Se presentan a continuación los ponderadores obtenidos para cada variable del modelo de scoring de comportamiento y su nivel de significatividad:

Variable Modelo Comportamiento	B	Sig.	Exp(B)
Plazo	0.013	0	1.013
Sexo(1)	-0.132	0.004	0.877
Amortización	-1.897	0	0.15
Cuotas_Impagas_Max	1.339	0	3.817
Antigüedad_Sistema	-0.02	0	0.98
PeorSit_24M	0.09	0.001	1.094
Consultas_3M	0.157	0	1.17
RCT_Mercado	0.049	0	1.05
Tendencia_Deuda_6M	0.455	0.004	1.576
RCl_Mercado	-0.739	0	0.477
Netolrregular_24M	-0.078	0	0.925
Score_Bureau_Cat		0	
Score_Bureau_Cat(1)	0.885	0	2.422
Score_Bureau_Cat(2)	0.75	0	2.116
Score_Bureau_Cat(3)	0.421	0	1.523
Constante	-2.616	0	0.073

Tabla 6: Coeficientes regresión logística comportamiento

Se observa que todas las variables del modelo son significativas (Sig. <0.05). En el anexo 9.2 se podrán revisar algunos ejemplos de bivariados.

El "Exp(B)" también permite tener una medida de qué tanto influye la variable en el evento de estudio, por ejemplo, en la variable "Cuotas_Impagas_Max" que considera la cantidad de cuotas máximas que adeudó el cliente en el pasado, el aumento de una unidad de dicha cantidad, manteniendo el resto de las variables constantes, aumentaría el riesgo relativo en 3.817 veces. Tiene sentido además considerar que a mayor cantidad de cuotas impagas se habla de un cliente con un perfil más riesgoso cuya probabilidad de *default* debería ser mayor (y coincide con el beta positivo =1.339).

Asimismo, se procede a calcular las tablas de performance tanto para la base de entrenamiento como para la base de validación.

Rango Score	Score Mín.	Score Máx.	#Total	%Portfolio +	%Portfolio -	%GoodAc +	%GoodAc -	%BadAc +	%BadAc -	%Bads	%Bads +	PD Teórica	Odds	KS	
10	976	995	2815	11	100	12	100	1	100	1.10	1	1.90	89	10	
9	968	975	2671	21	89	22	88	4	99	2.51	2	2.85	38	18	
8	959	967	2763	31	79	34	78	7	96	3.04	2	3.70	31	26	
7	950	958	2607	41	69	44	66	11	93	4.41	3	4.59	21	32	
6	940	949	2503	50	59	54	56	16	89	4.91	3	5.54	19	37	
5	926	939	2802	61	50	65	46	22	84	5.92	4	6.72	15	42	
4	909	925	2584	70	39	75	35	30	78	8.05	4	8.24	11	44	
3	880	908	2641	80	30	84	25	42	70	11.81	5	10.46	7	42	
2	801	879	2638	90	20	93	16	59	58	16.64	6	15.07	5	34	
1	1	800	2652	100	10	100	7	100	41	40.50	10	40.25	1	0	
			26676												

Tabla 7: Tabla de Performance de Entrenamiento

Rango Score	Score Mín.	Score Máx.	#Total	%Portfolio +	%Portfolio -	%GoodAc +	%GoodAc -	%BadAc +	%BadAc -	%Bads	%Bads +	PD Teórica	Odds	KS	
10	976	996	1211	11	100	12	100	2	100	1.49	1	1.90	66	9	
9	968	975	1141	21	89	22	86	5	98	2.89	2	2.85	33	17	
8	960	967	1065	30	79	32	78	8	95	3.41	3	3.64	28	24	
7	951	959	1124	40	70	43	68	13	92	4.36	3	4.49	21	30	
6	940	950	1138	50	60	54	57	17	87	4.39	3	5.47	21	36	
5	926	939	1179	61	50	65	46	23	83	5.17	4	6.72	18	41	
4	909	925	1082	70	39	74	35	30	77	6.93	4	8.26	13	44	
3	881	908	1115	80	30	84	25	39	70	8.61	5	10.40	10	45	
2	805	880	1133	90	20	94	16	54	61	14.21	6	14.85	6	40	
1	1	804	1127	100	10	100	6	100	46	44.10	10	40.71	1	0	
			11305												

Tabla 8: Tabla de Performance de Validación

Observar que las columnas de "%Bads" que corresponden al ratio de malos/total presentan un orden escalonado creciente a medida que el rango de score disminuye. Por otro lado, se observa un bajo desvío entre la PD empírica y la PD teórica obtenida desde el puntaje del score. En cuanto al índice KS, se obtiene un valor de 44 puntos.

Se obtiene un índice GINI de 59.04 y un AUC de 79.27 para la base de validación. Se amplía información en el anexo 9.2.

