

Trabajo Monográfico presentado ante la Facultad de Ciencias Económicas  
y de Administración de la Universidad de la República, para obtener el  
título de Licenciado en Economía.

**Crédito al Consumo en Uruguay:  
un Modelo de Scoring para el Sistema  
Bancario.**

Marzo 2007

Cecilia González  
Verónica Meyer

Tutor: Prof. Adrián Fernández

## RESUMEN

La necesidad de minimizar las asimetrías de información que caracterizan a los mercados financieros exige mejorar las estimaciones del riesgo de crédito. Las recomendaciones de Basilea II incentivan a las instituciones financieras a desarrollar modelos de scoring internos y a basar en ellos el cálculo de los requerimientos mínimos de capital, las decisiones de crédito, y las estrategias de *pricing*. A partir de una muestra de 63.000 solicitudes de un *pool* de instituciones del segmento de créditos al consumo en Uruguay, se ha derivado un modelo logit que estima la probabilidad de incumplimiento de los solicitantes, sirviendo como complemento a la política crediticia actual y permitiendo extraer conclusiones acerca de los determinantes del riesgo en este segmento particular. La aplicación de una regla basada en el modelo generaría al sistema en su conjunto una reducción de más de un punto porcentual en la tasa de incumplimientos observada, resultando en un ahorro de más del 15% de los costos estimados por operaciones incumplidas.

## AGRADECIMIENTOS

A Serafín Frache por sus valiosos aportes,  
a José Luis Puig y Manuel Ternande, por hacer posible este proyecto,  
y a nuestro tutor, Adrián Fernández, por su dedicación.

## ÍNDICE

<b>I.</b>	<b>INTRODUCCIÓN.....</b>	<b>2</b>
<b>II.</b>	<b>MARCO TEÓRICO.....</b>	<b>4</b>
1.	EL RIESGO DE CRÉDITO.....	4
2.	LAS CARACTERÍSTICAS ESPECIALES DE LOS MERCADOS FINANCIEROS.....	4
3.	EL NUEVO ACUERDO DEL COMITÉ DE BASILEA (BASILEA II).....	8
4.	LOS DEPARTAMENTOS DE RIESGO EN LAS ENTIDADES FINANCIERAS.....	10
5.	MÉTODOS DE CLASIFICACIÓN CREDITICIA EN LAS INSTITUCIONES FINANCIERAS.....	14
6.	LA INFORMACIÓN DISPONIBLE EN URUGUAY.....	19
<b>III.</b>	<b>ANTECEDENTES DE LA INVESTIGACIÓN.....</b>	<b>21</b>
1.	“A STATISTICAL MODEL FOR CREDIT SCORING” (GREENE, 1992).....	22
2.	“EQUIFAX SCORE” (EQUIFAX, 2002).....	24
<b>IV.</b>	<b>MODELO DE ANÁLISIS.....</b>	<b>27</b>
1.	DEFINICIÓN DE LA VARIABLE DEPENDIENTE Y EL PERIODO DE OBSERVACIÓN.....	27
2.	DISEÑO DE LA MUESTRA PARA DESARROLLO.....	28
3.	DESCRIPCIÓN DEL MARCO DE APLICACIÓN DEL MODELO.....	31
4.	MUESTRA DE APROBADOS: ANÁLISIS DE LAS VARIABLES DE CARACTERIZACIÓN.....	33
5.	DEFINICIÓN DE LA TÉCNICA ESTADÍSTICA.....	44
6.	REGULARIDADES EMPÍRICAS A TESTEAR.....	45
7.	DESARROLLO DEL MODELO.....	48
8.	MODELOS CANDIDATOS.....	51
<b>V.</b>	<b>ANÁLISIS DE PERFORMANCE DE LOS MODELOS.....</b>	<b>57</b>
1.	INDICADORES DE PERFORMANCE TRADICIONALES.....	57
2.	OTROS INDICADORES DEL PODER DISCRIMINATORIO DEL MODELO.....	58
3.	ANÁLISIS DE TABLAS DE CLASIFICACIÓN.....	63
4.	MODELO 1: DIFERENCIACIÓN DE COSTOS POR TIPO DE ERROR.....	66
5.	DETERMINACIÓN DEL PUNTO DE CORTE ÓPTIMO.....	67
6.	EVALUACIÓN GLOBAL DE CALIDAD DE LOS MODELOS.....	72
<b>VI.</b>	<b>CONCLUSIÓN.....</b>	<b>74</b>
	<b>REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>76</b>
	<b>ANEXO I: EVOLUCIÓN HISTÓRICA DEL CREDIT SCORING.....</b>	<b>80</b>
	<b>ANEXO II: ASPECTOS METODOLÓGICOS.....</b>	<b>82</b>
	Anexo III: Salidas y resultados.....	110

## **I. Introducción.**

La utilización de criterios objetivos para estimar la probabilidad de incumplimiento de solicitantes de crédito se enmarca dentro de la literatura del Credit Scoring y ha cobrado gran trascendencia desde que algunas teorías, como la información asimétrica, fueron incentivando a las instituciones, públicas y privadas, de intermediación y de regulación, a concentrar sus esfuerzos en reducir las asimetrías características de los mercados financieros. Valiéndose de herramientas estadísticas, las instituciones buscan caracterizar fielmente el perfil de los incumplidores, con el objetivo de corregir sus políticas de aprobación y controlar que el comportamiento de los prestatarios sea coherente con los intereses de la entidad que financia sus proyectos personales.

Las recomendaciones de Basilea II son coherentes con esta apreciación general, al establecer incentivos para que las instituciones utilicen modelos de scoring crediticios internos, no solo para ser utilizados en el cálculo de los requerimientos mínimos de capital, sino también para generar una mayor eficiencia en las decisiones, que en definitiva también se traslade a mejores servicios para el usuario final.

El área de créditos al consumo es la de mayor aplicación para la calificación estadística del riesgo, no solamente debido a que la gestión se hace a nivel de grandes carteras donde es ineficiente la realización de análisis individualizados, sino también porque en estas circunstancias es donde crecen las oportunidades de que la información analizada en forma global permita observar regularidades con el respaldo empírico necesario para emitir conclusiones acerca de los determinantes del incumplimiento.

Para que los modelos sean robustos y con buen poder predictivo, deben desarrollarse a partir de una muestra importante de solicitudes de crédito tomadas dentro de un pequeño espacio de tiempo, debiendo incluir toda la información histórica relevante para explicar el riesgo. La información con la que cuentan las instituciones para desarrollar este tipo de modelos incluye usualmente el contenido de los formularios que se completan al momento de las solicitudes, pero por dificultades de acceso y de

acumulación, no es usual que se cuente con información histórica suficiente del resto del mercado, que pueda incluirse como variables explicativas en los modelos. Asimismo, los tamaños muestrales que suelen conseguirse con la operativa mensual de una sola institución no son por lo general suficientes como para asegurar la eficiencia en las estimaciones.

En este contexto, el objetivo de este proyecto es desarrollar un modelo que permita clasificar el riesgo de nuevos solicitantes de créditos al consumo en el sector bancario uruguayo, en base a información disponible en el mercado que, por no estar incluida en el formulario de solicitud, pueda aportar nuevos elementos a la discriminación que consiguen actualmente los criterios de otorgamiento de las instituciones. La aplicación de una regla de decisión genérica por parte de las instituciones consideradas, que esté basada en las predicciones del modelo y sea óptima para el sistema tomado en su conjunto, permitirá analizar el aporte del modelo como complemento del sistema actual, debiendo reflejarse en una reducción de los costos totales que las instituciones afrontan por concepto de operaciones incumplidas.

Con este fin se comenzará por comentar en el Capítulo II los fundamentos teóricos que determinan la importancia de predecir correctamente el riesgo de crédito en las instituciones financieras, y las recomendaciones en este sentido establecidas en el Nuevo Acuerdo del Comité de Basilea. Posteriormente se incluye una síntesis de la experiencia recogida a lo largo de la historia en relación a los determinantes del riesgo en créditos al consumo (esquema de las 5 C del análisis crediticio), y se explican las variantes de aplicación de métodos de clasificación estadística (Credit Scoring) para el análisis de la información disponible. Finalmente se introducen las principales fuentes de información disponibles para el análisis crediticio de una institución financiera en Uruguay.

En el Capítulo III se describen las principales conclusiones extraídas de trabajos similares realizados en el área del Credit Scoring, incluyéndose como referencia principal el trabajo realizado por Equifax en el año 2002.

En el Capítulo IV se describe la muestra a utilizar en este proyecto, así como la metodología utilizada para la construcción del modelo y los resultados empíricos que

surgen del mismo, mientras que en el Capítulo V se verifica el poder predictivo del modelo y las implicancias en términos de los beneficios que genera la aplicación del mismo. Finalmente se formulan las conclusiones del proyecto.

## II. Marco Teórico

### *1. El riesgo de crédito*

El riesgo de crédito es la pérdida económica potencial relacionada con el incumplimiento de un contrato por parte del beneficiario de un crédito.

Si bien la mayoría de las entidades económicas conviven con este tipo de riesgo, especialmente lo hacen las instituciones financieras, debido a que por su naturaleza entregan dinero a personas o empresas, a cambio de una promesa de pago futura. La no devolución de este dinero en tiempo y forma constituye el evento sobre el cual se concentra el riesgo de crédito.

La investigación en el área del riesgo de crédito y sus determinantes es realizada principalmente dentro de las instituciones de crédito, sirviendo de soporte para la política de aprobaciones o la política de fijación de tasas de cada entidad. Pero dadas las características especiales que presentan los sistemas financieros y el papel que juega cada institución en la estabilidad general, es ésta un área donde las autoridades reguladoras también suelen centrar su interés.

### *2. Las características especiales de los mercados financieros.*

**Los mercados de crédito** han sido testigos históricos de la presencia de equilibrios donde no se cumplen las condiciones deseables de máxima eficiencia para el mercado y la economía global. Esto se ha repetido tanto en países con sistemas financieros desarrollados, como en otros de desarrollo más precario. Estas circunstancias han llevado a los teóricos a buscar las razones de este comportamiento en las estructuras más generales de los mercados financieros y no en características de una realidad o situación particular.

La intermediación financiera es necesaria y beneficiosa en términos macroeconómicos; sin embargo, las características de estos mercados determinan que su libre funcionamiento lleve a situaciones sub-óptimas, con el ejemplo más evidente de los equilibrios con insuficiencia de oferta o racionamiento de crédito.

¿Por qué no operan los mecanismos de ajuste al equilibrio entre la oferta y la demanda en los mercados de crédito?, ¿por qué es el racionamiento una característica común de estos mercados? la respuesta a estas preguntas ha encontrado una fundamentación de suficiente consistencia en la **Teoría de la Información Asimétrica** desarrollada por Akerlof (1970) y aplicada específicamente al problema del racionamiento de crédito por Stiglitz y Weiss (1981).

El supuesto que se pone en tela de juicio en el marco de esta teoría es, precisamente, el **supuesto clásico de “información perfecta”**. En el mercado de crédito, la información que manejan las dos partes a la hora de celebrar un contrato es incompleta y asimétrica, condicionando las decisiones de los agentes tanto al momento de “firmar”, como al de determinar las acciones a llevar a cabo a posteriori de cerrado el contrato y concedido el crédito.

**Suponiendo por un momento que sólo existiera un tipo de préstamo**, a un plazo determinado, únicas condiciones y que sólo pudiera variar la tasa de interés, los dos elementos determinantes del rendimiento futuro del crédito para la institución serían: la tasa de interés a cobrar, y el riesgo asociado a la operación. Por un lado el interés a cobrar incrementa la rentabilidad esperada, mientras que por otro, el riesgo la reduce. Lamentablemente para las entidades de financiamiento, algunas condiciones llevan a que estos dos elementos se correlacionen en forma directa.

Por tratarse del elemento observable y manejable para la entidad financiera, **“la tasa de interés que está dispuesto a pagar el solicitante”** se utiliza como un indicador del riesgo asociado a la operación. Así, se asocia a mayor tasa de interés, una menor aversión al riesgo por parte del solicitante, influyendo ésta de diversas maneras para aumentar el riesgo de incumplimiento en la operación de crédito solicitada.

Al fijar una tasa de interés se está considerando el riesgo promedio asociado a una cartera de préstamos de similares condiciones, por lo que la misma tasa de interés se aplicará a personas con distintos niveles de riesgo. Los menos riesgosos tendrán pocos incentivos para aceptar las condiciones propuestas, ya que la tasa de interés coherente con sus proyectos personales es inferior. Bajo estos supuestos, la tasa de interés actúa como un filtro de prestatarios y a medida que aumenta su nivel, el riesgo global se incrementa en el mismo sentido. Así se describe el **problema de la selección adversa** en el mercado de crédito, que surge debido a las dificultades que enfrentan las entidades para discriminar a priori entre los individuos con distintos niveles de riesgo.

Para contrarrestar el efecto negativo que provoca el incremento del riesgo sobre la rentabilidad esperada, se hacen necesarios nuevos incrementos en la tasa de interés. Estos incrementos dejan de ser beneficiosos para la institución a partir de que la contrapartida generada en términos de riesgo compensa totalmente al efecto tasa de interés, por lo cual no se logra el objetivo de subir la rentabilidad esperada. A partir de allí la política más conveniente para las entidades es simplemente interrumpir la concesión de créditos, sin importar la tasa de interés que estén dispuestos a pagar los demandantes. De esta manera se puede explicar la frecuente situación de **racionamiento en la oferta de créditos**, donde el equilibrio se determina en un nivel de exceso de demanda.

Pero existe un segundo mecanismo a través del cual la tasa de interés a cobrar presenta correlación con el riesgo posterior de las operaciones. Una vez fijada la tasa de interés y aceptada por un individuo, ésta pasa a convertirse en un dato más, pero las acciones que se tomen a posteriori afectan el riesgo que enfrenta la entidad financiera. Si la tasa de interés es alta, los compromisos futuros del individuo son mayores, creándose incentivos para incrementar los riesgos de sus proyectos personales. La segunda consecuencia del problema de la información asimétrica es entonces: **la generación de incentivos para que las acciones del prestatario se contrapongan a los intereses de la entidad financiera, en presencia de riesgo moral**, una vez que se ha obtenido el crédito solicitado y es muy costoso o imposible para la institución llevar un control.

Si consideramos la situación en que pueden variar el **resto de las condiciones del crédito**, Stiglitz y Weiss (1981) demuestran como en un mercado con información

asimétrica la exigencia de mayores garantías (al igual que los incrementos en la tasa de interés) acentúa los problemas de selección adversa; de la misma manera actúa la fijación de peores condiciones de contratación en término de plazos o montos, llevando al individuo a bajar su aversión al riesgo, bajando su capacidad de repago, su ingreso disponible y en definitiva dejándole “menos para perder”. De ese modo se incrementan los incentivos a adquirir mayores riesgos por parte de los individuos, derivando en alicientes para que las instituciones reduzcan su oferta de crédito, una vez que la tasa que hace rentables las operaciones supera un cierto nivel.

**En síntesis, en un contexto de información imperfecta,** la selección adversa incrementa la probabilidad de que se otorguen créditos a individuos riesgosos, mientras que el riesgo moral disminuye la probabilidad de que los créditos otorgados sean devueltos. El rol de los bancos como intermediarios financieros es de crucial importancia en estos supuestos, ya que estas instituciones se especializan en la recolección de información, en la evaluación de proyectos y el monitoreo de prestatarios. Sin embargo, **minimizar el problema de la selección adversa (sin llegar a interrumpir la concesión de créditos), implica diseñar mecanismos de fijación de tasas de interés, y demás condiciones, en función del riesgo.** Para ello es imprescindible una adecuada estimación de la probabilidad de incumplimiento de los individuos, lo que también sirve para evitar la generación de incentivos al Riesgo Moral en el prestatario: al ofrecer tasas de interés más ajustadas al riesgo, se está controlando el riesgo promedio de la cartera, y eliminando la necesidad de elevar el nivel general de tasas.

Los problemas derivados de la existencia de asimetrías de información se acentúan en situaciones de recesión o crisis económica. Mishkin (1990) distingue 4 factores que afectan directamente las causas de la selección adversa y el riesgo moral:

- deterioro en las hojas de balance del sector financiero,
- deterioro de las hojas de balance en el sector no-financiero,
- aumento en las tasas de interés y
- aumento en la incertidumbre

En estas circunstancias, Mishkin explica los mecanismos por los cuales los problemas derivados de las asimetrías de información se ven intensificados, y pasan a ser una fuente de inestabilidad y propagación de la crisis en el sector financiero. Si bien el aumento de la incertidumbre y las mayores dificultades para discriminar riesgos son una realidad difícil de modificar en estos períodos, sus consecuencias podrían verse acotadas si durante los momentos de auge del crédito se tomaran los recaudos necesarios, manteniéndose un monto de reservas acorde con los riesgos asumidos. De lo contrario, en los momentos de crisis el desajuste insalvable entre el capital disponible y las necesidades de liquidez acaba por llevar a la quiebra a las instituciones con menos respaldo, acentuando así el carácter sistémico de las crisis.

Situaciones de estas características han podido observarse en los sistemas financieros de muchos países en los últimos años, incluido Uruguay, y es en vista de ello que surgieron las nuevas recomendaciones del Comité de Basilea.

### ***3. El Nuevo Acuerdo del Comité de Basilea (Basilea II).***

El “Nuevo Acuerdo” del Comité de Basilea (Basel Committee on Banking Supervision, 2006) actualización del esquema original presentado en 1988, implica modificaciones que a la luz de la experiencia recogida en la década de los 90 hubieran mitigado algunos de los principales causantes de la inestabilidad y la propagación de las crisis financieras observadas en el mundo.

Si bien los primeros documentos datan del año 1999 y la última versión del Nuevo Acuerdo se redactó en 2004, se estimó su implementación para el año 2007, considerándose además un período adicional dado por la flexibilidad que se otorgó a los reguladores en cada país para la fijación de los períodos de transición.

**El Acuerdo Original** del Comité sólo incorporaba el riesgo de crédito, agregándose luego la consideración del riesgo de mercado, a través de la actualización de 1996. El nuevo esquema mantiene lo establecido en el esquema original: el capital regulatorio mínimo debe ser al menos 8% de los activos ponderados por su riesgo; asimismo se mantiene lo referente al tratamiento del riesgo de mercado de la enmienda de 1996.

El objetivo explícito de Basilea II es lograr una mayor sensibilidad de los requerimientos de capital frente al riesgo. Se promueven prácticas más agresivas para la gestión de los riesgos, diferenciándose el riesgo de crédito de los operacionales y de mercado.

Este conjunto de recomendaciones **promueve la utilización de modelos de scoring desarrollados internamente en las instituciones**, y apunta no sólo a su utilización para el cálculo del capital de riesgo, sino también a su aplicación en otras áreas de la actividad bancaria, haciendo particular referencia a las estrategias de *pricing* de las instituciones.

Basilea II se centra en la información, en cómo debe mantenerse, utilizarse y reportarse. Los tres pilares definidos en este nuevo esquema son:

- I. Requerimientos Mínimos de Capital
- II. Proceso de supervisión bancaria y
- III. Disciplina de Mercado

En su primer pilar, el esquema incentiva la aplicación de modelos más sofisticados para medir el riesgo: los bancos comprendidos en estas recomendaciones pueden elegir entre dos métodos alternativos: el “estandarizado” y el método IRB<sup>1</sup> basado en calificaciones internas (en sus versiones “básico” y “avanzado”). El objetivo es enlazar el nivel de capital con el riesgo de incumplimiento, individualizado y calculado a priori, quedando a criterio del banco la cantidad de categorías de riesgo en las que prefiera realizar la clasificación.

El método estandarizado (EE) se mantiene respecto al establecido en Basilea I, mientras que el método basado en calificaciones internas (IRB) presenta una versión avanzada (AIRB) que implica no solo calcular la probabilidad de incumplimiento para cada activo sino también el resto de los componentes del riesgo: la pérdida en caso de incumplimiento (LGD) y la exposición al incumplimiento (EAD).

---

<sup>1</sup> *Internal Ratings-Based*

**La aplicación del método IRB en la cartera de *retail*** implica necesariamente la utilización del método avanzado, ya que se exige el cálculo interno de todos los componentes del riesgo antes mencionados.

**Existen ciertas condiciones que deben cumplir las instituciones** financieras para adoptar este método. En primer lugar se exige la independencia de las áreas de gestión de créditos, calificación de los riesgos y revisión de los sistemas de calificación. Por otra parte se establece un horizonte temporal de un año para estimar la probabilidad de incumplimiento y en la cual debe calcularse la capacidad y voluntad de pago independiente de la situación económica del país; además debe realizarse una prueba anual sobre los modelos utilizados; las calificaciones obtenidas deben utilizarse no solo para el cálculo de los requerimientos de capital sino como soporte a las decisiones de aprobación/rechazo de un crédito; finalmente dichas calificaciones deben realizarse con una periodicidad mínima de un año. En este contexto es que se acepta, sumado al criterio humano, el **sistema de scoring crediticio** como punto de partida para determinar las calificaciones.

#### ***4. Los departamentos de riesgo en las entidades financieras.***

Tanto en el segmento de créditos al consumo como en los hipotecarios o corporativos, las instituciones financieras cuentan con departamentos de riesgo cuyos objetivos son la identificación de los factores de riesgo de las carteras de créditos y la especificación de modelos que describan el riesgo asociado a cada crédito.