6.3. Modelo de scoring lifetime

Se presentan a continuación los ponderadores obtenidos para cada variable del modelo de *scoring lifetime* y su nivel de significatividad:

Variable Modelo LifeTime	B	Sig.	Exp(B)
Plazo	0.0224	<0.005	1.02
Amortizacion	-1.5182	<0.005	0.22
Cuotas_Impagas_Max	0.9528	<0.005	2.59
Antigüedad	-0.0104	<0.005	0.99
Score_Bureau	-0.0005	<0.005	1
Consultas_3M	0.0704	<0.005	1.07
RCT	-0.0626	<0.005	0.94
Tendencia_Endeudamiento_6M	0.1512	0.04	1.16
Tendencia_Endeudamiento_12M	0.1231	0.02	1.13
Netolreg_24M	-0.0496	<0.005	0.95
Sexo_F	-0.0945	<0.005	0.91

Tabla 9: Coeficientes regresión de Cox Lifetime

Adicionalmente, se puede caracterizar la función Hazard desarrollada en 4.1.2 con todas las tasas instantáneas de salida obtenidas para la base modelada:

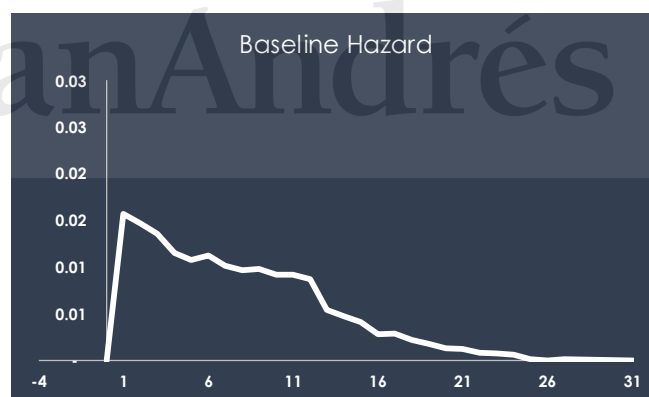


Gráfico 1: Baseline Hazard

Observar que al principio presenta un incremento sostenido hasta alcanzar un máximo y luego con el correr de los meses tiende a disminuir, esto puede

interpretarse como que en la medida que un cliente vaya pagando sus cuotas mensualmente, la probabilidad de default tiende a reducirse.

Análogamente, con la tasa instantánea de supervivencia, es posible graficar el tiempo de supervivencia base:

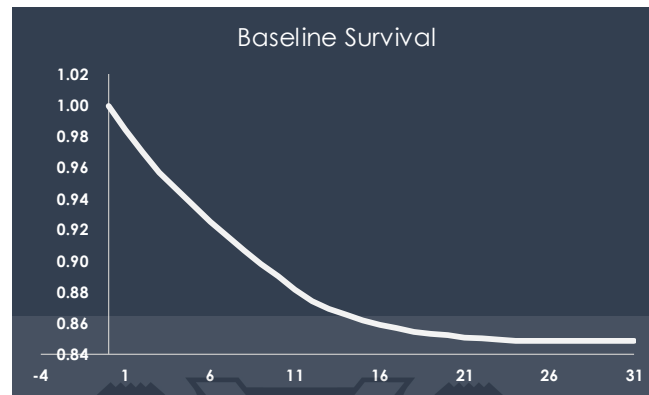


Gráfico 2: Baseline Survival

Recordando la función de supervivencia $S_i(t) = S_0(t)e^{\beta' X_i(t)}$, detallada en 4.1.2, se analiza un ejemplo práctico:

	Vars	Beta
Plazo	36.0000	0.0224
Amortización	0.3611	-1.5182
Cuotas_Impagas_Max	1.0000	0.9528
Antigüedad	24.0000	-0.0104
Score_Bureau	500.0000	-0.0005
Consultas_3M	2.0000	0.0704
RCT	1.4459	-0.0626
Tendencia_Endeudamiento_6M	0.6794	0.1512
Tendencia_Endeudamiento_12M	0.7846	0.1231
Netolreg_24M	6.0000	-0.0496
Sexo_F	0.0000	-0.0945
Suma producto:		0.6842

Tabla 10 Ejemplo cliente modelo lifetime

La probabilidad de que el cliente entre en default en una ventana de 24 meses es:

$$PD(24) = 1 - S(24) = 1 - 0.849074e^{0.6842} = 27.7\%$$

Al igual que en la regresión logística, el signo del coeficiente de la variable nos permite entender cómo afecta sobre la variable objetivo. Tomando como ejemplo la variable "Cuotas_Impagas_Max", es posible observar que tiene un coeficiente positivo de 0.95, es decir, que incrementos en dicha variable incrementan la probabilidad de pertenecer al grupo de interés (*default* o no supervivencia). En este sentido, se ha graficado la función de supervivencia para distintos valores de la variable (1,2,3 y 4) con el objetivo de validar lo mencionado:

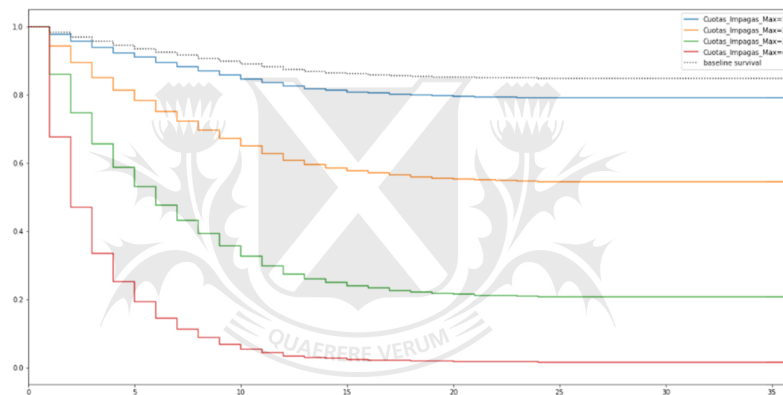


Gráfico 3: Baseline Survival para niveles de Cuotas_Impagas_Max

Observar cómo disminuyen las probabilidades (eje de ordenada) en la medida que se incrementan la cantidad de cuotas impagas. En el anexo podrán encontrarse otros ejemplos de variables analizadas.