La gestión del riesgo de una cartera de créditos requiere de una valoración y cuantificación del riesgo individual, que abarque tanto la probabilidad de que se produzca el incumplimiento como la probabilidad de que una vez efectivizado fallen todos los mecanismos diseñados por la institución para recuperar la deuda. Finalmente, se nutre de un adecuado cálculo de las pérdidas económicas asociadas a cada contingencia.

En particular en el ámbito bancario, el análisis va más allá del cálculo de las pérdidas esperadas agregadas: es necesaria la estimación de las pérdidas no esperadas, así como el cálculo del riesgo asociado a la cartera. Este último surge de la existencia de

correlaciones entre los comportamientos de los individuos, o de una excesiva concentración de los créditos otorgados.

### **Determinantes de la decisión de otorgamiento de créditos en las instituciones financieras.**

Es de frecuente utilización el término “5 C del análisis crediticio” para presentar los factores que tradicionalmente han sido utilizados para respaldar las decisiones de aprobación o rechazo de solicitudes. Las fuentes a partir de las que se obtiene y consolida la información para efectuar dicho análisis son:

- a) formulario de la solicitud de crédito
- b) historial de pago del cliente con la institución
- c) informe crediticio o historial de pagos con otras instituciones

Cada factor, o cada “C”, representa una de las categorías de variables que se describen a continuación.

#### **1. “Character” – Voluntad de pago**

Con frecuencia este factor es el primero en tomarse en consideración, pues aunque para el resto de los factores se cumplan las condiciones óptimas, la **ausencia de voluntad de pago** es determinante. El “*Character*” va a representar el grado en el cual el prestatario siente la obligación moral de devolver el préstamo.

Para detectar esta situación se deben analizar principalmente rasgos referidos a la **personalidad e integridad del solicitante**, pero también elementos como la existencia de una **relación de largo plazo entre el prestamista y el prestatario**, ya que estos tienden a incrementar la voluntad de pago del mismo.

Dentro de las variables a analizar en éste grupo se encuentran todas aquellas que reflejan características personales (edad, sexo, estado civil, domicilio, y demás **variables demográficas**). Por otra parte, y de especial interés en el proceso de aprobación o desaprobarción de una solicitud, se analizan datos que forman parte del

**historial de pagos del prestatario**, información recabada acerca de la conducta respecto a créditos anteriores: existencia de incumplimientos vigentes, cuántos de ellos se han presentado en el pasado, de qué montos y en qué momento del tiempo ocurrieron. Los atrasos cobran importancia cuando siguen un cierto patrón. Las consultas del historial crediticio también son indicadoras: el hecho de que existan demasiadas consultas recientes, por ejemplo, puede estar indicando un exceso de obligaciones contraídas por el solicitante, o dificultades que el mismo enfrenta para acceder a créditos (*frequent seeker of credits*), características que se asocian negativamente con la probabilidad de devolución del crédito. **Otros puntos a considerar** son: la estabilidad dada por el tiempo de residencia en una locación, la educación, la antigüedad laboral, la permanencia en el mismo sector del mercado de trabajo, etc.

La interpretación correcta de ésta información permite resumir las **características personales relevantes para el problema**, como el grado de aversión al riesgo y la responsabilidad. La hipótesis que sostiene a este factor está en la noción de que la voluntad de honrar las obligaciones es un reflejo del valor que el prestatario deposita en activos como su reputación, honestidad e integridad.

El análisis de ésta categoría se considera más como un **elemento de discriminación** que de decisión, representando un filtro previo a las restantes categorías. Es evidente que el status de cumplidor de un solicitante favorece su acceso al crédito, mientras que aquellos que cuentan con incumplimientos en su historial lo verán más restringido.

## 2. “Capacity” – Capacidad de pago

La capacidad de pago hace referencia a la capacidad del solicitante de generar los fondos netos mensuales necesarios para hacer frente a las obligaciones inherentes al crédito.

Mientras el primer factor representaba la “voluntad”, éste capta la “capacidad” de devolución del préstamo por parte del solicitante, y por ello es de crucial importancia entre los elementos determinantes de la decisión de aprobación/rechazo.

En éste punto se deben tomar en consideración los términos del crédito que se está solicitando, determinándose el grado de adecuación de los mismos dada la realidad del solicitante. Con este objetivo es usual calcular el ratio cuota – ingreso, y determinar qué tan estable es el ingreso en el tiempo.

En el análisis de la capacidad de pago, la entidad financiera proyecta el peor escenario de ingresos y lo compara con el nivel de ingresos mínimo a partir del cual se produciría el default, estableciendo de esta forma la “lejanía a la morosidad”.

### **3. “Capital” - Patrimonio**

El Patrimonio hace referencia al capital acumulado del solicitante de crédito. La importancia de la valoración del patrimonio se justifica como medio para determinar la capacidad de generación de ingresos histórica del prestatario. Este punto adquiere mayor importancia en el caso de préstamos comerciales donde aparece como respaldo o segunda fuente de liquidez en caso de que falle el flujo de fondos.

### **4. “Collateral” – Garantías**

Los colaterales y las garantías de un crédito se definen como los activos que quedan sujetos a la devolución del mismo, o el compromiso de asumir las obligaciones del solicitante por parte de un tercero. Ambas modalidades actúan como seguros del cumplimiento en tiempo y forma del contrato previamente establecido, y pueden ser consideradas como una “segunda fuente de repago”.

Es evidente que la valoración de las garantías variará en función de las probabilidades de default estimadas: será mayor la exigencia cuanto más alto el riesgo de crédito estimado, y menor en caso contrario.

Como contrapartida puede concluirse que ante dos individuos idénticos en sus características, se espera que quien reciba el crédito sin exigencia de garantías tenga una mayor probabilidad de incumplimiento, dadas todas las demás condiciones. Sin perjuicio de ello, las garantías también juegan su papel como incentivos al riesgo moral, por lo que el efecto final puede ir contra las previsiones. Stiglitz y Weiss (1981)

demuestran como en un mercado con información asimétrica la exigencia de mayores garantías (al igual que los incrementos en la tasa de interés) acentúa los problemas de selección adversa.

## 5. “Conditions” – Condiciones

Este grupo de variables abarca lo referente a las tendencias del contexto económico, las características de la industria con la que puedan asociarse los ingresos del solicitante, las perspectivas de crecimiento y estabilidad para el futuro cercano. Este factor abarca todos los elementos que caen por fuera del área de influencia de los prestatarios, y que influyen a su vez en su capacidad o voluntad de pago.

Luego de analizadas las 5 C y obtenidas las estimaciones acerca de la probabilidad de cobro del crédito, la entidad financiera posee una estimación del riesgo que está asumiendo y debe proceder a la fijación de las **condiciones de formalización del contrato**:

- Importe del crédito. En ocasiones la institución financiera post-análisis limita el importe que está dispuesto a prestarle al prestatario.
- Tipo de contrato. Se tendrá en cuenta la modalidad de operación así como las condiciones de la misma, como por ejemplo el plazo de la devolución y la periodicidad del pago de la operación.
- Garantías exigidas.
- Precio, incluyendo elementos tales como la prima de riesgo, gastos vinculados al contrato (apertura y cancelación de la operación), etc.

### *5. Métodos de clasificación crediticia en las instituciones financieras.*

Los métodos tradicionales de calificación de solicitudes se basan en el juicio personal de los analistas de crédito, que consiste por lo general en el análisis de las 5 C. La evolución hacia los métodos estadísticos estuvo acompañada por varios cambios importantes en los mercados:

- A partir de los años '60 la cantidad de operaciones aumentó rápidamente, sobre todo en el área de las tarjetas de crédito, dificultando la toma de decisiones eficientes y consistentes, además de sacar a relucir la escasez de mano de obra especializada.
- La mayor competencia entre las instituciones financieras que se disputaban el mercado llevó a la adopción de medidas para aumentar la eficiencia en la aprobación de los créditos y diferenciar el servicio de forma de evitar la deserción de clientes.
- Los avances en la tecnología y la informatización de las bases de datos, así como el surgimiento de paquetes estadísticos.

### **Los modelos de Credit Scoring.**

La utilización de métodos basados en modelos estadísticos-econométricos o de reglas lógicas con el objetivo de evaluar el riesgo de crédito de una solicitud, se comprenden en la literatura del Credit Scoring<sup>2</sup>. A partir de la selección de una técnica apropiada, estos modelos se desarrollan en base a muestras de créditos otorgados en el pasado, que cumplan con la condición de ser representativas de la operativa de la institución en el futuro próximo.

El procedimiento general implica determinar cuáles fueron, al momento de las solicitudes, las características de los solicitantes y de su historial de comportamiento que se relacionaron más fuertemente con los comportamientos positivos y negativos observados a posteriori. A partir de ello se conforman criterios para predecir la probabilidad de incumplimiento en los nuevos créditos.

Por lo general, estos sistemas arrojan valores o puntuaciones inversamente relacionadas con el riesgo: a mayor "score", menor probabilidad de incumplimiento, y viceversa; en la práctica se suele determinar un punto de corte mínimo para aprobar las solicitudes. También son comunes los sistemas que en lugar de dar puntajes o probabilidades, categorizan las solicitudes en grupos, como "aprobar/rechazar".

---

<sup>2</sup> Por una referencia completa acerca de la evolución histórica de estos métodos y las distintas técnicas disponibles en la actualidad véase la sección I del Anexo.

### **Aplicaciones del Credit Scoring.**

La clasificación más general de modelos de Credit Scoring nos lleva a la diferenciación entre el “**Application Scoring**” o scoring de solicitudes, y el “**Behavioral Scoring**”, o scoring de comportamiento. Mientras el primero se utiliza básicamente para respaldar una decisión de aprobación de crédito, el último sirve para monitorear los créditos ya otorgados, incrementar o reducir las líneas de crédito concedidas, etc. La diferencia fundamental radica en que los modelos de solicitudes utilizan información estática del formulario de solicitud, mientras que los de comportamiento agregan variables relativas al comportamiento crediticio del individuo en un período de tiempo reciente. Debido a que esta información no está disponible para nuevas solicitudes, los modelos de scoring de comportamiento sólo son aplicables a clientes pre-existentes.

### **Segmentos de aplicación del Credit Scoring.**

Indudablemente el área de mayor aplicación del Credit Scoring ha sido siempre el de las **tarjetas de crédito**, por la simple razón de ser el primer producto orientado a segmentos masivos, siendo el más importante también en la actualidad. En este segmento se han venido utilizando modelos de scoring basados en métodos estadísticos, que incorporan a su vez factores determinantes de la rentabilidad, y son aplicados tanto para nuevas solicitudes, como para analizar políticas a tomar con los antiguos clientes.

En el área de **préstamos personales** también se han incorporado casi todos los avances del Credit Scoring, mientras que en el de las **hipotecas** la incorporación de estos métodos ha definido una ramificación específica de la materia basada en el enfoque de los riesgos competitivos. Sin llegar al nivel de las tarjetas y los préstamos personales, la aplicación de estas técnicas a las hipotecas ha sido de amplia aplicación en los países con mercados financieros desarrollados, principalmente Estados Unidos<sup>3</sup>.

En cuanto a los **créditos a empresas**, la evolución no ha sido de gran significación, principalmente debido a la variabilidad que presentan los casos particulares. Son

---

<sup>3</sup> Al igual que todas las variantes del Credit Scoring, la generalización en el uso de estos sistemas no ha logrado transmitirse a los países sub-desarrollados, donde los problemas de oferta de crédito, el atraso relativo en cuanto a la información disponible, etc., han determinado que hasta los grandes bancos internacionales tropezaran en la implementación.

muchas las variables que difieren en su importancia cuando se analizan distintos tipos de negocio y por lo tanto el análisis estadístico pierde relevancia. Algunos métodos no estadísticos sí han encontrado andamio en estos segmentos, como ser los sistemas expertos.

Finalmente, otro segmento de reciente aplicación del Credit Scoring es el de **micro-finanzas**. Por tratarse de créditos que usualmente son de muy bajo monto, se requiere de una masa crítica de créditos muy elevada para representar ganancias a las instituciones. Si bien se encuentra el mismo problema que en el caso de los créditos empresariales dado por el amplio rango de negocios que es necesario analizar, se ha demostrado que en este segmento particular las características del titular del negocio son más importantes que el negocio en sí mismo para determinar el comportamiento crediticio (Schreiner, 2000). Sin embargo todavía se está por ver que un análisis cuantitativo sea capaz de obviar la importancia de algunas variables subjetivas que en este segmento suelen ser fundamentales.

#### **Las ventajas de los métodos estadísticos frente al tradicional.**

**Mayor objetividad en las decisiones y reducción del sesgo de selección**, dada por la influencia en las decisiones de factores no correlacionados con el riesgo: discriminación de género, racial, etc.

**Mayor precisión en las decisiones**, medida tanto a través de la tasa de morosidad como de la cantidad de créditos calificados incorrectamente.

La discusión en este punto se da principalmente debido a que es posible que en algunos casos el criterio humano detecte información fuera del alcance del análisis estadístico objetivo. La frecuencia con la que esto ocurre varía en función de las dimensiones de la operativa que enfrenta la institución y el grado de conocimiento personal que se tenga acerca de los solicitantes.

En el caso de una operativa de grandes dimensiones, el conocimiento que se puede tener acerca de los clientes es escaso. Pero el incentivo a la utilización de métodos

estadísticos está dado también por el hecho de que con muestras grandes se pueden conseguir modelos estadísticos más robustos, que permitan mejores predicciones.

**Mayor eficiencia en el proceso de decisiones**, medida a través del tiempo transcurrido entre la solicitud y la aprobación (o rechazo) de la misma, y uniformidad de los criterios utilizados.

El desarrollo de los mercados financieros, la mayor competencia y la aparición de productos especialmente orientados a segmentos masivos, como las tarjetas de crédito, han determinado la necesidad de automatizar y uniformizar las decisiones de aprobación/rechazo de solicitudes. Estos factores actúan a través de la reducción del error humano en la toma de decisiones, la mejora en el servicio prestado a los clientes, y la concreción de mayor cantidad de operaciones, para mejorar la rentabilidad de las entidades en un ámbito competitivo.

Con estos objetivos, la calificación estadística es uno de los elementos necesarios para llevar adelante procesos de automatización, debiendo integrarse adecuadamente en la plataforma tecnológica de las entidades.

**Sirven de input para enfoques más amplios** de rentabilidad esperada, y modelos de determinación de precios.

Mientras el análisis se base en la captación del riesgo a través de la probabilidad de incumplimiento, el método tradicional sin necesidad de un alto nivel de sofisticación puede dar buenos resultados. Sin embargo, la tendencia en esta área apunta a sustituir el enfoque unidimensional para empezar a incorporar otras variables orientadas a captar en forma completa la rentabilidad de las operaciones. El enfoque amplio de la rentabilidad esperada considera factores como el tiempo de supervivencia de los préstamos otorgados<sup>4</sup>, los costos de recuperación y el tipo de garantías existentes<sup>5</sup>.

**Sirven de herramienta para realizar monitoreo de grandes carteras de prestatarios.** Una vez desarrollados los modelos, el costo operativo de aplicar el

---

<sup>4</sup> El tiempo transcurrido entre la contratación y el default.

<sup>5</sup> Se ha comprobado que el incluir estas variables implica, en muchos casos, mejores tasas de aprobación que al considerarse únicamente la probabilidad de incumplimiento (Jacobson et al., 2003)

análisis a una cartera es mínimo o nulo, por lo que se abre la posibilidad de realizar estudios más ricos, y con mayor frecuencia que en el esquema tradicional.

### ***6. La información disponible en Uruguay***

El almacenamiento y distribución de datos personales destinados a la elaboración de informes de carácter comercial está regulado en Uruguay por la ley 17.838<sup>6</sup>, estableciéndose además en enero de 2006 a través de la 17.948 que las instituciones de intermediación financiera tienen derecho a solicitar este tipo de información a quienes se especialicen en administrar bases de datos, así como podrán acceder a la categorización de riesgo que presente la persona (física o jurídica) en la **Central de Riesgos Crediticios** administrada por el Banco Central del Uruguay.

Con respecto a la **información de bureau de crédito**, la misma se divide normalmente en datos de carácter público e información comercial obtenida de las empresas afiliadas al bureau. En el caso de Clearing de Informes en Uruguay, la información es de carácter nacional, y abarca personas y empresas. Los vectores principales de información en el caso de personas físicas son:

- 1) **datos personales:** incluyendo sexo, edad, residencia y datos del empleo.
- 2) **consultas del informe crediticio:** fechas y datos de las empresas que las realizaron.
- 3) **incumplimientos vigentes:** fecha de registro, fecha de último pago, fecha de contratada la operación, datos de la empresa acreedora, importe de la operación y saldo adeudado, moneda y plazo de la operación.
- 4) **incumplimientos cancelados:** fecha de cancelación de la operación incumplida, implicando la pre-existencia de un registro de incumplimiento.
- 5) **incumplimientos refinanciados:** fecha de refinanciación de la operación incumplida.
- 6) **cheques devueltos por falta de fondos:** fecha de registro, carácter de titular o endosante, empresa que realizó el registro, etc.

---

<sup>6</sup> “Protección de datos personales para ser utilizados en informes comerciales y acción de habeas data”, aprobada en setiembre de 2004.

- 7) **información de cuentas corrientes:** existencia de suspensiones o clausuras de cuentas por parte del Banco Central del Uruguay.
- 8) **empresas afiliadas que aportaron información** a lo largo de todo el historial crediticio de la persona.

La ley 17.838 establece que la información relativa a incumplimientos vigentes permanece hasta 5 años luego de registradas las operaciones, a no ser que la empresa solicite su mantenimiento por 5 años más. La información de la cancelación de operaciones incumplidas se encuentra regulada también por la ley, estableciéndose allí un plazo de 10 días a partir de que se produzca el pago, para que la empresa informe al administrador de la base de datos acerca del hecho.

### **III. Antecedentes de la investigación.**

El análisis del riesgo de crédito y la probabilidad de incumplimiento, y su aproximación a través de métodos estadísticos, define un área muy concurrida en el ámbito de la investigación privada: es una práctica común el que las instituciones crediticias desarrollen modelos para predecir incumplimientos, con mayor o menor nivel de sofisticación, partiendo de información histórica de la operativa propia.

Sin embargo se ha advertido una notable escasez de trabajos publicados, no sólo en nuestro país sino en el mismo entorno internacional. Los casos publicados son pocos y carecen de la generalidad necesaria para ser aplicables al caso de una institución financiera en Uruguay.

La lógica detrás de esta situación es simple: la construcción de un modelo de calificación crediticia requiere de información privada, la cual es uno de los activos principales de las instituciones financieras. Una institución típica del ámbito privado, siguiendo un comportamiento racional, no está dispuesta a “donar” su experiencia en el mercado, para que todas las demás empresas se vean eventualmente beneficiadas con las consecuencias. Por ello, los esfuerzos realizados en la materia permanecen en la confidencialidad.

Los antecedentes que se han seleccionado son de reciente publicación. En ambos casos se desarrollan modelos para predecir la probabilidad de incumplimiento, basándose en información histórica de la operativa de una institución de crédito (caso 1) o en un pool de solicitudes de varias instituciones (caso 2):

- El caso de una institución de créditos para consumo en Estados Unidos (Greene, 1992)
- El modelo de scoring crediticio para afiliados de Clearing de Informes en Uruguay (Equifax, 2002)

Los objetivos perseguidos en estos trabajos y las conclusiones a las que se arribaron fueron referentes para esta investigación, además de constituir buenos antecedentes metodológicos donde se utilizaron distintas formas para abordar el problema, y diversas técnicas para la estimación de los modelos.

Debe destacarse que el modelo de Equifax se desarrolló a partir de una base de datos similar a la que se utilizará en esta ocasión.

### ***1. “A statistical model for Credit Scoring” (Greene, 1992).***

En su trabajo de 1992, Greene estudia el caso de los créditos para consumo, planteando como objetivo primario el análisis de los factores que afectan la probabilidad de incumplimiento, pero extendiéndose luego para incorporar estos resultados en un modelo de rentabilidad esperada de la política crediticia.

El estudio se orienta en la hipótesis de que la probabilidad de incumplimiento o default no puede considerarse en forma unilateral al momento de decidir un crédito, debido a que existen otros factores que afectan en mayor medida la rentabilidad de las operaciones.

Los datos con los que se cuenta para realizar este análisis pertenecen a la base de solicitudes para altas de tarjetas de crédito de una importante compañía, e incluyen entre otros, el gasto asociado a cada usuario al que se le aprobó la solicitud. En total se consideran más de 13.000 solicitudes de un solo mes, a las que se asocian datos del formulario de la solicitud, información de historia crediticia y datos descriptivos del segmento de mercado al que pertenece la persona, los cuales se aproximan a través del código postal y la localización geográfica.

Sobre las solicitudes “aprobadas” se observan 12 meses de comportamiento, los cuales se reflejan en un “indicador de default” que toma valor 1 cuando se produce el no pago de la operación durante 6 meses consecutivos.

Los datos presentan dos problemas: censura y sesgo de selección. El primer inconveniente radica en la ausencia de observaciones de comportamiento para los individuos cuya solicitud fue rechazada; como el modelo se desarrolla a partir de una muestra que excluye estas solicitudes (que posiblemente se asocien a probabilidades de incumplimiento superiores), el resultado de aplicar posteriormente el modelo a una población genérica estará sesgado y no reflejará la probabilidad de incumplimiento “real”.

El segundo problema se basa en que para la muestra utilizada, algunas variables presentan proporciones que no se corresponden con las observables en la población subyacente. En este caso la proporción de usuarios de tarjeta de crédito en la muestra (aproximadamente 78%) es muy superior a la proporción de usuarios en la población (23%), lo que de ignorarse llevaría a un sesgo en las estimaciones del modelo en caso de aplicarse a una población genérica.

La solución elegida para afrontar la censura en los datos (problema I) es el desarrollo de un modelo condicionado a que los individuos sean usuarios de tarjeta de crédito. Dado que esta muestra no representa fielmente las proporciones reales, se le aplican correcciones a las estimaciones para resolver el sesgo de selección muestral que está afectando a los datos (problema II).

Aparte de las anteriores consideraciones, la metodología aplicada para estimar la probabilidad de incumplimiento se mantiene dentro de los estándares, utilizando un Análisis Discriminante (AD) y un modelo Probit como alternativa. Los resultados para ambas técnicas son muy similares, lo cual se explica dentro del trabajo en base a la interpretación de la función discriminante como un Modelo de Probabilidad Lineal. Este artículo confirma la apreciación general de que los resultados en este tipo de estudios son casi idénticos independientemente de que se utilicen modelos Probit, Logit o de Probabilidad Lineal.

Las variables más significativas para el modelo de default condicional a la ecuación de usuario de tarjeta de crédito son:

- Cantidad de incumplimientos de magnitud considerable en el pasado (-)
- Cantidad de consultas de historial crediticio (-)
- Indicador de “cuenta-propista” (-)
- Cantidad de incumplimientos de 30 días en el último año (-)
- Cantidad de líneas de crédito comerciales abiertas y activas (+)
- Tenencia de una tarjeta de crédito “superior” (+)
- Indicador de posesión de cuenta corriente y caja de ahorros (+)
- Nivel de ingreso (+)

Las variables indicadoras del segmento de mercado, que fueron aproximadas con datos de localización geográfica, no se incluyeron como candidatas para el modelo dado que no se asocian a nivel de individuo. Sin embargo fueron utilizadas en el análisis de los diferentes perfiles de default a un nivel de mayor agregación.

Basándose en una ecuación propuesta para estimar la rentabilidad esperada de las solicitudes que se aprueben (que incluye los niveles de gasto esperados) se efectuaron supuestos acerca del resto de las variables implicadas, fijándose distintos puntos de corte para la probabilidad de incumplimiento.

El resultado de la optimización permite concluir que basar la política de aprobaciones exclusivamente en un análisis discriminante es menos conveniente para la institución, en comparación con hacerlo sobre la maximización del modelo ampliado<sup>7</sup>. Esto se debe a que la segunda alternativa supone un importante incremento de las tasas de aprobación, atenuando el elevado costo de oportunidad que se genera con la primera.

## **2. “Equifax Score” (Equifax, 2002)**

La documentación que respalda el modelo de Scoring crediticio de Equifax es uno de los principales referentes para este trabajo, debido a que se trata de un modelo desarrollado a partir de una base de datos del mismo origen que la que se dispone en esta oportunidad.

El objetivo principal en aquella ocasión era derivar un modelo estadístico que sirviera a los afiliados de la mencionada institución, pertenecientes a todos los sectores de actividad, como una herramienta para ordenar clientes de modo objetivo, en función del riesgo de incumplimiento en un período de entre seis y doce meses.

El desarrollo se hizo sobre una muestra de personas físicas entre las fichas existentes a Febrero del año 2000, que tomaba la información histórica vigente a ese momento para caracterizar a los individuos, mientras analizaba sus comportamientos a un período de seis meses, partiendo desde Setiembre hasta Febrero de 2001.

---

<sup>7</sup> Modelo original condicionado por la probabilidad de ser usuario de tarjeta de crédito, incluyendo la estimación de la rentabilidad esperada en caso de que se apruebe la solicitud.

De la muestra aleatoria se excluyeron los casos de individuos que no presentaban solicitudes de información por parte de ningún afiliado, para lograr una muestra más representativa de las personas que se encontraban activas en el mercado de crédito en aquel momento. En la muestra final se observaba una proporción de 8.9% de comportamientos “malos” en el total.

La información histórica a la que se recurrió para buscar variables explicativas del comportamiento incluye datos demográficos, estadísticas de solicitudes de información por parte de afiliados, información de operaciones incumplidas y canceladas con atraso, así como de cheques devueltos por falta de fondos y cuentas clausuradas o suspendidas por el Banco Central del Uruguay. Asimismo se contaba con información relativa a las empresas que aportaron los datos anteriores.

La variable que se pretende describir en este modelo es binaria, y el comportamiento “bueno” o “malo” se determina por la observación de por lo menos uno de los siguientes eventos en los períodos de desempeño: registro de un incumplimiento o una cancelación con atraso, registro de un cheque devuelto por falta de fondos, o de una cuenta clausurada o suspendida por el BCU.

La variable dependiente del modelo es binaria, por lo que se aplicó una regresión logística sobre las variables explicativas disponibles.

El modelo resultante consta de 12 variables explicativas con sus respectivos parámetros, más una constante definiéndose como atributo de interés la observación del comportamiento “bueno”<sup>8</sup>:

- Edad del solicitante (+)
- Dummy: sí o no (1 ó 0) tiene operaciones incumplidas, cheques devueltos por falta de fondos, resoluciones de clausura o suspensión de cuentas corrientes (-)
- Cantidad de solicitudes anteriores a las del último mes (-)
- Meses de la solicitud más antigua (+)
- Dummy: sí o no (1 ó 0) tuvo extravíos de documento de identidad en los últimos 12 meses (-)
- Cantidad de afiliados que le registraron operaciones incumplidas en los últimos 12 meses (-)

---

<sup>8</sup> Entre paréntesis figura el signo asociado al parámetro de cada variable.

- Saldo incumplidor total acumulado en los últimos 3 meses (-)
- Meses desde la compra de la última operación incumplida (+)
- Meses desde la compra de la última operación cancelada (+)
- Cantidad de clausuras o suspensiones de cuenta corriente (-)
- Cantidad de empresas afiliadas que han aportado información (-)
- Interacción entre las variables Edad y Dummy de operaciones incumplidas (-)

Los signos de los coeficientes son coherentes con lo que se podría prever. Algunas variables reflejan el comportamiento crediticio histórico, y otras las características del individuo. La variable “extravío de cédula de identidad” parece estar sirviendo como indicador de algún rasgo de la personalidad del individuo, principalmente al considerarse la ausencia de otras variables más concretas relacionadas a la personalidad entre la información disponible a priori.

Entre los resultados de la validación se destacan los valores que tomó el estadístico KS<sup>9</sup> (Kolmogorov-Smirnov), el grado de asociación entre las probabilidades predichas y las respuestas observadas, la captación de “malos” en los rangos de más bajo scoring y la tasa de “malos” por intervalo de score:

- KS de la muestra de validación: 37.8
- % de parejas concordantes<sup>10</sup>: 75.1%
- El 20% de individuos con score más bajo acumula el 51.5% de los “malos” de la muestra.
- La tasa de “malos” es monótona creciente con el score.

---

<sup>9</sup> En el capítulo V de Análisis de Performance de los modelos se incluye una interpretación del estadístico.

<sup>10</sup> De todas las combinaciones de parejas de un “bueno” y un “malo”, se calcula el porcentaje que cumple la condición de que el “bueno” tenga mayor scoring que el “malo”.

## IV. Modelo de Análisis

### *1. Definición de la variable dependiente y el periodo de observación*

Cuando se trata de estimar el riesgo de incumplimiento de individuos que solicitan un préstamo, es habitual definir una variable dependiente binaria que toma valor 0 ó 1 según el comportamiento haya sido “bueno” o “malo” en un período de interés determinado. Para estimarla se utiliza un conjunto de variables independientes que se espera contengan la información necesaria para predecir el comportamiento.

En este trabajo la clasificación del comportamiento de los solicitantes de crédito como “bueno” o “malo” se realiza en base a la presencia o no de registros de operaciones incumplidas dentro del período de interés.

Dado el objetivo de este trabajo, se considerará como “malo” aquel individuo que presente al menos un registro de incumplimiento, presentado por una institución financiera bancaria o no bancaria, y que lo haya hecho dentro del período de 12 meses desde la solicitud de un crédito

Para la elección del período de observación se siguieron dos criterios, en primer lugar se buscó que el mismo estuviera lo más alejado posible del periodo de la crisis financiera de 2002, de forma de aislar efectos sistémicos<sup>11</sup>; por otra parte se consideró que la proximidad en el tiempo era fundamental a fin de realizar predicciones para el futuro cercano.

Se seleccionó como período de observación el que comienza el 1º de setiembre de 2005 y finaliza el 31 de agosto de 2006, período en el cual se comprobó que el registro de incumplidores no presentó anomalías, al tiempo que el porcentaje de créditos vencidos sobre el total del Sistema Bancario se mantuvo estable<sup>12</sup>.

---

<sup>11</sup> Como consecuencia, no se incorporarán variables de entorno al modelo, dado que se asume que las mismas permanecieron constantes en el período de análisis.

<sup>12</sup> En la Sección II.2 del Anexo se presentan gráficos de estos indicadores según estadísticas del Banco Central del Uruguay.

## 2. *Diseño de la muestra para desarrollo.*

La muestra está conformada por personas que en el período comprendido entre el 1° de Mayo de 2005 al 31 de agosto de 2005 presentaron consultas de su informe crediticio en Clearing de Informes (CDI) por parte de alguna institución bancaria, u otras instituciones financieras no bancarias que se consideró abarcan un segmento de mercado similar al de los bancos<sup>13</sup>. Como consecuencia se estarán evaluando comportamientos a lo largo de los doce meses siguientes a la primera consulta del informe dentro del período de selección muestral definido anteriormente<sup>14</sup>.

La muestra inicial de personas cumpliendo estas condiciones incluye 104.339 casos. La composición en términos del tipo de institución que generó la primera consulta dentro del período de selección es la siguiente:

Tabla 1 Composición de la muestra inicial por tipo de Institución que generó las consultas

<b>Tipo de Institución</b>	<b>Frecuencia</b>	<b>%</b>
Bancos	59.228	56,76%
Financieras no bancarias	45.111	43,24%
<b>Total</b>	<b>104.339</b>	<b>100,00%</b>

Tal como fueron definidas previamente, las frecuencias para los atributos “bueno” y “malo” de la variable dependiente en la muestra se distribuyen de esta manera:

Tabla 2 Composición de la muestra inicial según variable dependiente

<b>V.Dependiente</b>	<b>Frecuencia</b>	<b>%</b>
BUENO	97.793	93,73%
MALO	6.546	6,27%
<b>Total</b>	<b>104.339</b>	<b>100,00%</b>

Los 104.339 casos incluyen solicitudes de crédito que fueron aprobadas o rechazadas por las instituciones en base al análisis de la información contenida en el reporte

---

<sup>13</sup> Se tuvo en cuenta que un eventual incremento del crédito en el futuro próximo implicará la necesaria ampliación del segmento de mercado que captaban los bancos en 2005-2006.

<sup>14</sup> Nuevamente se corroboró que en este período las consultas desde el Sector Financiero no presentarían un comportamiento atípico: ver Sección II.2 del Anexo.

crediticio. La composición de la muestra entre aprobados y rechazados, estimada según las reglas de cada institución<sup>15</sup> (aplicadas a la fecha de la consulta) es la siguiente:

Tabla 3 Resultado de las solicitudes de crédito (muestra total)

<b>Respuesta a las solicitudes</b>	<b>Frecuencia</b>	<b>% malos</b>
Aprobados	81782	4,77%
Rechazados	22557	11,72%
<b>Total</b>	<b>104.339</b>	<b>6,27%</b>

El hecho de que un individuo quede incluido entre los “Rechazados” no implica que no haya logrado operar con alguna otra institución dentro del sistema financiero en el período de interés. El status de “Aprobado” o “Rechazado” está discriminando dentro de la muestra a los individuos que pasaron todos los filtros necesarios para operar en el segmento particular que se está analizando.

Entre los “Rechazados” eventualmente podrán encontrarse individuos que desistieron de solicitar el crédito, o que acudieron a otras instituciones más flexibles en su política crediticia.

Por una razón de tipo metodológico es necesario excluir el segmento de los “Rechazados” de la muestra de desarrollo: no se puede discriminar con certeza en este grupo a los individuos que desistieron de aquellos que perseveraron y consiguieron el crédito en otra institución. Se trata de un caso de **censura en la variable dependiente**, con el agregado de que no se puede determinar cuáles son las observaciones que están censuradas.

El problema de la censura es recurrente cuando se analiza el comportamiento crediticio de los individuos. Aunque se estuviera trabajando con una base de datos formada por clientes de una única institución, siempre existen “rechazados” a los que es necesario asignar un comportamiento. Las alternativas de solución más comunes son: 1) asignar un comportamiento “malo” a todos los rechazados, 2) excluirlos de la muestra, o 3)

---

<sup>15</sup> Estas reglas son pre-definidas por cada institución de forma de automatizar la interpretación del reporte crediticio de CDI.

inferir el comportamiento en base a técnicas de *Reject Inference*<sup>16</sup>. En este caso, optamos por la segunda opción y la muestra quedó conformada de la siguiente manera:

Tabla 4 Composición muestral post-exclusión de rechazados

<b>Tipo de Institución</b>	<b>Frecuencia</b>	<b>%</b>
Bancos	46.079	56,34%
Financieras no bancarias	35.703	43,66%
<b>Total</b>	<b>81.782</b>	<b>100,00%</b>

Por tanto, estaremos considerando una muestra compuesta por solicitantes de créditos que fueron a priori aceptados por las instituciones: luego de atravesar los filtros aplicados por las mismas puede asumirse que se trata de individuos sujetos de crédito.

El sesgo presente en la muestra surge, en primer lugar, debido a que ciertas características referidas al nivel de ingreso o situación laboral de las personas definen la decisión de solicitar el crédito en el tipo de instituciones que se analizan; por otra parte, una vez que el individuo solicita el crédito, el proceso normal implica que la institución aplique un primer filtro basado en características que también se asocian a la capacidad de pago, efectivizando luego la consulta del informe crediticio. A partir de los datos recogidos allí, se toma la decisión final de aprobación/rechazo de la solicitud.

En el caso del presente trabajo, dada la información con la que se cuenta, solo se podrán evaluar los comportamientos de los aprobados y excluir de la muestra, tal como se mencionó anteriormente, al grupo de rechazados.

### **Tratamiento de valores faltantes.**

A continuación se describen las soluciones encontradas al problema de valores faltantes para algunas variables. Las variables con este problema dentro de la muestra son las relativas a datos personales y a localización de las personas. En el caso de los datos personales se tomó en consideración que las tres variables (Edad, Sexo y Estado Civil) comparten un alto porcentaje de los datos faltantes: la ausencia de información en Edad suele acompañarse de valores faltantes en las otras dos variables, y algo similar ocurre con el Sexo<sup>17</sup>.

---

<sup>16</sup> En la sección II.1 del Anexo se explican en detalle las ventajas y desventajas de cada una de las técnicas.

<sup>17</sup> La explicación para esta situación está dada por la costumbre en relación al llenado de formularios al momento de las solicitudes. Las dos situaciones más comunes en la práctica son: o se completa el

En la sección II del Anexo se discuten las diversas estrategias a adoptar ante un problema de valores faltantes en una variable explicativa. De allí se desprende la necesidad de determinar si los datos faltantes forman un conjunto aleatorio de la muestra, lo cual en el presente trabajo se corroboró mediante la comparación de tasas de “malos” para ambos grupos, y de las diferencias en las distribuciones de otras variables relevantes. A raíz de este análisis se determinó la exclusión de 16.673 casos de la muestra de aprobados.

En el vector de residencia los valores faltantes pueden inferirse en base a datos contenidos en otras variables. Con el objetivo de llegar a una clasificación que discrimine el departamento de residencia de la persona para toda la muestra (y el barrio, en caso de los residentes en Montevideo) se fijó un criterio para completar los datos: como primer variable de inferencia se utilizó el código postal, complementándose con la característica telefónica para asignar algunos casos ambiguos. A partir de allí se logró una primera gran clasificación, donde los casos que no se identificaron totalizaron 1.630 y fueron excluidos de la muestra final.

### ***3. Descripción del marco de aplicación del modelo.***

Con el objetivo de delimitar un marco de aplicación del modelo, se analizan en esta sección las variables del informe crediticio que están influyendo en la decisión de aprobación/rechazo de las instituciones. Para ello se ha construido un cuadro comparativo de las muestras de aprobados y rechazados, que incluye una descripción estadística de las un algunas variables..

El siguiente cuadro permite concluir que la variable que más discrimina entre “aprobados” y “rechazados” es la presencia o no de incumplimientos. De hecho, todas las personas que tenían incumplimientos vigentes fueron rechazadas por los filtros aplicados en las instituciones.

---

formulario, o no se completa en absoluto. Los casos donde se llena parcialmente la información son menos frecuentes pero generalmente en estos casos se comienza por las variables más sencillas y/o que no requieren más que contar con el documento de identidad de la persona.

En el resto de las variables no se observan grandes diferencias entre las muestras, aunque sí se observa un patrón en el estado civil: los porcentajes de solteros, divorciados y viudos son más altos en el grupo de rechazados, mientras que para los casados la situación es inversa. En la variable edad se observan valores un tanto menores entre los rechazados. Estos resultados pueden estar reflejando el nivel de correlación que seguramente existe entre ambas variables y el nivel de ingreso de los individuos.

Con respecto a las consultas no se observa un patrón definido, siendo los valores medios de las variables similares para todos los grupos. Esta variable no parece estar jugando un papel importante en las reglas de aprobación y rechazo de las instituciones.

Tabla 5 Cuadro comparativo de muestras

	Tipo de solicitante	
	Aprobados	Rechazados
<b><i>Variables Demograficas</i></b>		
Sexo (porcentaje de mujeres)	51,02%	45,33%
E.Civil (porcentaje para Dummy =1)		
Casados	60,91%	57,08%
Divorciados	6,80%	9,71%
Solteros	29,43%	29,83%
Viudos	2,87%	3,37%
Edad (media muestral)	46,48	45,67
<b><i>Consultas (media muestral)</i></b>		
Cant_ ConsHist	5,75	6,24
Cantidad de afiliados fin. que registran cons.	1,91	1,60
<b><i>Incumplimientos (porcentaje para Dummy =1)</i></b>		
Dummy_IncsTotales	10,30%	95,50%
Dummy_Incs_Fin	8,77%	77,67%
<b><i>Responsabilidad</i></b>		
Dummy_C.I	13,81%	17,91%

#### ***4. Muestra de Aprobados: Análisis de las variables de caracterización***

Luego del tratamiento a los valores faltantes, la muestra quedó compuesta por 63.479 observaciones. Del total de la muestra se excluyeron en forma aleatoria 3.000 casos con

el fin de apartarlos como muestra de validación del modelo. El análisis de aquí en adelante se realiza para la muestra de desarrollo definitiva de 60.479 casos.

A continuación se describen los vectores principales de información incluidos en la base de datos final<sup>18</sup>, dentro de los que se encuentran las variables candidatas a formar parte del modelo. Se incluye además el resultado de los análisis de contingencia realizados para aquellas variables que a priori presentan correlaciones fuertes con la variable dependiente.

### Datos personales

Este vector incluye Sexo, Edad y Estado Civil del solicitante. Las frecuencias que presentan estas variables en la muestra de aprobados son las siguientes:

Tabla 5 Frecuencias y distribuciones por grupo de edad

<b>Grupo Edad</b>	<b>Frecuencia</b>	<b>%</b>
22 o menor	771	1,27%
23 - 27	3.256	5,38%
28 - 32	6.552	10,83%
33 - 37	7.794	12,89%
38 - 42	7.581	12,53%
43 - 47	7.990	13,21%
48 - 52	7.429	12,28%
53 - 57	5.697	9,42%
58 - 62	4.679	7,74%
63 - 67	3.418	5,65%
68 - 72	2.410	3,98%
73 - 77	1.680	2,78%
78 - 82	867	1,43%
83 o mayor	355	0,59%
<b>Total</b>	<b>60.479</b>	<b>100,00%</b>

Tabla 6 Frecuencias y distribuciones por Sexo

<b>Sexo</b>	<b>Frecuencia</b>	<b>%</b>
M	29.509	48,79%
F	30.970	51,21%
<b>Total</b>	<b>60.479</b>	<b>100,00%</b>

---

<sup>18</sup> Con información tomada al 30 de abril de 2005.