Con el objetivo de validar el ajuste del modelo, se calculan las tablas de performance tanto para la base de entrenamiento como para la base de validación. Para ello se valida en diferentes rangos de plazo remanente, por ejemplo el subsegmento de plazo remanente menor a 24 meses que equivale al 99.59% de la base, en este caso se *scorea* toda la base obteniendo los siguientes resultados:

Rango Score	Score Mín.	Score Máx.	#Total	%Portfolio +	%Portfolio -	%GoodAc +	%GoodAc -	%BadAc +	%BadAc -	%Bads	%Bads +	PD Teórica	Odds	KS	
10	940	979	3205	10	100	12	100	2	100	3.18	3	4.89	30	10	
9	923	939	3067	20	90	24	88	4	98	4.92	4	6.93	19	19	
8	906	922	3304	31	80	36	76	8	96	7.99	5	8.62	11	27	
7	890	905	2926	40	69	46	64	13	92	10.36	7	10.22	8	33	
6	869	889	3215	50	60	58	54	20	87	12.19	8	12.03	7	37	
5	838	868	3112	60	50	68	42	28	80	15.10	9	14.58	5	40	
4	791	837	3053	70	40	78	32	37	72	19.69	10	18.49	4	40	
3	728	790	3145	80	30	87	22	50	63	25.06	12	23.90	2	37	
2	603	727	3096	90	20	95	13	68	50	35.37	15	32.34	1	27	
1	0	602	3119	100	10	100	5	100	32	62.26	20	61.36	0	0	
			31242												

Tabla 11: Tabla de Performance de Entrenamiento

Observar que las columnas de “%Bads” que corresponden al ratio de malos/total presentan un orden escalonado creciente a medida que el rango de score disminuye. Por otro lado, se observa un bajo desvío entre la PD empírica y la PD teórica obtenida desde el puntaje del score, salvo en el primer rango donde se observa una leve sobreestimación. En cuanto al índice KS, se obtiene un valor de 40 puntos.

Rango Score	Score Mín.	Score Máx.	#Total	%Portfolio +	%Portfolio -	%GoodAc +	%GoodAc -	%BadAc +	%BadAc -	%Bads	%Bads +	PD Teórica	Odds	KS	
10	941	977	1383	10	100	12	100	1	100	2.82	3	4.86	34	10	
9	924	940	1373	20	90	24	88	5	99	6.34	5	6.84	14	19	
8	908	923	1328	30	80	35	76	9	95	8.43	6	8.46	10	26	
7	891	907	1311	40	70	46	65	14	91	10.53	7	10.08	8	32	
6	869	890	1400	50	60	58	54	21	86	13.14	8	11.99	6	36	
5	839	868	1307	60	50	68	42	29	79	16.53	10	14.55	5	38	
4	792	838	1352	70	40	78	32	38	71	16.72	11	18.36	4	40	
3	728	791	1339	80	30	87	22	50	62	24.79	12	23.93	3	36	
2	598	727	1344	90	20	95	13	69	50	36.01	15	32.49	1	26	
1	0	597	1347	100	10	100	5	100	31	61.32	20	60.88	0	0	
			13484												

Tabla 12: Tabla de Performance de Validación

7.7. Cálculo de la LGD

Respecto al cálculo de LGD, a partir de la metodología de Chain Ladder, se ha obtenido un valor de parámetro del 75.46%. Es decir que, sobre aquellos clientes que incumplen en default, la entidad logra recuperar un 24.54%. Se amplía información en el anexo 9.4.

7.8. Cálculo de Previsiones

Para obtener los valores de previsiones sobre la base de datos del “mes 1” mencionada, en primer lugar, se clasifica la cartera por *stage* y se compara con la SIT BCRA:




Gráfico 4: Distribución de SIT BCRA vs STAGE

SIT_BCRA	Stage_1	Stage_2	Stage_3	Total
1	78.58%	0.00%	0.00%	78.58%
2	1.42%	5.87%	0.00%	7.29%
3	0.62%	0.26%	2.22%	3.10%
4	0.34%	0.13%	3.71%	4.18%
5	0.04%	0.02%	6.80%	6.86%
Total	80.99%	6.28%	12.73%	100.00%

Tabla 13: Distribución SIT BCRA y STAGE

Se observa que el 80.99% de la cartera, que equivale a un total de 14938 préstamos se encuentra en *stage 1* por lo cuál su PD será evaluada a partir de los dos modelos de regresión logística, en función a si es o no cliente conocido. El 6.28% de la base, que corresponde a un total de 974 préstamos, se encuentra en *stage 2* y su PD será evaluada con el modelo lifetime de Cox. El 12.73% restante en *stage 3* presentan evidencia de deterioro por lo cual la PD es 1.