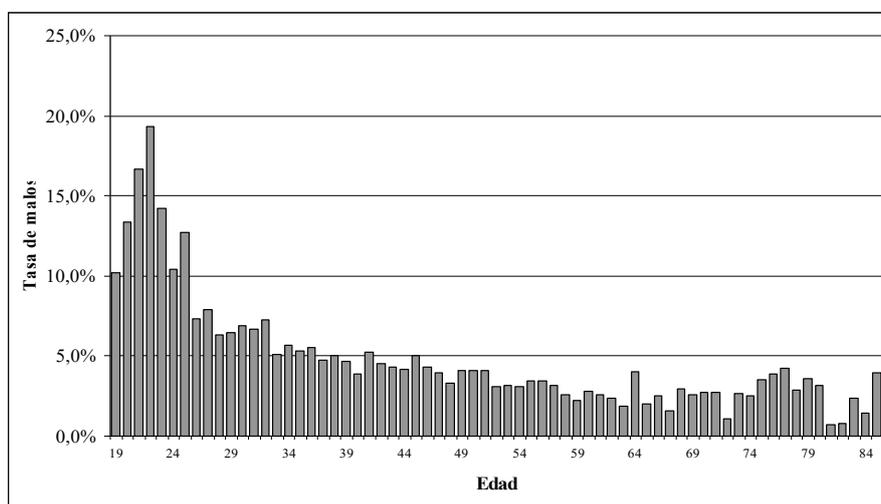
Tabla 7 Frecuencias y distribuciones por Estado Civil

Estado Civil	Frecuencia	%
C	36.838	60,91%
D	4.111	6,80%
S	17.797	29,43%
V	1.733	2,87%
<b>Total</b>	<b>60.479</b>	<b>100,00%</b>

En la muestra definitiva, un 51% de las observaciones son mujeres, la edad varía entre 19 y 106 años, con un promedio de 46. A su vez, la mayoría de las observaciones corresponden a personas casadas (61%), mientras que un 29% son solteros.

En términos de contingencia con la variable dependiente, el sexo no presenta una clara relación con la variable dependiente. La tasa de “malos” entre los hombres es de 4,8% mientras que la de las mujeres 4,5%. Con respecto a la edad, sí se encontró una fuerte asociación negativa con el riesgo. La tasa de incumplidores va decreciendo a medida que se incrementa la edad, como muestra el gráfico:

Gráfico 1 Muestra final: Tasa de malos por edad



En relación al estado civil, son los casados los que presentan la menor tasa de incumplidores (3,6%), mientras que los solteros son los más riesgosos (6,6%).

### Variables de residencia.

La distribución de individuos en la muestra según su residencia entre Montevideo e Interior es la siguiente:

Tabla 8 Muestra final: Composición por localización

<b>Localización</b>	<b>Frecuencia</b>	<b>%</b>
Montevideo	44.877	74,20%
Interior	15.602	25,80%
<b>Total</b>	<b>60.479</b>	<b>100,00%</b>

Además del departamento de residencia se contó con algunas variables que permitieron un mayor nivel de desagregación. En base a la Encuesta Continua de Hogares 2005 del Instituto Nacional de Estadística y Censos (INE), se creó una clasificación de Montevideo en 4 zonas<sup>19</sup>, definidas por el ingreso per cápita de los distintos barrios<sup>20</sup>. El objetivo fue la creación de una variable que describa el ingreso promedio de la zona de residencia del individuo. Montevideo quedó entonces clasificada en Zona 1 (barrios que presentan niveles de ingreso per cápita más elevados), Zona 2, Zona 3 y Zona 4 (niveles de ingreso más bajos).

Tabla 9 Composición muestral por categorías de ingreso<sup>21</sup> (Montevideo)

<b>Categorización</b>	<b>Frecuencia</b>	<b>%</b>	<b>Ingreso</b>
MVD_1	10.729	23,91%	\$U16.136
MVD_2	20.448	45,56%	\$U10.140
MVD_3	4.789	10,67%	\$U6.509
MVD_4	8.911	19,86%	\$U4.043
<b>Total</b>	<b>44.877</b>	<b>100,00%</b>	

El mismo procedimiento se realizó para el Interior, asignando a cada individuo el ingreso per cápita promedio de su departamento de residencia.

A continuación se presenta la correlación entre la variable que toma los ingresos per cápita (de zona y departamento) contra la variable dependiente.

<sup>19</sup> En la sección II.4 de Anexos se especifica la composición de las zonas y la determinación del Ingreso per cápita promedio por barrio de Montevideo y departamento del Interior, calculado en base a ECH 2005.

<sup>20</sup> Se manejó como alternativa el ingreso total por hogar, pero no se contó con información para considerar también el ingreso total por perceptor.

<sup>21</sup> Se considera el ingreso medio de la zona de residencia.

Ingreso p/c Zona	Tasa malos
3000 a 3999	6,82%
4000 a 4999	6,26%
5000 a 5999	5,96%
6000 a 8999	6,72%
8000 a 15999	3,75%
16000 o más	1,70%

Como se observa, la relación no es clara en los menores niveles de ingreso, pero sí en las categorías de ingreso superior. La explicación se asocia al hecho de que los niveles inferiores se corresponden con los departamentos del Interior, donde la varianza de los ingresos per cápita no es relevante. Por otra parte, puede asumirse en base a lo visto en el Marco Teórico, que la variable que más explica la probabilidad de incumplimiento no es el ingreso por sí solo, sino su vinculación con la cuota del crédito que se está solicitando<sup>22</sup>.

Por el contrario, sí se encuentran relaciones significativas al discriminar las zonas de ingreso intra Montevideo. Por este motivo se decidió la creación de variables dummy que indiquen el departamento de residencia para el Interior, y la zona de ingreso para Montevideo. El objetivo fue buscar que las dummies reflejen en el caso del Interior otros factores de idiosincrasia que puedan asociarse al riesgo, en lugar del escaso diferencial de ingresos encontrado.

El análisis de contingencias entre las variables de localización y la dependiente refleja que las Zonas 1 y 2 de Montevideo (las localidades más ricas según el ingreso per cápita) presentan una probabilidad de incumplimiento más baja que el resto. En el primer caso la diferencia es de casi 4 puntos porcentuales, mientras que en el segundo es algo inferior a 2. Por el contrario para el resto de las zonas (3, 4 y promedio del Interior) la situación es la opuesta: presentan una tasa de “malos” superior.

En el caso de los residentes en el Interior, 15 de los departamentos presentan tasas de incumplimiento mayores que el promedio. Los casos más evidentes, cuyo diferencial de tasas se aproxima a 5%, son Rivera y Artigas, mientras que Salto presenta un diferencial de aproximadamente 4 puntos porcentuales. Por el contrario en Río Negro, Treinta y Tres y San José la tasa de malos es menor que la tasa promedio.

---

<sup>22</sup> El ingreso estimado en este caso funciona como una variable proxy del patrimonio o la garantía del crédito y no como una estimación de la capacidad de reembolso.

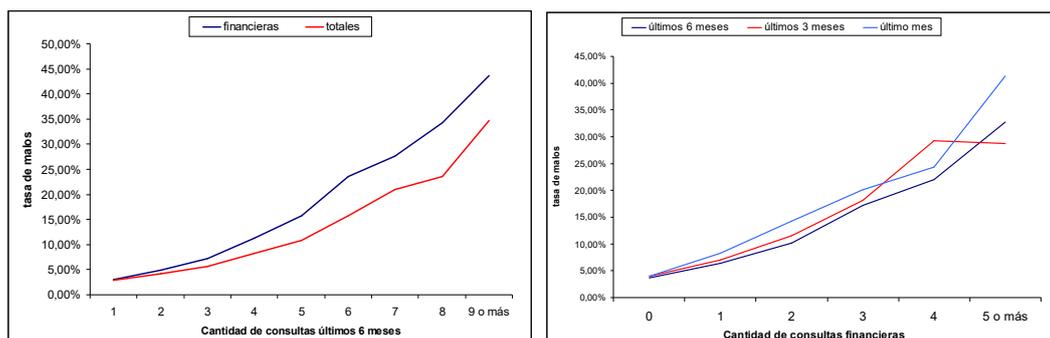
### Historial de crédito.

En este grupo de variables se incluye información acerca de las consultas realizadas al informe crediticio de la persona, incumplimientos registrados en el historial, datos acerca de las empresas que han aportado información, así como fecha de apertura de la ficha y observación de extravíos o hurtos del documento de identidad.

1. Consultas del informe crediticio (en los últimos 4 años):
  - a. Fecha de la consulta.
  - b. Información acerca de las empresas que las efectuaron.

El vector de Consultas quedó formado inicialmente por un set de variables que separan las consultas por frecuencia y sector de actividad de las empresas que las realizaron, agrupadas a su vez por períodos de tiempo que fueron definidos en base a la distancia en meses respecto de la solicitud del crédito.

El análisis de contingencias permite concluir que las solicitudes recientes al sector financiero presentan mayor correlación con el riesgo que las del resto de los sectores. Además como muestra el gráfico, a mayor proximidad en el tiempo, más fuerte afecta la cantidad de consultas a la probabilidad de incumplimiento.



Las variables que presentan asociaciones fuertes con la variable dependiente son:

- Cantidad de consultas históricas. Mide la cantidad de consultas que se registraron en la ficha de la persona desde la apertura de la misma hasta los 6

meses previos a la solicitud del crédito. La variable toma valores entre 0 y 191 presentando una media de 5,75.

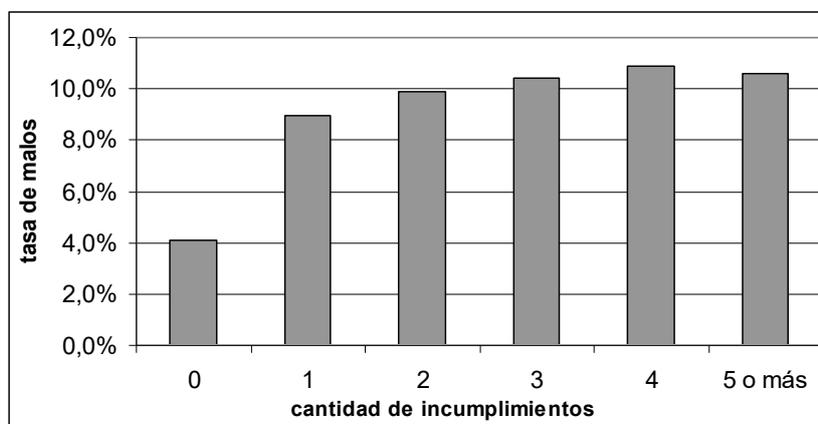
- Cantidad de consultas financieras recientes. Considera las consultas registradas en la ficha del solicitante en los últimos 6 meses previos, sin considerar las registradas en el último mes. El intervalo muestral fue (0-17), mientras que la media tomó un valor de 0,51.
  - Cantidad de consultas financieras en el último mes. El rango de variación es de 0 a 13, y la media de 0,16.
  - Cantidad de consultas del Sector no financiero en los últimos 6 meses. Presenta un mínimo muestral de 0 y un máximo de 30, con una media de 0,34.
  - Cantidad de afiliados financieros que registraron consultas. Se mide en cantidad de instituciones financieras, y presenta valores muestrales de entre 0 y 19. El promedio observado en la muestra es de 1,91. La variable presenta correlación positiva con la variable dependiente.
2. Registro de incumplimientos (vigentes y cancelados, en los últimos 10 años):
- a. fecha de registro del incumplimiento, de último pago, de contratación de la operación y de cancelación de la deuda
  - b. datos de la empresa acreedora
  - c. importe de la operación (sin intereses moratorios)
  - d. saldo adeudado
  - e. moneda
  - f. plazo de la operación

Para analizar los montos en caso de que se presente más de un incumplimiento, se calcularon en forma separada para moneda nacional y extranjera la suma y el promedio de la totalidad de los incumplimientos registrados en la ficha. Con el mismo fin se incluyó entre las variables candidatas un promedio de los plazos contratados para todas las operaciones incumplidas.

El sesgo que imprimen los filtros de aprobación de las instituciones determina que la variable “incumplimientos vigentes” sea constante para la muestra analizada, por lo que se trabajó con la variable “incumplimientos totales”, sin necesidad de un mayor nivel de desagregación.

El análisis de contingencia refleja que la mayoría de las variables presentan cierta vinculación con la dependiente, aunque no muy fuerte. El caso particular de la cantidad de incumplimientos se muestra a continuación:

Gráfico 2 Tasa de “malos” por cantidad de incumplimientos históricos en la ficha



En el gráfico se observa un salto en la proporción de “malos” cuando se analizan fichas con 0 contra 1 incumplimiento. Por este motivo se crearon variables dummy que indican la presencia de al menos 1 incumplimiento en la ficha:

- Dummy Incumplimientos Totales. La variable toma valores iguales a 1 en los casos en que existe al menos un registro de incumplimientos a la fecha de la consulta. El 10% de la muestra presenta al menos un incumplimiento a esa fecha, con una proporción de “malos” de 9,5%.
- Dummy Incumplimientos Financieros. Indicador de si la persona registra en su historial uno o mas incumplimientos con el sector financiero. En la muestra se encontraron 5.303 fichas (8,7%) con valor 1 en esta variable, y el grupo presenta una tasa de “malos” 5 puntos porcentuales por encima de los individuos sin incumplimientos con el sector.

Las correlaciones analizadas en término de montos o antigüedad de los incumplimientos no parecen explicar a la variable dependiente. A continuación se presentan gráficamente los cruces entre las variables “montos totales adeudados” y “antigüedad del último incumplimiento” contra la tasa de “malos”.

Gráfico 3 Tasa de “malos” por montos totales adeudados en la ficha (histórico)

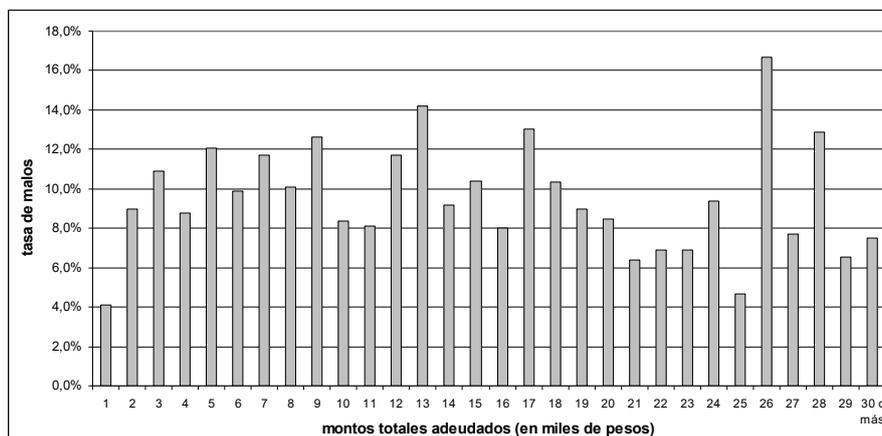
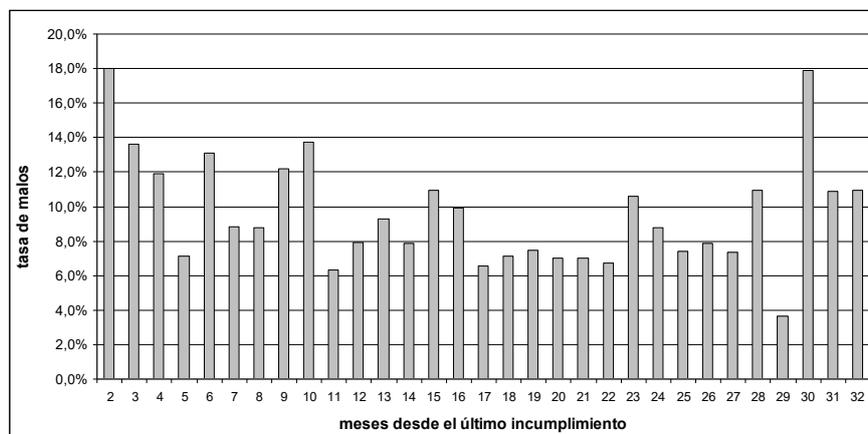
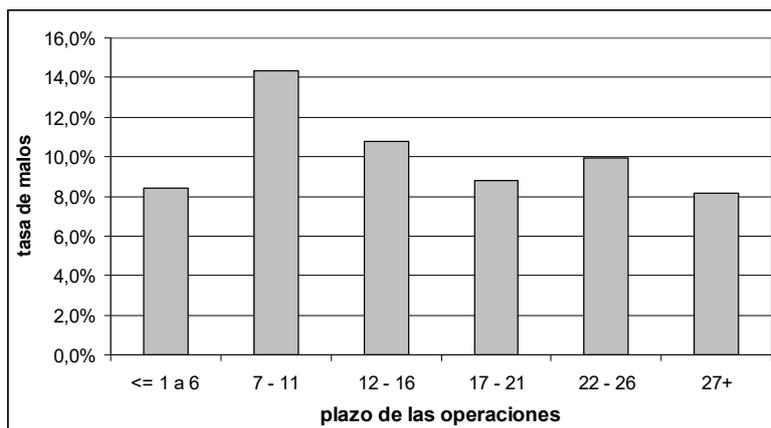


Gráfico 4 Tasa de “malos” según antigüedad del último incumplimiento registrado (en meses)



En cuanto al plazo de contratación de las operaciones que se incumplieron en el pasado, se observa una tendencia decreciente en la proporción de “malos” a partir de la segunda categoría (plazos mayores a 6 meses):

Gráfico 5 Tasa de “malos” según el plazo de las operaciones incumplidas en el pasado



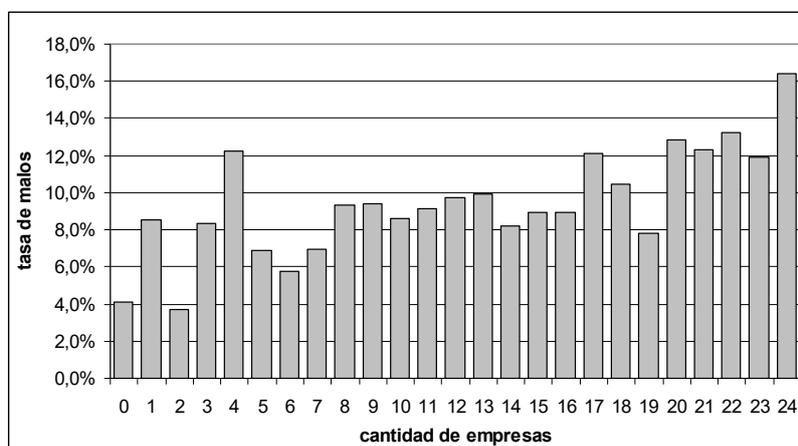
3. Empresas que aportaron información:

a. sector de actividad

Esta variable agrupa información sobre las empresas afiliadas que aportaron datos a la ficha desde su apertura. El vector de “Empresas que aportaron información” dio lugar a cinco variables que acumulan la totalidad de los casos según el sector de actividad: Sector Bancario, Financiero no Bancario, Servicios Públicos, Servicios No Públicos y Comercios.

La variable tomada en totales muestra una correlación positiva con el riesgo, la cual también se confirma al nivel de mayor desagregación. El gráfico muestra la proporción de “malos” creciente según la cantidad de empresas que aportaron datos a la ficha de la persona:

Gráfico 6 Cantidad de empresas que aportaron información

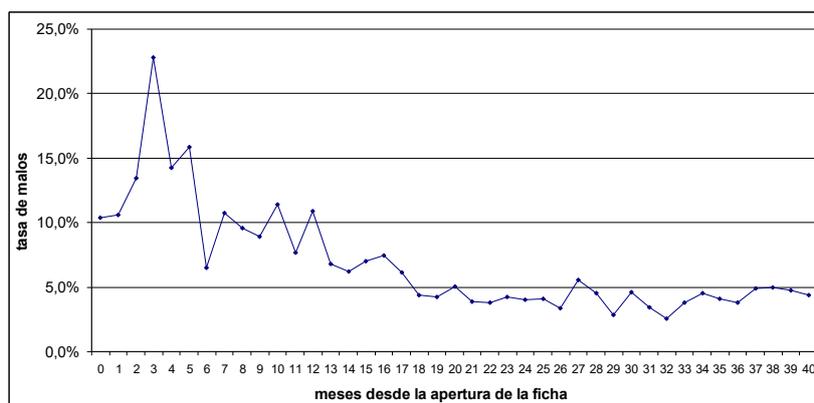


Dado que esta variable está muy correlacionada con la cantidad de afiliados que consultaron la ficha, se determinó su exclusión de entre las candidatas al modelo final.

4. Fecha de apertura de la ficha.

Esta variable presenta a priori una asociación negativa con el riesgo, tal como se aprecia en el siguiente gráfico.

Gráfico 7 Tasa de “malos” por antigüedad de la ficha



La tendencia decreciente se inicia con tasas bajas de incumplidores para niveles de hasta 3 meses de antigüedad de la ficha, donde aún no se ha tenido oportunidad de registrar incumplimientos. La variable presenta una correlación moderada con la variable edad.

5. Observaciones en la ficha:

- a. Hurto de documento
- b. Extravíos de documento

Basándonos en la experiencia del trabajo de Equifax (ver Antecedentes) estas variables se manejan en frecuencias totales para dos períodos de interés: últimos 12 meses, y total histórico, resultando significativa:

- Dummy Extravíos de C.I. Indica si el solicitante presenta al menos un registro de extravío de cédula de identidad desde la apertura de la ficha. En la muestra se encontró un total de 8.350 observaciones dentro de esta categoría, presentando

una proporción de “malos” de 6,5% (superior en casi dos puntos al promedio muestral).