Una vez scoreada la base, considerando la LGD del 75.46% y la actualización de flujos correspondiente de la EAD, se obtienen los siguientes resultados de parámetros:

STAGE	PD_Mean	LGD_Mean	EAD_Mean
Stage_1	10%	75%	\$ 14,064
Stage_2	36%	75%	\$ 12,443
Stage_3	100%	75%	\$ 15,487
Total	27%	75%	\$ 41,994

Tabla 14: Resultado de parámetros

Se procede a calcular las provisiones, obteniendo para el modelo de ECL un valor total de 59 millones que equivale a una cobertura sobre el stock de deuda del 15.00%. En cuanto a los lineamientos del BCRA, se obtiene un valor de previsión de 45 millones, equivalente a un 11.51% de cobertura. Se evidencia que el modelo NIIF implica un incremento en las provisiones del 30.00%:

STAGE	DEUDA	PREVISIÓN BCRA	PREVISIÓN NIIF	DELTA
Stage_1	\$ 318,629	\$ 4,861	\$ 17,510	260%
Stage_2	\$ 24,690	\$ 1,822	\$ 3,716	104%
Stage_3	\$ 50,089	\$ 38,618	\$ 37,798	-2%
Total	\$ 393,409	\$ 45,300	\$ 59,024	30%

Tabla 15: Resultado de Modelos de Previsión

Análogamente, se calculan las provisiones con ambas metodologías para los sucesivos próximos 11 meses con el objetivo de contar con un cierre contable completo, obteniendo las siguientes series de cobertura:




Gráfico 5: Evolución de ratios de cobertura

Observar que el spread entre ambas metodologías se va levemente reduciendo. Eso se debe a que la cartera de préstamos se ha ido deteriorando y se ha

utilizado el mismo modelo de ECL durante un año completo sin efectuar ninguna revisión del modelo. Resulta crítico realizar con frecuencia un ajuste en los parámetros, por ejemplo, cada trimestre o semestre, o lo que resulte más adecuado según la volatilidad de la cartera. Se podrían recalibrar los beta de las regresiones o bien, si las PDs se han desplazado sin perder escalonamiento, ajustar las PDs teóricas obtenida implícitamente de los modelos con las PDs empíricas capturadas con períodos más recientes de información. Adicionalmente, recordar que este trabajo no cuenta con un modelo de *forward looking* que capture los movimientos macroeconómicos, probablemente también sea una buena herramienta para corregir estimaciones futuras.

De todos modos, para todos los períodos se observa un incremento en las previsiones por riesgo de incobrabilidad con la nueva metodología. Lo visto anteriormente se presenta a continuación en términos nominales:

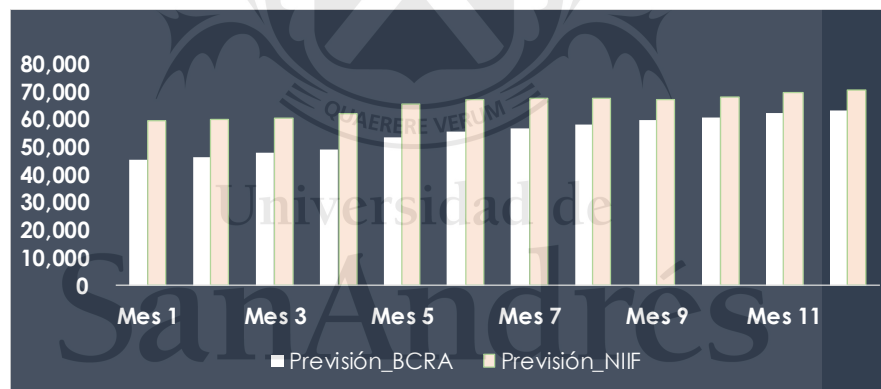


Gráfico 6: Evolución del monto de previsiones

7. CONCLUSIÓN

Los cambios en las normas de provisionamiento por riesgo de incobrabilidad se han diseñado para propiciar un profundo cambio en la forma en la cual las entidades financieras abordan y gestionan el riesgo de crédito.

En función al riesgo que asuma y gestione la entidad, el cambio puede generar mayor o menor impacto en los balances. En la medida que el apetito a riesgo sea más elevado, el incremento de provisiones por converger a un esquema de pérdida esperada debería tener mayor repercusión. Para el caso puntual analizado en este trabajo, el cambio metodológico implica un incremento en el monto de provisiones del 30%, que en términos nominales genera un pase a pérdida de 13,7 millones en el primer mes de convergencia. Esto representa un 3.5% sobre el stock de deuda.

El principal quiebre se encuentra en el grupo tradicionalmente clasificado como segmento 1, según metodología BCRA, al cual se le asignaba una cobertura del 1%. Al provisionar bajo pérdida esperada el cambio refleja un incremento significativo. En la cartera analizada, la previsión sube un 260%, llegando a una cobertura del 5%.

Para el stage 2, si bien el delta de cobertura casi duplica la metodología anterior, la proporción sobre la cartera total no es tan representativa y no genera un fuerte impacto económico.

Por último, dentro del stage 3, el mayor grupo pertenece al anterior segmento conocido como SIT 5, cuya cobertura tradicional era del 100%. Si bien se cuenta con evidencia certera de deterioro, aún queda la herramienta de la gestión de recupero, por lo cual, si la entidad logra obtener una gestión positiva, la previsión no necesariamente tendrá que ser del 100%. En la cartera analizada, se ha obtenido y utilizado para la estimación de pérdida una LGD del 75%, lo que resulta una previsión equivalente a dicho porcentaje sobre la exposición total.

Respecto a la definición metodológica, la norma permite gran creatividad para modelar de la forma más robusta los parámetros. Se ha podido comprobar que es posible aplicar modelos de supervivencia para la estimación de la probabilidad de *default*, además de las tradicionales regresiones logísticas, e incluso, aplicar herramientas del marco de los seguros para estimar la LGD.

En esta línea, resulta interesante profundizar en modelos que puedan predecir el tiempo al default, considerar curvas de LGD en función al estadio de mora o bien realizar un modelo de *forward looking* que permita ajustar los parámetros en función a proyecciones macroeconómicas, que no han sido considerados en este trabajo. Hay mucho por investigar para obtener finalmente el modelo que mejor ajuste a la cartera crediticia.