### **Transformaciones de las variables candidatas.**

El análisis de las variables referidas al historial crediticio y observaciones en la ficha, se realizó tomando en cuenta que se parte de una muestra definitiva de 60.479 observaciones, donde la presencia de valores faltantes en las variables no se debe a información incompleta, sino a un significado específico que es necesario interpretar correctamente. Por este motivo, y por la necesidad de captar nuevas relaciones o corregir variables con valores atípicos, es que se realizaron algunas transformaciones sobre las variables originales. Las principales se detallan a continuación:

- Fechas relacionadas al registro de operaciones incumplidas<sup>23</sup>. El tratamiento de estas variables implicó la transformación de las mismas a su equivalente en “meses desde la ocurrencia del evento”. El rango de variación de las mismas va de 0 a 120 meses.
- Plazo de las operaciones. Atendiendo al análisis de contingencia, se determinó la transformación de la variable de manera tal que los valores nulos (personas que no registran incumplimientos) se aproximaran a los de individuos con incumplimientos en el pasado pero en operaciones de muy largo plazo. Lo anterior se logró completando los valores nulos con el valor máximo muestral de la variable.
- Fidelidad. A través del cociente entre las variables “meses desde apertura de la ficha” y “cantidad de afiliados distintos del sector financiero que consultaron la ficha” se construyó un indicador del tipo de relación que los individuos tienen con las instituciones financieras. El valor resultante, medido en meses, puede interpretarse como la cantidad de meses que cada individuo le ha asignado exclusivamente a cada institución. La media muestral para esta variable es 19,5 meses y el recorrido es de 0 a 41.

---

<sup>23</sup> Fecha de registro del incumplimiento, fecha del último pago efectuado previo al registro, fecha de cancelación de la deuda, fecha de contratación de la operación incumplida.

- Porcentaje de los incumplimientos originados en el período de crisis. El indicador refleja el porcentaje de incumplimientos registrados en la crisis sobre el total de incumplimientos históricos. “Dummy\_IncsCrisis” adquiere valor 1 cuando el porcentaje mencionado equivale a 100%. La variable creada presenta 4.134 observaciones con valor 1 (6,8% del total).
- Interacción entre “Dummy Incumplimientos Financieros” y “Dummy Incumplimientos Crisis”. Esta interacción pretende diferenciar a los individuos en función de si presentan algún incumplimiento financiero fuera del período de crisis, caso en el cual toma valor 0, mientras que en caso contrario el indicador adquiere valor 1. El porcentaje de casos en esta situación es de 5,9%.
- Interacción entre “Dummy Incumplimientos Totales” y “Edad”, se incluyó como candidata tomando como referencia el modelo de Equifax. La variable busca discriminar a aquellos individuos que incumplieron siendo que pertenecen a grupos de edades avanzadas<sup>24</sup>.

### ***5. Definición de la técnica estadística.***

En base al análisis de las técnicas de Credit Scoring disponibles<sup>25</sup> se concluye que según el objetivo de este trabajo, es apropiada la utilización de modelos de variable dependiente cualitativa del tipo Logit/Probit.

La aplicación de las técnicas de variable dependiente discreta permite interpretar las estimaciones de la variable dependiente como una probabilidad, ya que su rango de variación se mantiene entre 0 y 1. Asimismo, el análisis a realizar a posteriori de obtenido el modelo final se enriquece con la posibilidad de interpretar las relaciones existentes entre las variables explicativas y la probabilidad de incumplimiento, lo que no es posible a través de otras técnicas como el Análisis Discriminante o las Redes Neuronales.

---

<sup>24</sup> Los registros de incumplimientos presentan una vigencia máxima de entre 5 y 10 años (ver Marco Teórico: “La información disponible en Uruguay”).

<sup>25</sup> Ver Sección II.1 del Anexo.

Otra característica que se consideró a la hora de definir la técnica es que los objetivos del proyecto exigen que el resultado del modelo de lugar a una clasificación continua de los casos, asociada a una probabilidad de incumplimiento.

Luego de descartar la posibilidad de utilizar un Modelo de Probabilidad Lineal, dados los problemas metodológicos conocidos de esta técnica y explicitados en la sección II del Anexo, se pasó a definir la técnica entre las dos alternativas restantes, un modelo Logit o un Probit. Dado que los resultados de aplicar estas dos técnicas en la práctica no suelen diferir en gran medida, se tomó la decisión de utilizar una Regresión Logística, para tomar ventaja de la mayor simpleza en el cálculo de probabilidades.

### ***6. Regularidades empíricas a testear***

Dado el tipo de información que se puede extraer de las variables ya presentadas, es de esperar que mediante una aproximación del primer factor del **esquema de las 5C del análisis crediticio** pueda construirse un modelo significativo de predicción de la probabilidad de incumplimiento.

Tal como se desarrolló en el marco teórico de la investigación, **la voluntad de pago** es uno de los elementos que la experiencia sugiere como determinante principal del riesgo, por lo que su correcta captación debería poder discriminar más allá de lo que las instituciones financieras consiguen con la información que recaban al momento de la solicitud. Además, el diseño muestral permite contar con una cantidad de observaciones lo suficientemente grande como para asegurar la significación del modelo.

Por otra parte, es de esperar que elementos determinantes de **la capacidad de pago**, como la relación cuota ingreso, ya estén considerados en un filtro previo aplicado por las propias instituciones financieras. El hecho de que se registre una consulta del reporte crediticio tiene un costo que justifica la precalificación de solicitantes en función de su cumplimiento con las condiciones fijadas por las entidades financieras.

La voluntad de pago del solicitante se explica según la teoría en base a características personales relacionadas con la aversión al riesgo, elementos que hacen al grado de

responsabilidad de la persona e información que refleje la moralidad y la importancia que le asigna a la reputación.

En línea con lo ya expresado en el marco teórico, es de esperar que la **edad** sea una variable significativa y negativamente correlacionada con la probabilidad de incumplimiento. De la misma manera, se espera que el **estado civil** refleje principalmente las diferencias de estabilidad y seguridad financiera que existen entre individuos casados, solteros y divorciados y que los primeros resulten menos riesgosos que los últimos dos grupos. El caso de los viudos no es claro, ya que es una contingencia correlacionada con la edad.

Si bien el **sexo** suele incluirse como una de las variables candidatas a discriminar el riesgo a priori entre individuos, no se espera un coeficiente elevado, ya que en ninguno de los antecedentes de esta investigación se encontró una asociación importante con el riesgo una vez que se tomaron en consideración otras variables en los modelos.

La **localización geográfica** de la persona es una variable que puede captar factores como el ingreso, así como otros factores de idiosincrasia. Para esta variable es de esperar un comportamiento diferencial en primer lugar entre los residentes en Montevideo y los del Interior. Los primeros se pueden asociar a una mayor experiencia en el mercado de crédito, una “cultura crediticia” mas arraigada (uso frecuente de tarjetas de crédito). Por estos motivos se espera que los residentes en Montevideo tengan asociado un menor nivel de riesgo, aunque también existen elementos atenuantes de esto como puede ser el mayor valor depositado en la reputación, que suele darse en localidades más pequeñas como las que caracterizan al interior del país.

De la misma manera, las diferencias intra Montevideo (captadas a través de un diferencial de ingreso per capita promedio de la zona de residencia) deberían verse cristalizadas a través de una asociación mayor ingreso – menor riesgo. En el interior del país no se espera una alta significación del diferencial de ingresos entre departamentos, debido principalmente a que la varianza encontrada en este indicador no fue de gran magnitud.

Dentro del historial de comportamientos previos en el mercado de crédito, y en relación al indicador de “**fidelidad**”, la teoría indica una menor tendencia al incumplimiento de individuos que acostumbran a mantener vínculos fuertes y estables con las instituciones, por lo cual el coeficiente debería ser significativo y de signo negativo para corroborar la hipótesis.

En cuanto a la existencia de **operaciones incumplidas** es necesario reiterar que la muestra no contiene casos de personas con incumplimientos vigentes, ya que todos estos fueron “rechazados” por los filtros de las instituciones. En cambio, sí se encuentran diferenciados dos grupos de personas dados por la presencia o no de **incumplimientos cancelados con atraso**. Esta variable actúa como indicador de la integridad del solicitante, aunque es necesario considerarla en términos relativos: no debe analizarse de la misma manera una situación de incumplimiento generada en periodo de crisis, donde la frecuencia de estos eventos es más alta e influenciada por factores externos, que en una situación normal, donde juega más la propia voluntad de pago.

Asimismo, no se espera una relación lineal entre la cantidad de incumplimientos y el riesgo: los factores psicológicos están más vinculados al **estigma del primer incumplimiento**, donde lo que se tiene para perder es mucho más en términos de reputación y consecuencias directas (por ejemplo sobre el acceso a futuros créditos). Por el mismo motivo no hay razones para esperar una relación clara entre el monto de las operaciones incumplidas y la probabilidad de incumplimiento en este tipo de créditos. En cambio, sí puede suponerse que la existencia de incumplimientos con el sector financiero, por tratarse de productos de similares características, podría elevar el riesgo.

Los incumplimientos deben estudiarse en conjunto con la **etapa del ciclo vital** en que se encuentra el solicitante. Es común que en la primera etapa del ciclo vital ocurran situaciones de inestabilidad que provoquen incumplimientos, pero se puede asociar con un comportamiento más anormal o riesgoso el que los incumplimientos se registren en edades más avanzadas. Este efecto se debería reflejar a través de la interacción entre la edad y la dummy que indica la presencia de incumplimientos, mediante un coeficiente positivo y significativo.

Otro signo al que se prestará la debida atención es a la existencia de **consultas recientes** reiteradas, la experiencia en este sentido indica que esto se asocia o bien a dificultades de acceso al crédito (rechazos reiterados), o a dificultades financieras que pueden determinar con alta probabilidad una situación de incumplimiento en el futuro próximo. Por lo anterior, se esperan coeficientes significativos y positivamente asociados al riesgo para estas variables.

La **duración de la vida crediticia** de la persona, entendiendo por ella el momento en que se comenzó a operar en el mercado de crédito, y reafirmada por frecuentes intervenciones en el mercado, en caso de no presentarse incumplimientos, está reflejando un comportamiento responsable y que debería relacionarse negativamente con la probabilidad de incumplimiento en operaciones futuras.

Finalmente se utilizará la variable “**extravío de cédula de identidad**” como un indicador adicional de la responsabilidad del solicitante, esperándose para esta variable un signo positivo, aunque no se pueden formular hipótesis acerca de su nivel de significación.

## ***7. Desarrollo del modelo.***

Una vez obtenida la muestra final se procedió a analizar las variables una a una, construyéndose tablas de contingencia contra la variable dependiente, y calculándose los estadísticos correspondientes para efectuar los tests Chi-Cuadrado y de correlación de Pearson.

Finalmente se corrieron regresiones logísticas univariadas entre cada una de las variables independientes contra la dependiente, con el objetivo de estudiar la significación de sus coeficientes. Las variables cuyos p-valores fueron inferiores a 0.25<sup>26</sup> se incluyeron como candidatas al modelo final, junto con aquellas que sin cumplir la condición, se entendió por otros motivos que era importante su inclusión.

---

<sup>26</sup> Se siguió el criterio sugerido por Hosmer y Lemeshow (Pág 95, 2000)

Una vez que se testearon todas las variables y que se seleccionaron aquellas que resultaban significativas o que se consideraron relevantes desde una perspectiva teórica, se procedió a realizar regresiones multivariadas.

La importancia de las variables que se fueron incluyendo en el modelo se testeó mediante la significación individual y la verosimilitud del modelo con y sin la variable. De la misma forma se prestó especial atención a la modificación de las tablas de clasificación para el punto de corte seleccionado<sup>27</sup>, así como a los valores de los coeficientes, comparándolos con los resultantes del análisis univariado. Asimismo se atendió a los cambios de signo observados en la misma variable o en otras incorporadas en el modelo.

Este procedimiento se realizó una y otra vez incluyendo y eliminando algunas variables, verificando y volviendo a incluir las previamente eliminadas hasta llegar a un modelo con parámetros estables.

Una vez obtenido el modelo se procedió a testear la linealidad de las variables continuas incluidas en el mismo. La técnica elegida fue la de polinomios fraccionales (Royston y Altman, 1994) usando el programa Stata. A través de estas técnicas se sugirieron transformaciones a dos variables: edad y cantidad de consultas históricas. Con respecto a la edad la sugerencia fue la de aplicar la transformación:  $Edad^2$ , e incluirla en el modelo adicionalmente a la variable Edad original.

Las consultas históricas fueron sustituidas por:  $1 / (1 + ConsHist)^{1/2}$ . La inclusión de ambas transformaciones mejoró la verosimilitud del modelo, por lo que se decidió su incorporación definitiva.

Luego de llegar a un modelo que contiene todas las variables relevantes se probaron interacciones entre las mismas, de forma de verificar si alguna, siendo estadísticamente significativa, mejoraba la verosimilitud del modelo.

---

<sup>27</sup> En el capítulo V de Análisis de Performance de los modelos se explica en detalle la selección del punto de corte en  $p=0,046$ .

Al llegar a esta instancia se procedió a testear la existencia de multicolinealidad severa de los modelos resultantes<sup>28</sup>, que luego de descartada, dio lugar a la consideración de dos modelos finales. Los mismos difieren entre sí en la variable que incorpora los ingresos per cápita promedio, así como en la modalidad de inclusión de los departamentos y las zonas de residencia de los individuos.

Dado que solo difieren en la inclusión de la variable relativa al ingreso, la consideración de los dos modelos como candidatos implica la verificación del aporte de la variable ingreso per cápita para discriminar a nivel de los departamentos, mas allá de lo que logran explicar las diferencias idiosincrásicas.

---

<sup>28</sup> Ver salida del diagnóstico de multicolinealidad de SPSS en Sección III.1 del Anexo.

## 8. Modelos candidatos<sup>29</sup>.

**Modelo I**

Variables	B	Sig.	Exp(B)	95.0% C.I.for EXP(B)	
				Inferior	Superior
Sexo	-0,0927	0,0236	0,9115	0,8412	0,9876
Edad	-0,0771	0,0000	0,9258	0,9079	0,9440
Transf_Edad	0,0005	0,0000	1,0005	1,0003	1,0007
DummyCasado	-0,5379	0,0000	0,5840	0,4549	0,7496
DummyDivorciado	-0,1469	0,2997	0,8633	0,6540	1,1397
DummySoltero	-0,4083	0,0025	0,6648	0,5099	0,8666
MVD_1	-1,2153	0,0000	0,2966	0,2449	0,3593
MVD_2	-0,5438	0,0000	0,5806	0,5045	0,6681
MVD_4	0,0250	0,7384	1,0253	0,8854	1,1873
DURAZNO	-0,4216	0,1789	0,6560	0,3548	1,2131
ARTIGAS	0,4350	0,0851	1,5449	0,9416	2,5349
CERROLARGO	-0,2766	0,4462	0,7584	0,3723	1,5449
TACUAREMBO	0,1615	0,5753	1,1753	0,6679	2,0682
RIONEGRO	-0,5956	0,1071	0,5512	0,2671	1,1376
RIVERA	0,4130	0,1538	1,5114	0,8568	2,6662
TREINTAYTRES	-0,3421	0,3309	0,7103	0,3564	1,4155
SALTO	0,4484	0,0065	1,5658	1,1334	2,1632
COLONIA	0,0448	0,8124	1,0458	0,7226	1,5135
LAVALLEJA	0,0530	0,8119	1,0544	0,6816	1,6310
PAYSANDU	0,1986	0,1827	1,2196	0,9107	1,6333
SORIANO	0,2311	0,2158	1,2600	0,8738	1,8168
SANJOSE	-0,6653	0,0003	0,5141	0,3576	0,7390
CANELONES	-0,1308	0,1020	0,8774	0,7501	1,0263
ROCHA	0,5495	0,0351	1,7324	1,0391	2,8884
FLORES	0,3629	0,3737	1,4374	0,6462	3,1977
MALDONADO	-0,0026	0,9820	0,9974	0,7985	1,2460
FLORIDA	0,2122	0,3548	1,2363	0,7888	1,9377
Transf_Cant_ConsHist	1,1500	0,0000	3,1581	2,4710	4,0363
Cant_Consfin_6m	0,2180	0,0000	1,2435	1,1985	1,2903
Cant_Consfin_1m	0,2605	0,0000	1,2976	1,2236	1,3761
Cant_Cons_SNF_6m	0,0956	0,0000	1,1003	1,0569	1,1454
Cant_afi_fin	0,2159	0,0000	1,2409	1,1946	1,2890
Fidelidad	-0,0114	0,0001	0,9887	0,9831	0,9942
Dummy_IncsTotales by Edad	0,0138	0,0000	1,0139	1,0092	1,0186
Dummy_Incs_Fin by Dummy_IncsCrisis	-0,3591	0,0004	0,6983	0,5722	0,8521
Dummy_Incs_Fin	0,2281	0,0750	1,2563	0,9773	1,6149
Dummy_ExtraviosCI	0,3103	0,0000	1,3638	1,2318	1,5099
Constante	-1,2029	0,0000	0,3003		

Si bien no todas las variables que componen el modelo final resultaron significativas (en particular algunas variables relacionadas con la localización geográfica) la significación de las mismas se analizó a nivel de bloques de atributos relativos a una misma variable.

<sup>29</sup> Las salidas completas de los modelos candidatos en SPSS se encuentran en la Sección III .2 del Anexo.

**Modelo II**

Variables	B	Sig.	Exp(B)	95.0% C.I. for EXP(B)	
				Inferior	Superior
Sexo	-0,0918	0,025	0,912	0,842	0,988
Edad	-0,0762	0,000	0,927	0,909	0,945
Transf_Edad	0,0005	0,000	1,000	1,000	1,001
DummyCasado	-0,5290	0,000	0,589	0,459	0,756
DummyDivorciado	-0,1409	0,320	0,869	0,658	1,147
DummySoltero	-0,4018	0,003	0,669	0,513	0,872
MVD_1	-0,2930	0,737	0,746	0,135	4,137
MVD_2	-0,2308	0,453	0,794	0,435	1,450
MVD_4	-0,1913	0,359	0,826	0,549	1,243
INE_Interior	-0,0001	0,245	1,000	1,000	1,000
DummyMVD by INE_Interior	0,0001	0,194	1,000	1,000	1,000
Transf_Cant_ConsHist	1,1792	0,000	3,252	2,547	4,152
Cant_Confin_6m	0,2161	0,000	1,241	1,196	1,288
Cant_Confin_1m	0,2583	0,000	1,295	1,221	1,373
Cant_Cons_SNF_6m	0,0951	0,000	1,100	1,057	1,145
Cant_afin_fin	0,2114	0,000	1,235	1,189	1,283
Fidelidad	-0,0117	0,000	0,988	0,983	0,994
Dummy_IncsTotales by Edad	0,0140	0,000	1,014	1,009	1,019
Dummy_Incs_Fin by Dummy_IncsCrisis	-0,3549	0,000	0,701	0,575	0,855
Dummy_Incs_Fin	0,2294	0,072	1,258	0,979	1,615
Dummy_ExtraviosCI	0,3107	0,000	1,364	1,233	1,510
Constante	-0,6512	0,292	0,521		

Como se aprecia en las salidas, la significación de las variables se mantiene prácticamente incambiada entre los modelos.

**9. Interpretación de los coeficientes.**

Para el cálculo de los efectos parciales se consideró al individuo “típico” de la muestra, tomándose como valores de referencia para las variables continuas la media muestral, y para las variables categóricas la moda.

De esta forma, el individuo representativo se caracteriza por ser de sexo femenino, de 46 años de edad, casado y residente en la zona 2 de Montevideo; presenta no más de una consulta con financieros en el último semestre y ningún incumplimiento en su historial crediticio, así como tampoco extravíos de su cedula de identidad. La probabilidad de incumplimiento estimada para este individuo característico es de 1,95%.

### Efectos parciales y elasticidades.

El análisis en esta sección se desarrolla para el modelo 1, explicándose luego los resultados para las variantes implicadas en el segundo modelo.

En primer lugar se consideran los cambios en la probabilidad de incumplimiento del individuo cuando son modificadas algunas de las **variables demográficas**. De acuerdo a las estimaciones, las mujeres poseen un riesgo de incumplimiento casi igual que el hombre: dados los valores del individuo característico, la **mujer** es solamente 0.19% menos riesgosa que el hombre. La significación de esta variable ha determinado su inclusión en el modelo, pero se confirma la hipótesis de que el Sexo no es una variable que aporte en gran medida a la explicación de la probabilidad de incumplimiento.

En referencia a la **edad** del prestatario, en concordancia con el análisis estadístico previo y las hipótesis formuladas, se confirma que las edades mayores se corresponden con una menor probabilidad de incumplimiento. Particularmente, para el individuo característico, el efecto marginal asociado a un incremento en la edad es una reducción de la probabilidad de aproximadamente 0,06%.

En cuanto al **estado civil** del solicitante, tal como se esperaba, los casados representan el grupo menos riesgoso, presentando en el individuo medio un riesgo estimado de 1,35 puntos porcentuales menos que el grupo de referencia, los viudos, estado civil de mayor riesgo en la muestra.

Variables	B	Sig.	Exp(B)	95.0% C.I.for EXP(B)		Efecto parcial
				Inferior	Superior	
Sexo	-0,0927	0,0236	0,9115	0,8412	0,9876	-0,19%
Edad	-0,0771	0,0000	0,9258	0,9079	0,9440	-0,06%
Transf_Edad	0,0005	0,0000	1,0005	1,0003	1,0007	
DummyCasado	-0,5379	0,0000	0,5840	0,4549	0,7496	-1,35%
DummyDivorciado	-0,1469	0,2997	0,8633	0,6540	1,1397	-0,44%
DummySoltero	-0,4083	0,0025	0,6648	0,5099	0,8666	-1,08%

Que el individuo haya tenido incumplimientos anteriores (cualquiera sea el sector con el que operó) es un factor que atenúa del efecto positivo que posee la edad respecto a la probabilidad de incumplimiento:

Dummy IncsAbril by Edad	0,0138	0,0000	1,0139	1,0092	1,0186	1,69%
-------------------------	--------	--------	--------	--------	--------	-------

Por su parte, la interpretación de los coeficientes asociados a la **localidad de residencia** (cuyo valor de referencia fue tomado en Montevideo 3) revela que los solicitantes que residen en las dos zonas mas ricas de la capital (Montevideo I y II) presentan un riesgo menor, mientras que los que lo hacen en la zona IV son más riesgosos. En el Interior se ha estimado un riesgo menor que el de referencia a los departamentos de San José y Río Negro.

Variables	B	Sig.	Exp(B)	95.0% C.I.for EXP(B)		Efecto parcial
				Inferior	Superior	
MVD_1	-1,2153	0,0000	0,2966	0,2449	0,3593	-2,31%
MVD_2	-0,5438	0,0000	0,5806	0,5045	0,6681	-1,36%
MVD_4	0,0250	0,7384	1,0253	0,8854	1,1873	0,08%
DURAZNO	-0,4216	0,1789	0,6560	0,3548	1,2131	-1,12%
ARTIGAS	0,4350	0,0851	1,5449	0,9416	2,5349	1,72%
CERROLARGO	-0,2766	0,4462	0,7584	0,3723	1,5449	-0,78%
TACUAREMBO	0,1615	0,5753	1,1753	0,6679	2,0682	0,56%
RIONEGRO	-0,5956	0,1071	0,5512	0,2671	1,1376	-1,46%
RIVERA	0,4130	0,1538	1,5114	0,8568	2,6662	1,61%
TREINTAYTRES	-0,3421	0,3309	0,7103	0,3564	1,4155	-0,94%
SALTO	0,4484	0,0065	1,5658	1,1334	2,1632	1,78%
COLONIA	0,0448	0,8124	1,0458	0,7226	1,5135	0,15%
LAVALLEJA	0,0530	0,8119	1,0544	0,6816	1,6310	0,17%
PAYSANDU	0,1986	0,1827	1,2196	0,9107	1,6333	0,70%
SORIANO	0,2311	0,2158	1,2600	0,8738	1,8168	0,83%
SANJOSE	-0,6653	0,0003	0,5141	0,3576	0,7390	-1,58%
CANELONES	-0,1308	0,1020	0,8774	0,7501	1,0263	-0,39%
ROCHA	0,5495	0,0351	1,7324	1,0391	2,8884	2,29%
FLORES	0,3629	0,3737	1,4374	0,6462	3,1977	1,38%
MALDONADO	-0,0026	0,9820	0,9974	0,7985	1,2460	-0,01%
FLORIDA	0,2122	0,3548	1,2363	0,7888	1,9377	0,75%

Como se señaló anteriormente, el **historial crediticio** del solicitante fue considerado en dos grandes grupos, **consultas e incumplimientos**. En términos generales, un incremento marginal en las **consultas recientes** aumenta la probabilidad estimada de incumplimiento en un nivel cercano a los 50 puntos básicos. La **fidelidad** del solicitante, por el contrario, aparece como un atenuante del riesgo al igual que un mayor historial de consultas históricas: ambas se asocian con una buena reputación en el sistema financiero y por ende un nivel estimado de incumplimiento menor.

Variables	B	Sig.	Exp(B)	95.0% C.I.for EXP(B)		Efecto parcial
				Inferior	Superior	
Transf_Cant_ConsHist	1,1500	0,0000	3,1581	2,4710	4,0363	2,20%
Cant_Consfin_6m	0,2180	0,0000	1,2435	1,1985	1,2903	0,42%
Cant_Consfin_1m	0,2605	0,0000	1,2976	1,2236	1,3761	0,50%
Cant_Cons_SNF_6m	0,0956	0,0000	1,1003	1,0569	1,1454	0,18%
Cant_afi_fin	0,2159	0,0000	1,2409	1,1946	1,2890	0,41%
Fidelidad	-0,0114	0,0001	0,9887	0,9831	0,9942	-0,02%

Que el individuo haya caído anteriormente en **incumplimientos con el sector financiero**, aunque posteriormente los haya cancelado, es una señal que se asocia positivamente con la probabilidad estimada de default. Asimismo, frente a dos individuos iguales, el que uno de ellos haya registrado todos sus incumplimientos con el sector financiero durante la crisis, disminuye su probabilidad de incumplimiento respecto a quien haya incumplido fuera de dicho período.

Variables	B	Sig.	Exp(B)	95.0% C.I.for EXP(B)		Efecto parcial
				Inferior	Superior	
Dummy_Incs_Fin by Dummy_IncsCrisis	-0,3591	0,0004	0,6983	0,5722	0,8521	-0,24%
Dummy_Incs_Fin	0,2281	0,0750	1,2563	0,9773	1,6149	0,49%

El extravío de la cédula de identidad fue considerado como un indicador de la responsabilidad del individuo. Acorde a las hipótesis formuladas, el hecho de que el individuo representativo haya extraviado su cédula de identidad incrementa en 69 puntos básicos su probabilidad estimada de default.

Variable	B	Sig.	Exp(B)	95.0% C.I.for EXP(B)		Efecto parcial
				Inferior	Superior	
Dummy_ExtraviosCI	0,3103	0,0000	1,3638	1,2318	1,5099	0,69%

El análisis anterior aplicado al modelo 2 presenta resultados similares en términos de significación y signos de los coeficientes de las variables que ambos modelos comparten. En relación a la magnitud de los efectos, los resultados también fueron semejantes. Con respecto a la variable que distingue al modelo, ingreso per cápita promedio de la zona de residencia, para un individuo de Montevideo el cambio en el riesgo asociado a un incremento de \$U 1.000 es de  $-0,22\%$ .

**Las hipótesis que se han corroborado** en este análisis han sido las enunciadas para las variables Edad, Estado Civil, Consultas (históricas y recientes por sector), Fidelidad, y

la presencia de al menos un incumplimiento en el historial. Esta última variable no resultó significativa cuando fue considerada en cantidades totales, por lo que también se ha podido demostrar que el primer incumplimiento es el que más influye en la voluntad de pago de las personas. A su vez, se corroboró que el registro de incumplimientos en el período de crisis financiera es menos grave en términos de las estimaciones de riesgo, mientras que sí lo es presentar incumplimientos a edades avanzadas, y con el propio sector financiero. Por otra parte, ni los montos ni los plazos de las operaciones incumplidas anteriores parecen aportar mayor información relativa al riesgo que la incluida en las variables que sí formaron parte del modelo.

La duración del historial crediticio no formó parte de los modelos, pero su efecto está siendo recogido por el indicador de Fidelidad, con la diferencia de que este indicador reduce su influencia cuando la extensión del historial se acompaña por un gran número de instituciones financieras a las que se acudió a solicitar créditos. Recordemos que la variable que mide la duración del historial crediticio (meses desde la apertura de la ficha) presenta correlación con la edad de la persona, lo cual explica que la variable por sí sola no aporte suficiente información como para justificar su inclusión en el modelo.

Por su parte, la variable Sexo, si bien es significativa, no presenta un efecto parcial importante, mientras que los resultados para las variables de residencia, demuestran que algunos departamentos del Interior presentan en promedio un riesgo inferior que el de las zonas más riesgosas de Montevideo.

En cuanto a la variable relativa a extravíos de cédula, se ha corroborado que puede recoger rasgos de la personalidad asociados con el riesgo, activándose para individuos que en promedio presentan una probabilidad de incumplimiento estimada superior.

En síntesis el análisis de ambos modelos permite concluir que las variables incluidas contienen información capaz de explicar el riesgo observado en la muestra de desarrollo, y que en su mayoría se asocian al factor que se ha denominado como “voluntad de pago” en el Marco Teórico de este proyecto.

## **V. Análisis de performance de los modelos.**

Para evaluar la significación y el ajuste de los modelos, se presentan en primer lugar los valores que tomaron los estadísticos tradicionales (basados principalmente en lo observado para la función de verosimilitud), y los resultados que arrojaron los tests de significación realizados para ambos modelos.

Más adelante se comentan los resultados obtenidos para otro tipo de indicadores de frecuente utilización en el área del Credit Scoring, como el estadístico K-S y el Accuracy Ratio, y se presentan también algunas medidas más intuitivas de la calidad, como la tasa de “malos” por tramo de probabilidad, o el costo de captar el 50% de los “malos”.

Para medir la capacidad predictiva del modelo se utilizaron tablas de clasificación, derivadas en una primera instancia de la regla de predicción basada en la tasa de “malos” muestral: los resultados se analizan suponiendo costos iguales para los dos tipos de error de clasificación, calculándose luego la relación de costos de los errores que equipara los resultados “con” y “sin modelo”.

Posteriormente se introduce el costo real observado para los errores de clasificación “sin modelo”, y se realizan supuestos sobre algunas variables clave, para determinar el ahorro de costos generado por la aplicación de la regla. Finalmente se determina el punto de corte óptimo, calculado para distintos escenarios de variación de las variables clave.

### ***1. Indicadores de performance tradicionales.***

A continuación se resumen los valores que presentaron algunos estadísticos para los dos modelos alternativos:

Tabla 6 Estadísticos de ajuste de los modelos.

	<b>Modelo 1</b>	<b>Modelo 2</b>
Log Verosimilitud Inicial	22.723,69	22.723,69
Log Verosimilitud Modelo	19.946,27	20.005,24
Model Chi-Sq	2.777,42	2.718,46
<b>Sig (Model Chi-Sq)</b>	<b>0,000</b>	<b>0,000</b>
<b>Pseudo R2 (Mc F)</b>	<b>0,122</b>	<b>0,120</b>
<b>Sig (Hosmer - Lemeshow Test)</b>	<b>0,144</b>	<b>0,050</b>

La significación de los modelos se corroboró a través del **test Chi-cuadrado** realizado en cada caso sobre el modelo total, permitiendo rechazar la hipótesis nula de que todos los parámetros son iguales a cero, para un nivel de significación menor al 1% (ver salida en la Sección III.2 del Anexo).

El **Pseudo-R<sup>2</sup> de Mc Fadden** fue similar para ambos modelos, alcanzando un nivel superior a 12% que puede considerarse dentro del rango de valores que normalmente toma el estadístico.

Asimismo, en ninguno de los casos se obtuvo evidencia suficiente para rechazar la hipótesis nula del **test de Hosmer-Lemeshow**. Basándose en la comparación de las frecuencias esperadas versus las observadas para la variable dependiente (a través del estadístico  $\chi^2$ ), el test asume como  $H_0$  la igualdad entre ambas distribuciones. Considerando el modelo 1 sólo se podría rechazar la hipótesis a niveles de significación de 14.4%, mientras que en el caso del modelo 2 la exigencia es apenas superior al 5%.

## ***2. Otros indicadores del poder discriminatorio del modelo.***

En esta etapa se analiza el poder discriminatorio de los dos modelos, no sólo en la muestra de desarrollo sino en la muestra de 3000 observaciones apartada para validación. Por tanto, todos los indicadores de calidad del modelo que se exponen a continuación se calcularon para ambas muestras.

Tabla 7 Distribución de "buenos" y "malos" en la muestra

	MUESTRA	
	DESARROLLO	VALIDACIÓN
# BUENOS	57.671	2.858
# MALOS	2.808	142
% MALOS	4,6%	4,7%
<b>MUESTRA TOTAL</b>	<b>60.479</b>	<b>3.000</b>

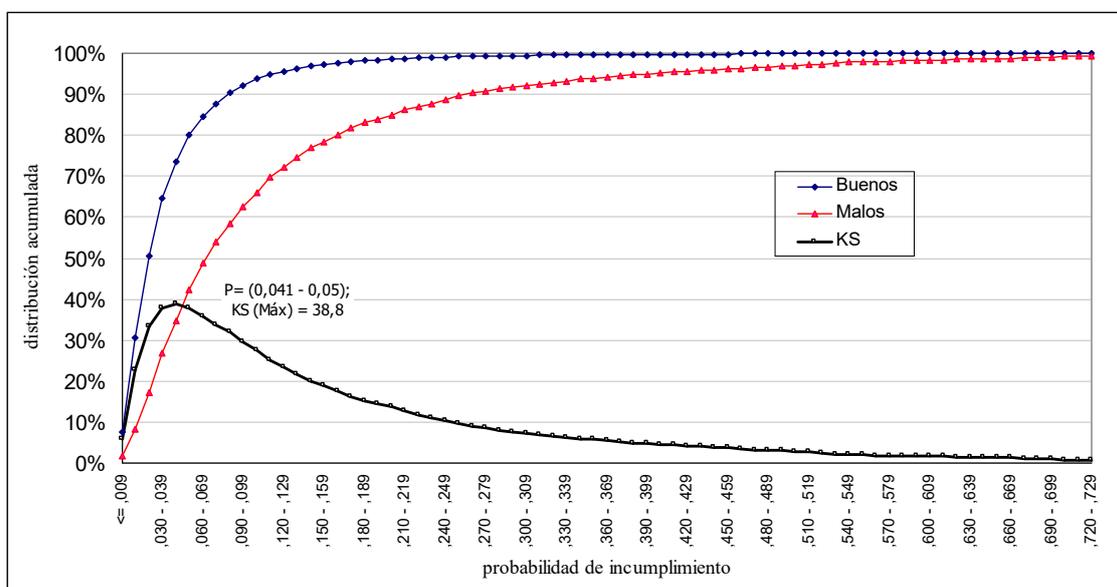
### **Estadístico KS**

El estadístico KS mide la capacidad del modelo para segmentar la población, a través de la diferencia observada en la muestra para las distribuciones (acumuladas) de “buenos” y “malos”, en cada nivel de probabilidad de incumplimiento (p).

El punto de máximo KS es utilizado como una medida de la calidad de los modelos de scoring: su valor puede estar entre 0 y 1, indicando que el modelo logra una separación nula o perfecta entre las dos distribuciones.

En la siguiente gráfica se determina la diferencia entre las dos distribuciones (KS) y el punto de máximo KS para el Modelo 1 en la muestra de desarrollo:

Gráfico 8 Muestra Desarrollo: Determinación gráfica del KS Máx (Modelo 1)



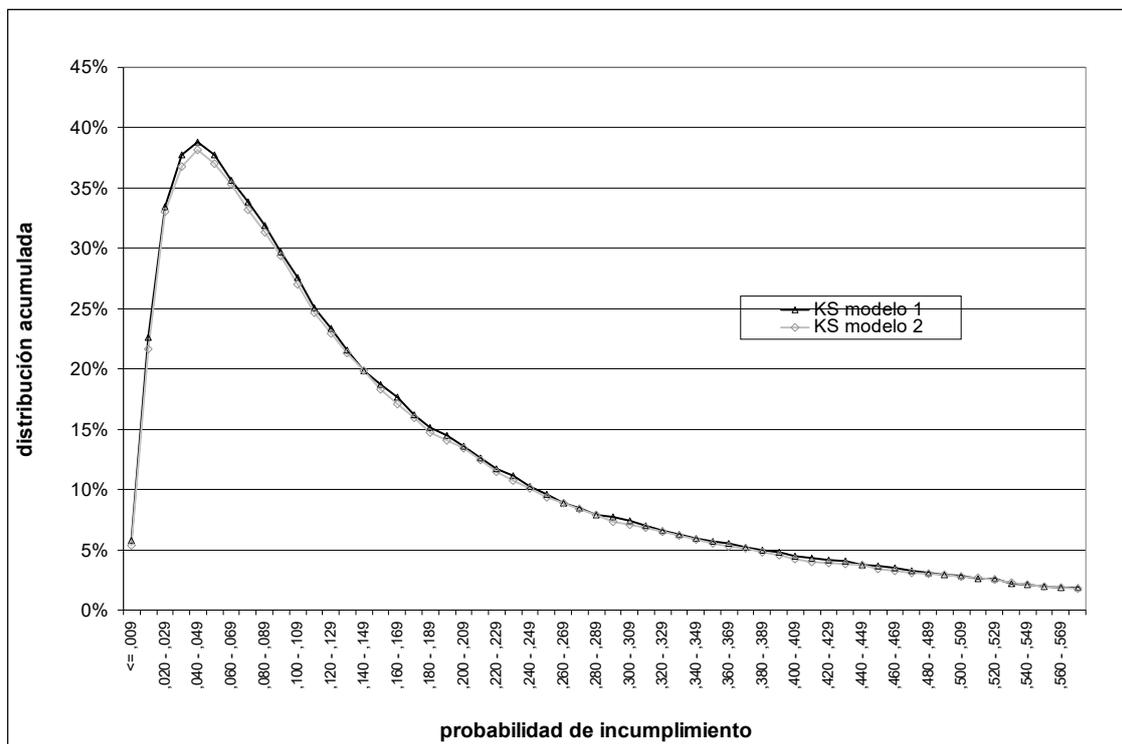
A continuación se presenta el resumen de valores estimados para el estadístico KS, tanto en la muestra de desarrollo como en la de validación, utilizando los dos modelos que se manejan como alternativa.

Tabla 8 Estimación del KS Máximo

	MUESTRA DESARROLLO		MUESTRA VALIDACION	
	Modelo 1	Modelo 2	Modelo 1	Modelo 2
KS	0,388	0,382	0,288	0,287

Basándonos en este indicador, el Modelo 1 presenta mejores resultados tanto en la muestra de desarrollo como en la de validación. El siguiente gráfico muestra las distribuciones del estadístico en simultáneo para los dos modelos: aunque son pequeñas, se observan mayores diferencias a favor del Modelo 1 en el entorno del máximo KS de ambos modelos.

Gráfico 9 Contraste de Modelos - Distribución del KS en la muestra para desarrollo.



**“ROC Statistic” (AUROC) y “Accuracy Ratio” (AR)**

Estos estadísticos surgen del análisis de gráfico de las curvas ROC y CAP<sup>30</sup>, cuya interpretación implica comparar los resultados del modelo en cuestión, contra los que se obtendrían con un modelo “random” que asigna probabilidades al azar.

Basándose en la medición del área debajo de la curva, el AUROC parte de un nivel mínimo de 0.5 mientras el AR lo hace desde 0: ambos estadísticos valen 1 cuando el modelo es perfecto, y se relacionan entre sí mediante una fórmula simple tal como demuestran Engelmann et al. (2003).

Tabla 9 Estadísticos ADROC y AR

ESTIMACIONES ROC / CAP	MUESTRA DESARROLLO		MUESTRA VALIDACION	
	Modelo 1	Modelo 2	Modelo 1	Modelo 2
ADROC	75,8%	75,4%	70,2%	70,5%
AR	51,6%	50,9%	40,4%	41,1%

<sup>30</sup> En la sección II.5 del Anexo se desarrolla el cálculo de estos dos indicadores, y se incluye una interpretación de las curvas ROC y CAP.

Como se aprecia en el cuadro, una vez más el modelo 1 presenta mejores resultados para todos los indicadores.