Adicionalmente, se ha podido remarcar la importancia de revisar el modelo o recalibrar los parámetros con cierta frecuencia para capturar los posibles cambios en el riesgo y poder reflejar correctamente la pérdida esperada de la cartera. En la base analizada se ha observado que a lo largo de los meses se iba reduciendo el spread entre ambas coberturas porque la cartera se había deteriorado y el modelo no se había ajustado.

La eficacia de la nueva norma dependerá, no solo de cómo la apliquen los bancos, sino también del rol que tomen los organismos supervisores. Resulta crítico que se promueva el uso de prácticas rigurosas y la divulgación de información útil sobre la exposición crediticia a fin de lograr mayor transparencia que facilite la disciplina de mercado y la confianza entre los distintos participantes.

Cabe destacar que este contexto de gran incertidumbre generado por la pandemia Covid-19 no ha sido de gran ayuda para transitar el primer año de implementación. Si bien la NIIF 9 establece un marco para determinar las ECL, no establece una mecánica para determinar cuándo se requieren reconocer pérdidas de por vida. Tampoco menciona las bases sobre las cuales las entidades

deben establecer los escenarios prospectivos. Además, los parámetros y supuestos implementados a principio de año ya no pueden mantenerse en el entorno actual y sumado a los cambios normativos impulsados como medidas de apoyo a la sociedad (postergación de obligaciones, refinanciaciones automáticas, entre otros¹³) generan la necesidad de revisar los modelos. De todos modos, difícilmente sea posible incorporar dichos efectos sobre una base razonable y sustentable de información.

Los desafíos más importantes con los que se encontrarán las entidades podrían vincularse a la organización y gobierno, ya que será necesario generar equipos multidisciplinarios y capacitados, y la necesidad de trabajar en la definición de metodologías, políticas, procedimientos, controles y responsables. Por el lado de información y sistemas, implicará la automatización de procesos para obtener información histórica, motores de cálculo, validaciones y reportes de seguimiento. Sin embargo, el principal desafío se encontrará en la integración de los modelos de ECL en la gestión diaria. Va a ser un largo camino alcanzar la consideración de dichos modelos en, por ejemplo, la adquisición de clientes, definición de tasas, gestión de cobranzas, entre otros.


Como todo cambio de gran magnitud llevará un cierto tiempo de asimilación, pero finalmente se alcanzará un proceso de previsionamiento más riguroso, congruente y transparente con una visión prospectiva que permitirá mayor grado de eficiencia en la gestión de riesgo.

¹³ COM A "7056" – Servicios financieros en el marco de la emergencia sanitaria dispuesta por el decreto N°260/2020 Coronavirus (Covid-19). Adecuaciones.

8. BIBLIOGRAFÍA

- Abid, L., Masmoudi, A., & Zouari-Ghorbel, S. (2016). The Consumer Loan's Payment Default Predictive Model: An Application in a Tunisian Commercial Bank. *Asian Economic and Financial Review*, 6(1), 27.
- Altman, E. I. (1989). Measuring corporate bond mortality and performance. *The Journal of Finance*, 44(4), 909-922.
- BCBS (2012) «Principios Básicos para una supervisión bancaria eficaz», septiembre.
- Bikker, J. A., & Metzmakers, P. A. (2005). Bank provisioning behaviour and procyclicality. *Journal of international financial markets, institutions and money*, 15(2), 141-157.
- Bolton, C. (2010). Logistic regression and its application in credit scoring (Doctoral dissertation, University of Pretoria).
- Cohen, B. H., & Edwards Jr, G. A. El provisionamiento en función de las pérdidas crediticias esperadas.
- Comité de Supervisión Bancaria de Basilea (2015). Orientaciones sobre la contabilidad de pérdidas crediticias esperadas.
- Eckert, J., Jakob, K., & Fischer, M. (2016). A credit portfolio framework under dependent risk parameters: probability of default, loss given default and exposure at default.
- Edwards Jr, G. A. (2014). The upcoming new era of expected loss provisioning. *Insights and Thought Leadership on Financial Stability*, 13.
- Gupton, G. M., Stein, R. M., Salaam, A., & Bren, D. (2002). LOSSCALCTM: Model for predicting loss given default (LGD). Moody's KMV, New York.
- Hand, D. J., & Henley, W. E. (1997). Statistical classification methods in consumer credit scoring: a review. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 160(3), 523-541.
- Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied logistic regression (Vol. 398). John Wiley & Sons.

- International Accounting Standards Board (2014a) «NIIF 9 Instrumentos Financieros», julio.
- Mack, T. (2004). Chain-Ladder Method. Encyclopedia of Actuarial Science.
- Merz, M., & Wüthrich, M. V. (2007). Prediction error of the expected claims development results in the chain ladder method. Bulletin of Swiss Association of Actuaries, 1(2007), 117-137.
- Novotny-Farkas, Z. (2016). The interaction of the NIIF 9 expected loss approach with supervisory rules and implications for financial stability. Accounting in Europe, 13(2), 197-227.
- Onali, E., & Ginesti, G. (2014). Pre-adoption market reaction to NIIF 9: A cross-country event-study. Journal of Accounting and Public Policy, 33(6), 628-637.
- Schuermann, T. (2004). What do we know about Loss Given Default?