### Costo de captar el 50% de los “malos”.

Este indicador refleja el porcentaje de “buenos” que se rechazan como efecto colateral, para poder clasificar correctamente la mitad de los “malos”. El cuadro resume los resultados para ambos modelos, primero indicando el punto de corte que debe utilizarse para obtener el resultado, y luego mostrando el porcentaje de “buenos” que se clasifican incorrectamente a raíz de su aplicación:

Tabla 10 Rechazo del 50% de los "malos" : punto de corte y % de "buenos" mal clasificados

	MUESTRA DESARROLLO		MUESTRA VALIDACION	
	Modelo 1	Modelo 2	Modelo 1	Modelo 2
Punto de corte (pred)	0,0713	0,0700	0,0561	0,0581
% Buenos con Pr > Punto de corte	0,147	0,150	0,229	0,219

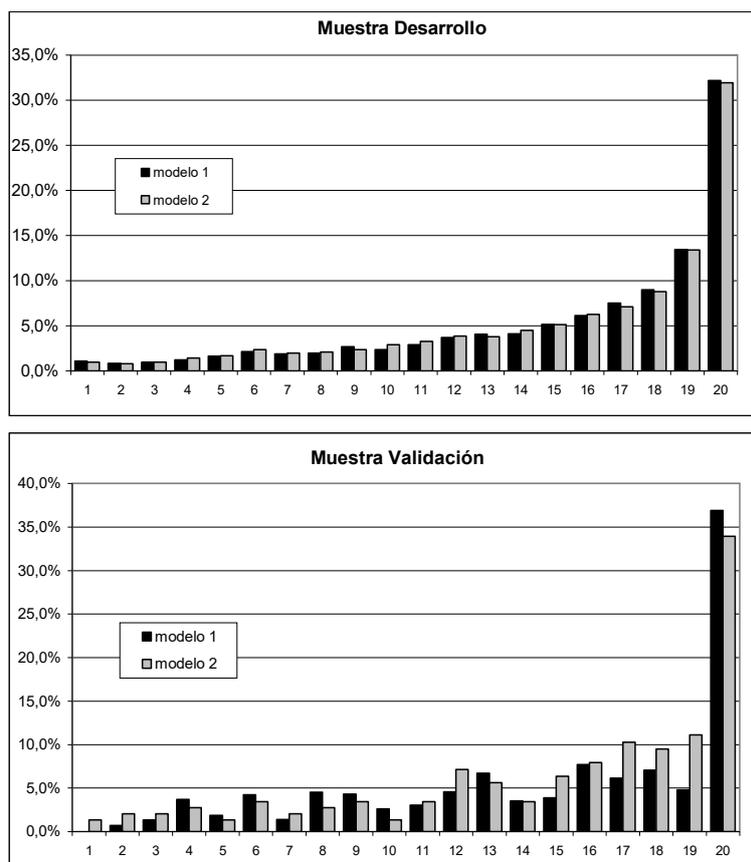
El indicador presenta un valor que puede considerarse satisfactorio para ambos modelos. En la muestra de desarrollo, el modelo 1 arroja un resultado levemente mejor, aunque en la de validación la situación se revierte, siendo el segundo modelo el que mejor funciona<sup>31</sup>.

### Tasa de “malos” por tramo.

Para ambos modelos, los gráficos confirman que el indicador cumple con la condición deseable de mantener una tendencia creciente a medida que nos acercamos a niveles de mayor probabilidad de incumplimiento:

<sup>31</sup> La presencia de comportamientos atípicos con probabilidad predicha entre 0.0561 y 0.0581 puede estar ocasionando este efecto. El pequeño tamaño de la muestra para validación, y la escasa cantidad de observaciones negativas explican la ocurrencia de este tipo de problemas.

Gráfico 10 Tasa de “malos” por ventiles de probabilidad



### 3. Análisis de Tablas de clasificación.

Para enfocar la evaluación del modelo en su capacidad para predecir correctamente el riesgo, se analizan a continuación los resultados obtenidos para las tablas de clasificación.

Dado que el evento de interés es de una frecuencia relativa muestral muy baja, no se utiliza aquí el habitual punto de corte de probabilidad de incumplimiento  $p=0.5$ , sino  $p=0.046$ : valor correspondiente a la frecuencia relativa de “malos” en la muestra.

La clasificación se realiza en base a la comparación de la probabilidad estimada para el individuo, contra la probabilidad de incumplimiento promedio en la muestra:

Si  $p_i \geq 0.046$  entonces  $i$  se clasifica “malo” (o se rechaza)

Si  $p_i < 0.046$  entonces  $i$  se clasifica “bueno” (o se aprueba)

La evaluación de performance del modelo se basa en la consideración de los dos tipos de error que pueden presentarse en las predicciones: el primero consiste en clasificar “bueno” a un incumplidor (**error de tipo i**), y el segundo en clasificar “malo” a un buen pagador (**error de tipo ii**). La suma de ambas frecuencias da lugar al error total del modelo.

El cuadro muestra los porcentajes de cada tipo de error, y el porcentaje de error total del modelo; la performance se compara contra la situación inicial “sin modelo” donde se aprueba el 100% de los casos, con un error total equivalente al 4.6% de los casos analizados (dado por la frecuencia relativa de “malos” observada en la muestra):

Tabla 11 Porcentaje de errores por tipo: Situación Inicial (sin modelo) vs Situación con modelo

	MUESTRA DESARROLLO		MUESTRA VALIDACION	
	Modelo 1	Modelo 2	Modelo 1	Modelo 2
punto de corte	1,000	1,000	1,000	1,000
error tipo i	100%	100%	100%	100%
error tipo ii	0%	0%	0%	0%
error inicial total	<b>4,6%</b>	<b>4,6%</b>	<b>4,7%</b>	<b>4,7%</b>
punto de corte	0,046	0,046	0,047	0,047
error tipo i	32,5%	32,7%	42,3%	43,0%
error tipo ii	28,8%	29,0%	29,0%	29,6%
error total modelo	<b>29,0%</b>	<b>29,1%</b>	<b>29,7%</b>	<b>30,2%</b>

En el supuesto de que los dos tipos de error se valoren de forma equivalente, la opción más razonable sería aceptar el 100% de los casos, ya que la tasa de errores totales con la regla de clasificación incrementa en más de 20% la cantidad de casos mal clasificados.

Mientras la aplicación de la regla reduce el error de tipo i, concomitantemente aumenta el error de tipo ii. Dado que hasta aquí no se han realizado supuestos acerca de la valoración de cada tipo de error, el ejercicio siguiente tiene por objetivo determinar cuánto más debería valer el primer tipo de error en relación al segundo, para que la regla mejore la situación inicial<sup>32</sup>:

<sup>32</sup> %Ei es el porcentaje de “malos” que resultaron aprobados por la regla, %Eii es el porcentaje de los “buenos” que fueron rechazados, Nm es el número de “malos” en la muestra, y Nb el de “buenos”. \$Ei es el costo asociado a cada error i, y \$ Eii a cada error ii.

Partiendo de un costo unitario del error i arbitrario ( $\$E_i = \$100$ ), se determina el Costo Total Inicial (sin modelo) en la muestra para desarrollo, al asignar ese valor a cada uno de los 2.808 malos pagadores que conformaron la muestra:

$$CT(0) = 2808.100 = \$ 280.800$$

Por otra parte el Costo Total “con modelo” corresponde al generado por los 913 “malos” que se aprueban con la regla, más los 16.609 buenos que la misma rechaza:

$$CT(1) = (\%E_i.N_m).\$E_i + (\%E_{ii}.N_b).\$E_{ii} = 0,325.2808.100 + 0,288.57671.\$E_{ii}$$

Se puede determinar  $\$E_{ii}$  para que  $CT(0) = CT(1)$ :

$$\$E_{ii} = 11,42$$

La relación de costos necesaria para igualar los costos totales con y sin modelo, en el punto de corte fijado es entonces:

$$RC = \$E_i / \$E_{ii} = 100/11,42 = 8,76.$$

Tabla 12 Análisis para  $\$E_i = \$100$ : Relación de costos de equilibrio.

	MUESTRA DESARROLLO		MUESTRA VALIDACION	
	Modelo 1	Modelo 2	Modelo 1	Modelo 2
<u>sin modelo</u>				
CT (E i)	280.800	280.800	14.200	14.200
CT (E ii)	0	0	0	0
CT (0)	280.800	280.800	14.200	14.200
<u>con modelo</u>				
CT (E i)	91.200	91.700	6.000	6.100
CT (E ii)	189.600	189.100	8.200	8.100
CT (1)	280.800	280.800	14.200	14.200
<u>Relación de Costos</u>				
\$ E <sub>i</sub>	\$U 100,00	\$U 100	\$U 100	\$U 100
\$ E <sub>ii</sub>	\$U 11,42	\$U 11,32	\$U 9,88	\$U 9,59
<b>RC</b>	<b>8,76</b>	<b>8,84</b>	<b>10,12</b>	<b>10,43</b>

Esta relación de costos (RC) depende en última instancia de los porcentajes de “buenos” y “malos” mal clasificados, así como de la relación de cantidades de “buenos” a “malos” en la muestra<sup>33</sup>:

$$RC = \$ E_i / \$ E_{ii} = [\% E_{ii} / (1 - \% E_i)] \cdot N_b / N_m$$

Se concluye que para un punto de corte determinado por la tasa de “malos” muestral, y suponiendo que el costo de los errores es constante para distintos niveles de riesgo, la relación de costos necesaria para que la regla sea beneficiosa debería superar en el caso del modelo 1 un valor de 8.76 en la muestra de desarrollo y 10.12 en la de validación. Para el modelo 2 los valores se incrementan (8.84 en muestra para desarrollo y 10.43 en muestra para validación).

#### ***4. Modelo 1: Diferenciación de costos por tipo de error.***

El siguiente paso del análisis consiste en separar los dos tipos de error y asignar a cada uno el costo real que representan.

**Costo del error i (\$E<sub>i</sub>):** Está representado por el monto que no se logra recuperar del crédito otorgado. También incluye el costo que representa a la institución emprender acciones para recuperar lo adeudado.

**Costo del error ii (\$E<sub>ii</sub>):** Es la pérdida asociada al costo de oportunidad de negar un crédito, representada a través de la pérdida de ganancias (intereses del crédito solicitado menos costos). Asimismo representa también un costo para las instituciones la pérdida de porción de mercado que puede implicar la negación de créditos.

---

<sup>33</sup> La relación surge al desarrollar el cociente de costos unitarios, introduciendo el Costo Total de la regla, y sustituyéndolo por el Costo Total sin modelo:

$$\begin{aligned} \$E_i / \$E_{ii} &= \$E_i / [(CT(E_{ii})) / (\#E_{ii})] = \$E_i \cdot \#E_{ii} / [(CT(E_i) + CT(E_{ii})) - CT(E_i)] = \\ &= \$E_i \cdot \#E_{ii} / [(\$E_i \cdot N_m) - \$E_i \cdot \#E_i] = \#E_{ii} / [N_m - \#E_i] = (\% E_{ii}) \cdot N_b / [(1 - \% E_i) \cdot N_m] \\ &= [(\% E_{ii}) / (1 - \% E_i)] \cdot (N_b / N_m) \end{aligned}$$

Para simplificar el análisis no se toman en consideración en el caso del primer error los costos de recuperación de las deudas, al tiempo que en el segundo no se consideran los costos relacionados con la pérdida de porción de mercado. Asimismo, dado que los resultados de la validación fueron un tanto mejores para el modelo 1 en términos de verosimilitud y poder de predicción, el análisis siguiente se efectuará en base a éste último.

El costo del error i está entonces determinado por **el saldo incumplido informado por las instituciones financieras**. El costo unitario del error ii, dado por la ganancia promedio de los préstamos, se ha estimado a partir del monto promedio de las operaciones incumplidas<sup>34</sup>, dejándose como única variable exógena la ganancia promedio asociada a cada préstamo exitoso (g).

Los resultados de la aplicación de las reglas determinadas por los puntos de corte  $p = 0,046$  y  $p = 0,047$  para las muestras de desarrollo y validación respectivamente se exponen a continuación; el ejercicio demuestra que la utilización de la regla genera un ahorro de costos positivo para tasas de ganancia promedio de los préstamos menores a 10.24% en la muestra para desarrollo, y 6.38% en la muestra para validación<sup>35</sup>.

Tabla 13: Muestra Desarrollo: Resultado de la utilización del punto de corte  $p = 0,046$

Punto de corte: $p=,046$						
g promedio	CT Ei	CT Eii	CT	CT(0)	Ahorro	% Ahorro
5,00%	12.144.936	11.207.534	23.352.470	35.088.251	11.735.781	33,4%
10,00%	12.144.936	22.415.069	34.560.005	35.088.251	528.246	1,5%
10,24%	<b>12.144.936</b>	<b>22.943.315</b>	<b>35.088.251</b>	<b>35.088.251</b>	<b>0</b>	<b>0,0%</b>
15,00%	12.144.936	33.622.603	45.767.539	35.088.251	-10.679.288	-30,4%

Tabla 14: Muestra Validación: Resultado de la utilización del punto de corte  $p = 0,047$

Punto de corte: $p=,047$						
g promedio	CT Ei	CT Eii	CT	CT(0)	Ahorro	% Ahorro
5,00%	656.219	560.343	1.216.562	1.371.175	154.613	11,3%
6,38%	<b>656.219</b>	<b>714.956</b>	<b>1.371.175</b>	<b>1.371.175</b>	<b>0</b>	<b>0,0%</b>
10,00%	656.219	1.120.686	1.776.905	1.371.175	-405.730	-29,6%
15,00%	656.219	1.681.029	2.337.248	1.371.175	-966.073	-70,5%

<sup>34</sup> En la sección II.6 del Anexo se analiza el supuesto implícito en esta estrategia. Asimismo se explican las particularidades de las variables monto y saldo incumplidor en el periodo de comportamiento, y el tratamiento realizado a los valores atípicos en las mismas.

<sup>35</sup> En la sección II.7 del Anexo se relacionan los valores de intersección encontrados para “g” con las condiciones derivadas anteriormente para la relación de costos de los errores.

### 5. Determinación del punto de corte óptimo.

Ya se han definido las condiciones que deben cumplirse para que la utilización de la regla de clasificación basada en el modelo 1 sea beneficiosa para el sistema en su conjunto. El siguiente paso del análisis consiste en encontrar una regla de clasificación que además de ser beneficiosa, sea óptima. Con ese objetivo se manejan distintos escenarios dados por un espectro razonable de valores para la tasa de ganancia promedio de los préstamos.

El cuadro siguiente presenta los posibles puntos de corte, la regla de clasificación dada por cada uno, y la cantidad de aprobados (“buenos” y “malos”) para cada regla. Se trabajó con la distribución en veintiles para la probabilidad de incumplimiento en la muestra para desarrollo<sup>36</sup>.

Tabla 15 Cantidad de aprobados según punto de corte

		COMPORTAMIENTO		Total	Regla (aprueba si p<)	APROBADOS	
		BUENO	MALO			BUENO	MALO
Probabilidad pronosticada (Categorizada)	<= ,008	2.991	33	3.024	0,00	0	0
	,009 - ,010	2.998	25	3.023	0,009	2.991	33
	,011 - ,013	2.995	29	3.024	0,011	5.989	58
	,014 - ,015	2.988	36	3.024	0,014	8.984	87
	,016 - ,017	2.976	49	3.025	0,016	11.972	123
	,018 - ,019	2.959	64	3.023	0,018	14.948	172
	,020 - ,021	2.969	56	3.025	0,02	17.907	236
	,022 - ,024	2.966	58	3.024	0,022	20.876	292
	,025 - ,027	2.945	79	3.024	0,025	23.842	350
	,028 - ,030	2.956	69	3.025	0,028	26.787	429
	,031 - ,033	2.937	85	3.022	0,031	29.743	498
	,034 - ,037	2.916	108	3.024	0,034	32.680	583
	,038 - ,041	2.906	118	3.024	0,038	35.596	691
	,042 - ,047	2.904	120	3.024	0,042	38.502	809
	,048 - ,054	2.875	149	3.024	0,048	41.406	929
	,055 - ,062	2.850	175	3.025	0,055	44.281	1.078
	,063 - ,075	2.813	211	3.024	0,063	47.131	1.253
	,076 - ,095	2.774	249	3.023	0,076	49.944	1.464
	,096 - ,135	2.666	359	3.025	0,096	52.718	1.713
,136+	2.287	736	3.023	0,136	55.384	2.072	
		<b>57.671</b>	<b>2.808</b>	<b>60.479</b>	1,00	<b>57.671</b>	<b>2.808</b>

El procedimiento consistió en asignar a cada regla los costos de los errores, y comparar la suma de ambos con el costo total inicial sin modelo.

<sup>36</sup> Los mismos resultados para la muestra de validación pueden encontrarse en la Sección III.3 del Anexo.

El Ahorro Total de Costos (ATC) que genera cada regla se define de la siguiente manera:

$$ATC = CT(E_i) + CT(E_{ii}) - CT(0)$$

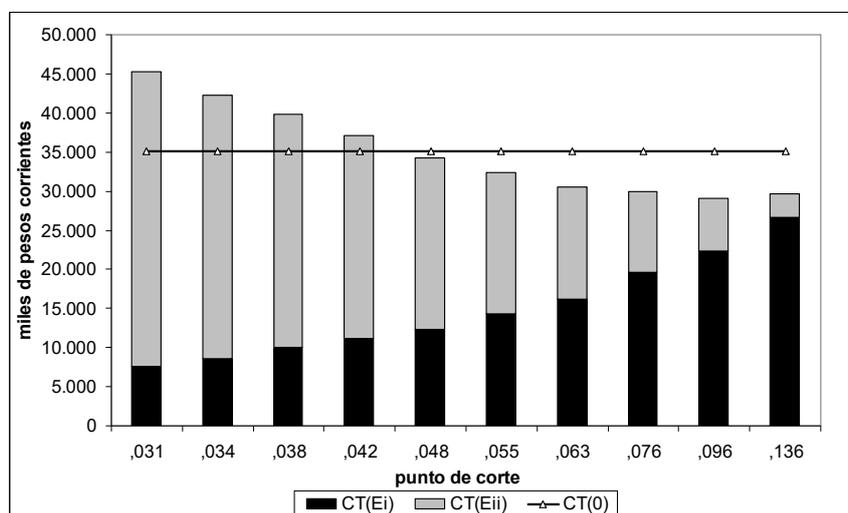
donde  $CT(0)$  es el costo inicial (sin modelo) y equivale a:

$$CT(0) = N_m \cdot \$E_i$$

$$CT(0) = 2808 \cdot 12495,82 = \$ 35.09 \text{ millones}$$

En el siguiente gráfico se muestra, para una “g” fijada en 10%, el Costo Total por tipo de error implícito en cada punto de corte, y el Costo Total sin modelo  $CT(0)$ :

Gráfico 11 Costos Totales por política: Análisis para  $g = 0,10$

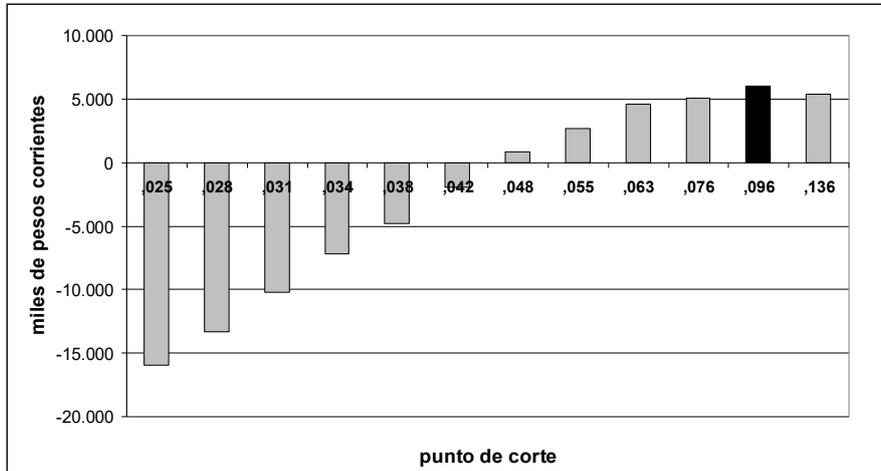


El gráfico muestra el *trade-off* entre los dos tipos de error: al disminuir el punto de corte, aumenta la cantidad de rechazados y el costo total del error ii adquiere mayor importancia. Cuando el punto de corte se fija en probabilidades más altas, es el Costo de Error i el que prepondera.

También se concluye a partir del gráfico, que para puntos de corte superiores al 4.6% fijado antes, el beneficio de las políticas es mayor, dado que la suma de los costos es claramente inferior al costo total sin modelo.

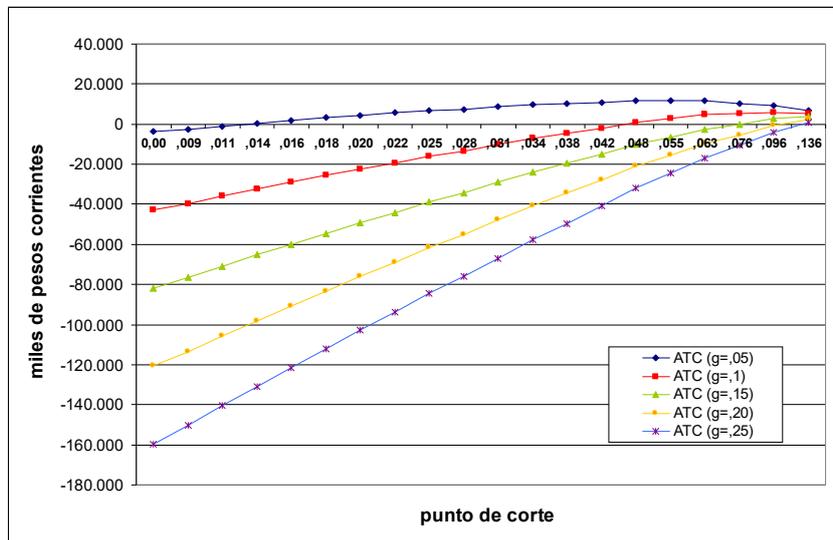
El punto de corte que maximiza el ATC en la muestra de desarrollo, para un nivel de  $g$  fijo en 0.10, se da para un nivel de probabilidad a priori de 9,6%:

Gráfico 12 Muestra desarrollo: Ahorro Total de Costos por punto de corte (análisis para  $g = 0,10$ )



Finalmente se analiza el ATC para distintos valores de  $g$ :

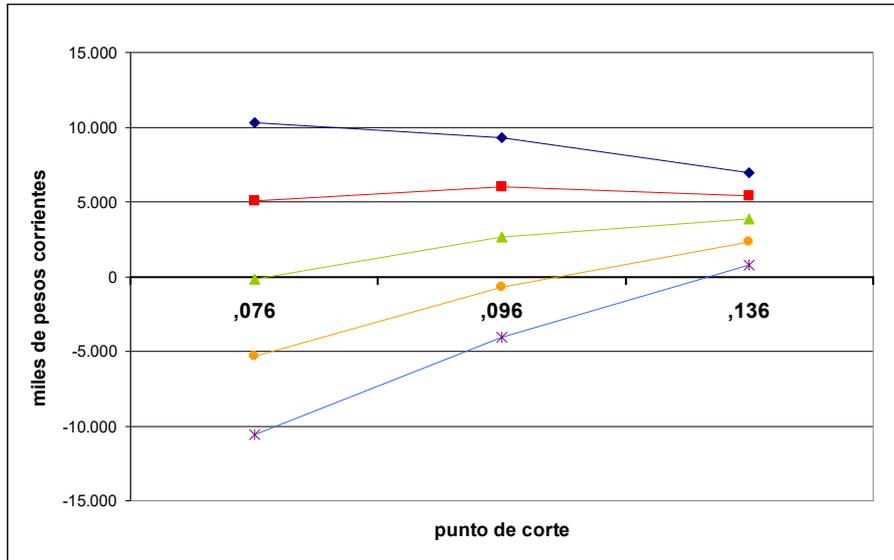
Gráfico 13 Ahorro Total de Costos por punto de corte (Modelo 1)



En el gráfico se observa el efecto amplificador sobre el  $CT(E_{ii})$  que ejerce  $g$ , provocando que para tasas muy altas, el ATC neto sea positivo solamente para puntos de corte muy elevados (donde se reduce la cantidad de “buenos” que son rechazados por la regla).