Universidad de
San Andrés

9. ANEXOS

9.1. Modelo de Scoring de Admisión

Variables	Desviación	Correlaciones de Pearson	Peso	Peso Ajustado
	(Puntuación Xi)	(Xi, Puntuación Total)		
Score_Bureau_Cat	0.263	0.47	18.21%	18.22%
Consultas_Financieras_6M_C	0.224	0.493	16.15%	16.16%
Cant_Sit1_24m_Cat	0.366	0.519	27.82%	27.83%
Consultas_Bancos_3M	0.153	0.244	5.48%	5.48%
Flag_Trabaja	0.144	0.144	3.04%	3.04%
Flag_Irregular_24M	0.148	0.218	4.72%	4.72%
Edad_Cat_v3	0.218	0.339	10.82%	10.83%
Sexo	0.155	0.185	4.20%	4.21%
Plazo_Cat	0.212	0.306	9.51%	9.51%
			99.95%	100.00%

Tabla 16: Importancia de las variables modelo de admisión




Gráfico 7: Bivariado Consultas_Financieras_6M_Cat

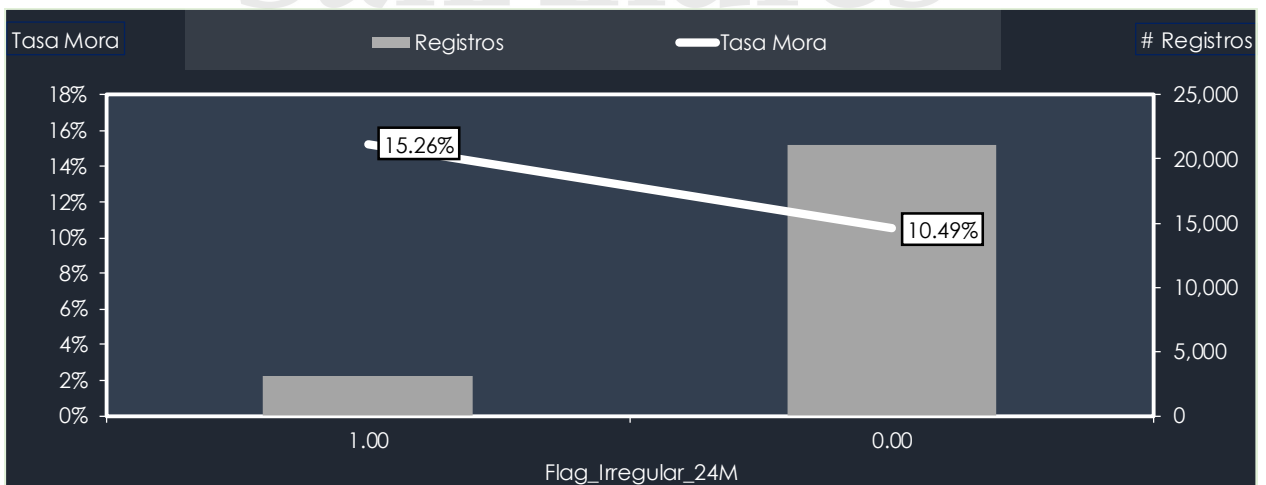


Gráfico 8: Bivariado Flag_Irregular_24M

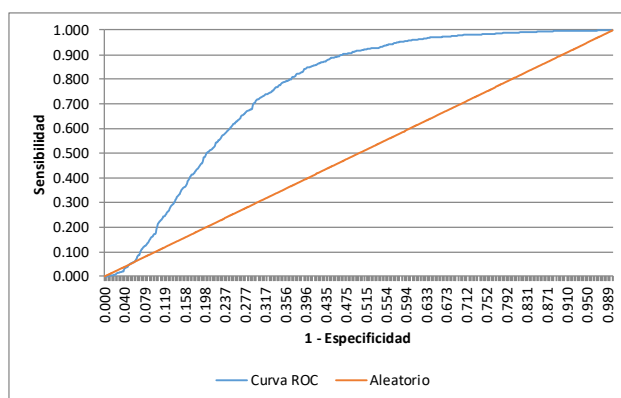


Gráfico 9: Curva ROC de modelo de admisión

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Flag_Score_Bureau_Cat(1)	1.0000	-0.6630	-0.2160	-0.0040	0.0530	-0.0440	0.1100	0.0240	0.0530	-0.0180	-0.0050	-0.0660	0.0150	0.0140
Flag_Score_Bureau_Cat(2)	-0.6630	1.0000	-0.3050	-0.0020	-0.0430	0.0690	-0.0790	-0.0230	-0.0560	-0.0010	-0.0820	0.0870	-0.0070	-0.0210
Flag_Score_Bureau_Cat(3)	-0.2160	-0.3050	1.0000	0.0030	-0.0530	0.0030	-0.0870	-0.0290	-0.0410	0.0220	-0.0550	0.0140	-0.0430	-0.0130
Consultas_Financieras_6M_Cat(1)	-0.0040	-0.0020	0.0030	1.0000	-0.4050	-0.0520	-0.0980	-0.0190	-0.0490	0.0000	-0.0380	-0.0350	0.0250	-0.0010
Consultas_Financieras_6M_Cat(2)	0.0530	-0.0430	-0.0530	-0.4050	1.0000	-0.0260	-0.0030	0.1840	0.1570	-0.0150	-0.0190	-0.0060	0.0220	-0.0130
Cant_Sit_24m_Cat(1)	-0.0440	0.0690	0.0030	-0.0520	-0.0260	1.0000	-0.4820	0.0040	-0.0150	0.0530	-0.0360	-0.0180	-0.0180	0.0210
Cant_Sit_24m_Cat(2)	0.1100	-0.0790	-0.0870	-0.0980	-0.0030	-0.4820	1.0000	0.0700	0.1190	0.0240	0.1190	0.0730	0.0120	-0.0150
Consultas_Bancos_3M_Cat(1)	0.0240	-0.0230	-0.0290	-0.0190	0.1840	0.0040	0.0700	1.0000	-0.1780	0.0200	0.0220	0.0020	0.0150	0.0050
Consultas_Bancos_3M_Cat(2)	0.0530	-0.0560	-0.0410	-0.0490	0.1570	-0.0150	0.1190	-0.1780	1.0000	0.0270	0.0330	0.0130	0.0170	0.0170
Flag_Trabaja(1)	-0.0180	-0.0010	0.0220	0.0000	-0.0150	0.0530	0.0240	0.0200	0.0270	1.0000	0.0440	-0.1280	-0.0630	0.2430
Flag_Irregular_24M(1)	-0.0050	-0.0820	-0.0550	-0.0380	-0.0190	-0.0360	0.1190	0.0220	0.0330	0.0440	1.0000	0.0080	0.0110	0.0130
Flag_Edad_Cat(1)	-0.0660	0.0870	0.0140	-0.0350	-0.0060	-0.0180	0.0730	0.0020	0.0130	-0.1280	0.0080	1.0000	0.0930	-0.0510
Flag_Plazo_Cat(1)	0.0150	-0.0070	-0.0430	0.0250	0.0220	-0.0180	0.0120	0.0150	0.0170	-0.0630	0.0110	0.0930	1.0000	-0.0700
Sexo(1)	0.0140	-0.0210	-0.0130	-0.0010	-0.0130	0.0210	-0.0150	0.0050	0.0170	0.2430	0.0130	-0.0510	-0.0700	1.0000

Tabla 17: Correlaciones entre las variables modelo de admisión

9.2. Modelo de Scoring de Comportamiento

Variables	Desviación	Correlaciones de Pearson	Peso	Peso Ajustado
	(Puntuación Xi)	(Xi, Puntuación Total)		
ScoreBureau	0.264	0.23	6.19%	6.19%
Plazo	0.106	0.218	2.33%	2.33%
Amortizacion	0.461	0.432	20.12%	20.11%
Cuotas_Impagas_Max	0.740	0.725	54.25%	54.25%
AntiguedadSistema	0.115	0.189	2.19%	2.19%
PeorSit_24M	0.073	0.033	0.25%	0.24%
Consultas	0.174	0.174	3.06%	3.06%
Sexo	0.065	0.067	0.44%	0.44%
RCT	0.190	0.11	2.11%	2.11%
Tendencia	0.075	0.176	1.34%	1.34%
RCI	0.205	0.192	3.97%	3.97%
Netolrr	0.183	0.203	3.77%	3.76%
			100.01%	100.00%

Tabla 18: Importancia de las variables modelo de comportamiento




Gráfico 10: Bivariado variable Sexo




Gráfico 11: Bivariado variable Antigüedad en el Sistema Financiero

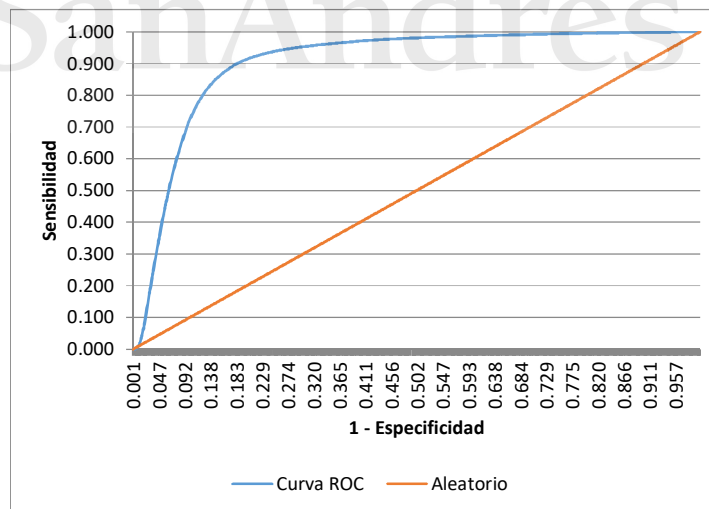


Gráfico 12: Curva de Roc modelo de comportamiento

9.3. Modelo de Scoring Lifetime

Período	Baseline Hazard	Baseline Survival
0	-	1.0000
1	0.0157	0.9844
2	0.0146	0.9701
3	0.0135	0.9571
4	0.0115	0.9461
5	0.0108	0.9360
6	0.0113	0.9254
7	0.0102	0.9161
8	0.0097	0.9072
9	0.0098	0.8983
10	0.0093	0.8900
11	0.0093	0.8818
12	0.0088	0.8741
13	0.0055	0.8694
14	0.0047	0.8653
15	0.0041	0.8617
16	0.0028	0.8593
17	0.0029	0.8568
18	0.0022	0.8549
19	0.0019	0.8533
20	0.0013	0.8521
21	0.0013	0.8510
22	0.0008	0.8503
23	0.0008	0.8496
24	0.0007	0.8491
25	0.0002	0.8489
26	0.0001	0.8489
27	0.0001	0.8488
31	-	0.8488

Tabla 19: Tasas instantáneas

```
In [156]: ##Abro por amortización
import matplotlib.pyplot as plt
plt.rcParams["figure.figsize"] = (20,10)
cph.plot_covariate_groups('Amortizacion', [0,0.2,0.4,0.6,0.8])
```

Out[156]: <matplotlib.axes._subplots.AxesSubplot at 0x1f915c4afc8>




Gráfico 14: Baseline Survival para niveles de amortización

```
In [154]: ##Abro por score de bureau
import matplotlib.pyplot as plt
plt.rcParams["figure.figsize"] = (20,10)
cph.plot_covariate_groups('Score_Bureau', [300,400,500,600])
```

Out[154]: <matplotlib.axes._subplots.AxesSubplot at 0x1f91234c086>




Gráfico 13: Baseline Survival para niveles de score bureau

```
In [157]: ##Abro por Tendencia_Endeudamiento_6M
import matplotlib.pyplot as plt
plt.rcParams["figure.figsize"] = (20,10)
cph.plot_covariate_groups('Tendencia_Endeudamiento_6M', [0,0.2,0.4,0.6,0.8])

Out[157]: <matplotlib.axes._subplots.AxesSubplot at 0x1f91196ca48>
```




Gráfico 15: Baseline Survival para niveles de tendencia de deuda 6M

9.4. Modelo de LGD

Mes de Ocurrencia	Mes de Desarrollo									
	0	1	2	3	4	5	6	7	8	9
i	\$4,997	0.07	1.89	1.32	1.10	1.09	1.07	1.06	1.08	1.03
i+1	\$4,370	0.08	1.37	1.29	1.10	1.06	1.06	1.12	1.04	1.04
i+2	\$3,743	0.07	1.48	1.38	1.18	1.10	1.13	1.05	1.04	1.05
i+3	\$2,996	0.05	1.68	1.46	1.21	1.19	1.10	1.09	1.07	1.05
i+4	\$2,887	0.04	1.96	1.45	1.31	1.17	1.09	1.07	1.07	1.05
i+5	\$2,797	0.08	1.55	1.29	1.16	1.08	1.06	1.06	1.06	1.04
...
1+11	\$3,932	0.04	1.73	1.37	1.20	1.13	1.08	1.11	1.05	1.03
1+12	\$4,481	0.05	1.59	1.46	1.21	1.14	1.13	1.07	1.07	1.04
1+13	\$4,943	0.04	1.75	1.53	1.18	1.15	1.07	1.08	1.06	1.04
1+14	\$3,974	0.04	2.16	1.55	1.17	1.11	1.15	1.07	1.06	1.04
1+15	\$4,121	0.04	2.14	1.38	1.23	1.15	1.09	1.07	1.06	1.04
1+16	\$4,224	0.03	1.91	1.60	1.29	1.12	1.09	1.07	1.06	1.04
1+17	\$4,117	0.05	1.74	1.55	1.18	1.12	1.09	1.07	1.06	1.04
1+18	\$3,721	0.05	1.76	1.47	1.18	1.12	1.09	1.07	1.06	1.04
1+19	\$4,391	0.14	1.82	1.47	1.18	1.12	1.09	1.07	1.06	1.04
1+20	\$4,057	0.05	1.82	1.47	1.18	1.12	1.09	1.07	1.06	1.04

Figura 21: Factores de Desarrollo

1	2	3	4	5	6	7	8	9
0.05	1.82	1.47	1.18	1.12	1.09	1.07	1.06	1.04

Tabla 20: Factores de Desarrollo Promedio

Mes de Ocurrencia	Mes de Desarrollo										
	0	1	2	3	4	5	6	7	8	9	
i	\$4,997	\$333	\$628	\$830	\$910	\$989	\$1,060	\$1,123	\$1,212	\$1,249	75.02%
i+1	\$4,370	\$346	\$475	\$612	\$670	\$710	\$750	\$839	\$877	\$910	79.17%
i+2	\$3,743	\$257	\$380	\$526	\$620	\$680	\$771	\$812	\$849	\$890	76.21%
i+3	\$2,996	\$146	\$245	\$358	\$434	\$514	\$568	\$618	\$658	\$692	76.88%
i+4	\$2,887	\$126	\$247	\$358	\$470	\$551	\$603	\$646	\$691	\$724	74.93%
i+5	\$2,797	\$229	\$354	\$456	\$528	\$568	\$604	\$638	\$676	\$701	74.94%
...	
1+11	\$3,932	\$162	\$279	\$383	\$459	\$516	\$558	\$619	\$648	\$670	82.97%
1+12	\$4,481	\$214	\$340	\$497	\$600	\$685	\$772	\$823	\$877	\$914	79.61%
1+13	\$4,943	\$180	\$314	\$480	\$568	\$654	\$701	\$755	\$798	\$831	83.19%
1+14	\$3,974	\$142	\$307	\$476	\$560	\$619	\$709	\$757	\$801	\$834	79.02%
1+15	\$4,121	\$167	\$357	\$493	\$606	\$695	\$761	\$813	\$859	\$895	78.28%
1+16	\$4,224	\$143	\$273	\$438	\$566	\$636	\$696	\$744	\$786	\$819	80.61%
1+17	\$4,117	\$216	\$374	\$579	\$686	\$771	\$843	\$901	\$953	\$992	75.90%
1+18	\$3,721	\$175	\$307	\$451	\$534	\$600	\$657	\$702	\$742	\$773	79.22%
1+19	\$4,391	\$634	\$1,155	\$1,695	\$2,008	\$2,257	\$2,470	\$2,639	\$2,790	\$2,906	33.81%
1+20	\$4,057	\$222	\$404	\$593	\$702	\$789	\$864	\$923	\$976	\$1,017	74.94%
											75.5%

Figura 20: Triángulo de Pagos Acumulados y LGD