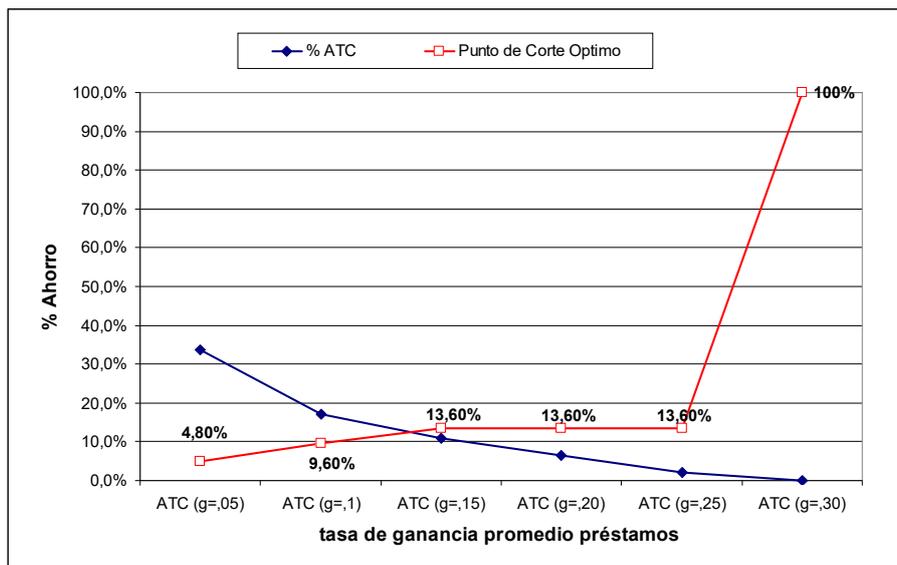
Ampliando la escala para concentrar el análisis en los últimos tres puntos, se observa que junto con la tasa de ganancia varía el punto de corte óptimo del modelo: a medida que aumenta, también lo hace el punto de corte óptimo para la probabilidad de incumplimiento estimada.

Gráfico 14 Ahorro Total de Costos y Punto de corte óptimo



La relación entre ambas variables se observa más claramente en el siguiente gráfico, donde también se incluye el ATC como porcentaje del CT(0).

Gráfico 15 Porcentaje de Ahorro vs. Punto de corte óptimo por niveles de "g"



A medida que aumenta  $g$ , disminuye el porcentaje de los costos que se logra reducir con la regla, desde más de 30% hasta hacerse nulo en  $g=0.3$  (donde la regla óptima es aprobar la totalidad de las solicitudes).

De la misma manera, el punto de corte óptimo se va incrementando desde  $p=.048$  (correspondiente a una  $g=.05$ ) hasta  $p=.136$  (para  $g=.25$ ). Si  $g$  supera el nivel de 0.25, ningún punto de corte mejora la situación inicial donde se aprueba la totalidad de las solicitudes.

## ***6. Evaluación global de calidad de los modelos.***

El objetivo de este capítulo fue analizar el poder discriminatorio de los modelos en términos generales, y el aporte de la aplicación de una regla basada en el modelo 1, como forma de complementar la política crediticia actual en el sector de créditos al consumo de Uruguay. Lo primero se ha confirmado a través de los diversos indicadores utilizados para cada modelo. Si bien la interpretación de los indicadores depende en buena medida del tipo de muestra que se está utilizando, puede resultar útil recurrir a las tablas presentadas por Maurice (2000), donde se resume el rango de valores que normalmente presenta cada estadístico en modelos de scoring utilizados en varias instituciones financieras, presentándose también una clasificación general de la calidad basada en todos ellos.

En todos los casos los valores de los estadísticos calculados para la muestra de desarrollo se mantuvieron dentro del rango asociado a un modelo “satisfactorio”, mientras que los resultados en la muestra de validación sin ser tan buenos, presentaron valores aceptables. No debemos olvidar que la muestra utilizada para validación fue de pequeño volumen, y con poca representación de observaciones negativas (apenas 142), lo cual perjudica el análisis. De todas maneras los resultados fueron en general satisfactorios.

En relación al resultado de aplicación de una regla basada en el modelo, es necesario recordar que en las condiciones actuales, la tasa de incumplimiento del sistema asciende a 4,6% lo cual refleja un funcionamiento adecuado. A partir de este dato y considerando

los resultados arribados en el análisis de performance se ha concluido que la aplicación de la regla en el período en consideración, podría haber generado efectos positivos sobre la eficiencia del sistema financiero, reduciendo su morosidad.

Utilizando el modelo 1, y considerando el punto de corte óptimo de 9,6% (calculado para una tasa de ganancia promedio de los préstamos de 10%) la tasa de incumplimiento alcanza un nivel de 3,15%, implicando una disminución de un punto y medio sobre la tasa original. Al tratarse de una muestra compuesta en un 100% por créditos aprobados, dentro de la cual probablemente no se haya logrado una discriminación importante del riesgo, puede afirmarse que el resultado es más que satisfactorio. Pero incluso en términos de costo/beneficio, esta reducción se traduce en un ahorro de costos estimado entre 15 y 20% sobre las pérdidas por incumplimiento del sistema en su conjunto.

En síntesis, se estima que la aplicación del modelo como complemento de las reglas de asignación de créditos de las instituciones tendría efectos positivos en la eficiencia del sistema bancario uruguayo, de mantenerse las condiciones observadas en el período de análisis de este proyecto.

## VI. Conclusión.

El presente trabajo constituye uno de los primeros antecedentes de estimación de la probabilidad de incumplimiento en créditos al consumo aplicados al sistema financiero uruguayo.

Las recomendaciones establecidas por el Nuevo Acuerdo del Comité de Basilea pretenden generalizar el uso de sistemas de scoring para el cálculo de los requerimientos mínimos de capital en las instituciones bancarias. También se argumenta que este tipo de métodos son de utilidad en otras áreas de aplicación, para justificar las decisiones de aprobación, o para guiar las políticas de *pricing* de las entidades. En este contexto, se ha logrado estimar un modelo que además de servir a estos fines, cumple con los requisitos generales como el horizonte temporal recomendado para la estimación, y la representación de la “voluntad de pago” en la estimación del riesgo.

Los grandes fundamentos detrás de las recomendaciones de Basilea se vinculan con la existencia de problemas de información asimétrica en los mercados financieros: en dicho contexto, la calificación estadística apunta a reducir las causas de la selección adversa y el riesgo moral. Aplicando tasas diferenciales basadas en la discriminación del riesgo que consigue el presente modelo se mitiga el primer problema, mientras que utilizando el scoring como sistema de monitoreo de los prestatarios, se puede reducir también el riesgo moral.

Los objetivos perseguidos han conducido a que el modelo tenga una aplicabilidad limitada por las características del propio segmento que se está analizando. Se evalúan comportamientos de individuos que suelen acudir al sistema bancario (aunque se abarcan también tarjetas de crédito emitidas por otras instituciones), y ellos constituyen el segmento para el cual se podrán realizar predicciones en el futuro.

Por otra parte, la falta de información completa acerca del comportamiento de los individuos que resultaron rechazados por las instituciones ha determinado un sesgo que

implica que el modelo sólo pueda aplicarse a personas que cumplen con las condiciones de aprobación aplicadas actualmente por las entidades, complementando y no sustituyendo al sistema actual de decisión. Contar con dicha información podría mejorar las predicciones, permitiendo a su vez analizar en forma completa la política de rechazos: en este trabajo se ha demostrado que la cantidad de errores observados entre las aprobaciones es pequeña, pero dada la información actual nada se ha podido concluir acerca de los rechazos.

Las regularidades empíricas que dan forma al esquema de análisis tradicional se han visto plasmadas en el modelo final, a través de las variables que resultaron más relevantes para explicar el riesgo de incumplimiento. Se concluyó que las consultas recientes con el sector financiero son de mayor importancia, seguidas por variables como la edad, la zona de residencia y la experiencia acumulada en créditos anteriores. Otras variables relevantes incluidas en el modelo final fueron el estado civil, el sexo, la existencia de incumplimientos anteriores y la observación de rasgos más específicos asociados a la personalidad del solicitante.

A partir de una aproximación de la voluntad de pago de los solicitantes, factor que por diversas razones es de difícil modelización para las instituciones, se ha logrado mejorar un sistema que, a juzgar por la tasa de incumplidores observada en el período, de por sí funcionaba satisfactoriamente. Al realizar supuestos razonables sobre algunas variables clave, se concluyó que la aplicación de una regla de aprobación basada en la probabilidad estimada, generaría un ahorro de costos por operaciones incumplidas de entre 15 y 20% para el sistema en su conjunto.

## Referencias Bibliográficas.

- Akerlof, G., “The Market for Lemons: Quality Uncertainty and the Market Mechanism” *The Quarterly Journal of Economics*, Vol. 84, No. 3, Pp 488-500, 1970.
- Aldrich, J., Nelson, F., “Linear probability, logit and probit models”, Sage Publications, Inc., 1<sup>st</sup> Edition, 1984.
- Basel Committee on Banking Supervision, “International Convergence of Capital Measurement and Capital Standards”, Bank for International Supervision, 2006.
- Cox, D., Snell, E., *Analysis of Binary Data*, 2a Edición., Chapman & Hall/CRC, 1989.
- Crook, J., Banasik, J., “Does reject inference really improve the performance of application Scoring Models?”, *Journal of Banking and Finance*, Vol.28, N°4, Pp 857-874, 2004.
- Crook, J., Banasik, J., “Reject Inference, Augmentation and Sample Selection”, Working Paper Series N° 05, 2004.
- Diallo, B., “Un modele de ‘credit scoring’ pour une institution de micro-finance africaine: le cas de Nyesigiso Au Mali”, Laboratoire d'Economie d'Orléans, Université d'Orléans, 2006.
- Dinh Thi Huyen Thanh, Kleimeier, S., “Credit Scoring for Vietnam’s Retail Banking Market: Implementation and Implications for Transactional versus Relationship Lending”, Limburg Institute of Financial Economics, Faculty of Economics and Business Administration, Maastricht University, 2006.

- Durand, D., “Risk elements in consumer installment financing”, National Bureau of Economic Research, New York, 1941.
- Engelmann, B., Hayden, E., Tasche, D., “Testing Rating Accuracy”, *Risk*, January, Pp 82-86, 2003.
- Equifax, “Documentación final: Equifax Score, Clearing de Informes”, 2002.
- Feelders, A., “Credit scoring and reject inference with mixture models”, *International Journal of Intelligent Systems in Accounting, Finance & Management*, 9, Pp 1-8, 2000.
- Feldman, R., “Banks and a big change in technology called Credit Scoring”, Federal Reserve Bank of Minneapolis, The Region, Pp 19-25, 1997.
- Fisher, R., “The Use of Multiple Measurements in Taxonomic Problems”, *Annals of Eugenics*, Vol. 7, Pp 179-188, 1936.
- Glennon, D., “Building and validating credit rating and scoring models”, Session I, Scoring Models Workshop, Comptroller of the Currency Administrator of Banks, US Department of Treasury, 2006.
- Greene, W., “A Statistical Model for Credit Scoring”, Department of Economics, Stern School of Business: New York University, 1992.
- Hand, D., Henley, W., “Statistical Classification Methods in Consumer Credit Scoring: a Review”, *Journal of The Royal Statistical Society, Series A*, Vol 160 (3), Pp 523-541, 1997.
- Heckman J., “Sample selection as a specification error”, *Econometrica*, 47, Pp 153-161, 1979.
- Hosmer, D., Lemeshow, S., *Applied Logistic Regression*, 2ª Edición, Wiley & Sons, New Jersey, 2000.

- Jaffee, D., Russell, T., “Imperfect information, uncertainty, and credit rationing”, *The Quarterly Journal of Economics*, 90, N°4, Pp 651-666, 1976.
- Little, R., Rubin, D., “Statistical analysis with missing data”, Wiley, New York, 1987.
- Maurice, J., “A PD validation framework for Basel II Internal Ratings-Based System”, *Credit Scoring and Credit Control IX*, 2005.
- Mester, L., “What's the point of Credit Scoring”, Federal Reserve Bank of Philadelphia Business Review, Pp 3-16, 1997.
- Mishkin, F., “Asymmetric information and financial crises: a historical perspective”, Working Paper 3400, National Bureau of Economic Research, Cambridge, 1990.
- Mishkin, F., “Prudential Supervision: why is it important and what are the issues?”, Working Paper 7926, National Bureau of Economic Research, Cambridge, 2000.
- Myers, J., Forgy, E., “The development of numerical credit evaluation systems”, *Journal of American Statistics Association*, 58, Pp 799–806, 1963.
- Novales, A., “Econometría”, 2ª Edición, Mc Graw-Hill, Madrid, 2000.
- Rosenberg, X., Gleit, X., “Quantitative methods in credit management: a survey”, *Operations Research*, 42, Pp 589-613, 1994.
- Royston, P., Altman, D., “Regression using fractional polynomials of continuous covariates: Parsimonious parametric modeling (with discussion)”, *Applied Statistics*, 43, Pp 429-467.

- Jacobson, T., Lindé, J., Roszbach, K., “Internal Rating Systems, Implied Credit Risk and the Consistency of Banks’ Risk Classification Policies”, Working Paper Series 155, Sveriges Riksbank, 2003.
- Schreiner, M., “La Calificación Estadística en Microfinanzas: ¿Podrá Funcionar?”, Microfinance Risk Management, Center for Social Development, 2000.
- Schreiner, M., “Scoring Arrears at a Microlender in Bolivia”, Center for Social Development, Washington University in St. Louis, 2004.
- Stiglitz, J., Weiss, A., “Credit rationing in markets with imperfect information”, *The American Economic Review*, 71, N°3, Pp 393-410, 1981.
- Superintendencia de Instituciones de Intermediación Financiera, “Actualización N° 155”, Normas Contables y Plan de Cuentas para las Empresas de Intermediación financiera, Serie PC III 11.8, Banco Central del Uruguay, 2005.
- Thomas, L., “A survey of credit and behavioral scoring: forecasting financial risk of lending to customers”, *International Journal of Forecasting*, 16, Pp 149-172, 2000.
- Ver Straeten, D., Van Den Poel, D., “The impact of selection bias on consumer credit, consumer performance and profitability”, Working Paper, Department of Marketing, Ghent University, Belgium, 2004.

## **Anexo I: Evolución histórica del Credit Scoring**

### **Primeras aplicaciones del análisis estadístico: Análisis Discriminante**

La primera aplicación de técnicas estadísticas para la clasificación de grupos en una población fue realizada por R. Fisher (1936). Si bien la investigación se dio en el área de las ciencias biológicas, la técnica del Análisis Discriminante sería fundamental en los primeros trabajos de análisis estadístico del riesgo de crédito.

David Durand (1941) aplicó la técnica de Fisher al análisis crediticio en el marco de una investigación para el US National Bureau of Economic Research distinguiendo entre “buenos” y “malos” préstamos. Durand sentó el primer precedente de clasificación de créditos, abriendo camino a que en la década posterior se comenzara a utilizar la técnica con fines predictivos. Al momento del auge de las tarjetas de crédito, la técnica de Análisis Discriminante estaba ya consolidada y era de uso general en las instituciones crediticias. Los resultados demostraban que además de su conveniencia por la necesidad de ahorrar recursos y automatizar las decisiones, los métodos estadísticos llevaron a una mejora de la eficiencia y la precisión en las decisiones, que se vio reflejada en una marcada reducción de las tasas de default (Myers y Forgy, 1963).

El surgimiento de la “Equal Credit Opportunity Acts” de 1975 en Estados Unidos agregó una razón más para la utilización de modelos de Credit Scoring en el otorgamiento de créditos en aquel país, al establecer la prohibición de cualquier discriminación en las decisiones de otorgamiento **a no ser que sus motivos estuviesen demostrados estadísticamente** (Thomas, 2000).

### **Difusión de los modelos estadísticos, aparición de nuevas técnicas y enfoques.**

La década de los ‘80 se caracterizó por la adopción de estas técnicas, exitosas en el segmento de las tarjetas de crédito, a otros rubros dentro de la actividad bancaria, principalmente el de los créditos al consumo y los pequeños créditos comerciales. Asimismo el desarrollo de la industria del software y los paquetes estadísticos permitió llevar a la práctica las ideas presentadas por David R. Cox (1989) en su libro “The

Analysis of Binary Data”, donde difundía las ventajas de la regresión logística, que habían sido sugeridas previamente en trabajos de Fisher (1936). Wigington fue el primero en aplicar la Regresión Logística al análisis crediticio.

Junto con los Modelos de Probabilidad Lineal y los modelos Probit, los modelos Logit se adoptaban como una forma de cuantificar mejor la probabilidad de incumplimiento, más allá de la finalidad de respaldar una decisión de aprobación que ya estaba cubierta con los modelos de Análisis Discriminante.

Por su extendida aplicación a los créditos hipotecarios principalmente en Estados Unidos, debe mencionarse el enfoque de los riesgos competitivos. En estos modelos, además de la situación de default se explicitan otras situaciones de riesgo (por ejemplo el pago anticipado), que en ciertos contextos de tasas de interés pueden hacerse atractivas al prestatario, generando pérdidas a la institución financiera. El problema pasa a analizarse desde el punto de vista del prestatario como un problema de opciones competitivas, donde ante cada situación se ejerce aquella que representa los mayores beneficios. La Regresión Logística Multinomial es una de las técnicas más aplicadas a este tipo de problemas.

### **Los sistemas inteligentes, la calificación corporativa y la detección de fraudes.**

Las innovaciones en la teoría del Credit Scoring siguieron apareciendo en años posteriores con el surgimiento de la Inteligencia Artificial, los sistemas expertos y las redes neuronales. Esas técnicas encontraron aplicación especialmente en el área del riesgo corporativo, donde por no contarse con tanta información como en el de consumo, aventajaban a las técnicas estadísticas tradicionales. A su vez, el mayor éxito de la aplicación de las técnicas de Inteligencia Artificial al análisis del riesgo crediticio fue su gran eficacia para la detección de fraudes financieros.

## Anexo II: Aspectos Metodológicos

### 1. Técnicas estadísticas aplicadas en el Credit Scoring.

A continuación se reseñan las principales características del Análisis Discriminante, el Modelo de Probabilidad lineal, los Modelos Probit y Logit, la técnica de Árboles de Clasificación, haciéndose breve referencia a técnicas no estadísticas como las Redes Neuronales.

#### Análisis Discriminante

Partiendo de una cantidad de grupos determinada de antemano, el análisis discriminante permite predecir la pertenencia de un individuo a un grupo, basándose en la puntuación que éste presenta para una función discriminante. Esta función se determina previamente a través de la combinación de un conjunto de variables que caracterizan y diferencian a los individuos de cada grupo y que a su vez se relacionan con el problema de interés.

Esta técnica estadística resulta útil para describir perfiles de distintos grupos de observaciones, pues en realidad se está contrastando la hipótesis de igualdad de medias entre grupos, sin embargo su principal virtud es la de predecir comportamientos para nuevos individuos.

Los supuestos que deben cumplir las variables para que sea posible aplicar el **Análisis Discriminante Lineal** son tres: multinormalidad (al interior de cada grupo), homogeneidad de varianzas, y carácter cuantitativo. Asimismo es necesario que las relaciones entre las variables sean lineales, ya que de otra forma no estarían siendo capturadas por la función discriminante. Si esto se cumple es posible calcular la distancia que separa a los grupos, en caso de que fueran dos, mediante la siguiente ecuación (Thomas, 2000):

$$D = (M1 - M2) / S$$

Donde  $D$  es la distancia,  $M_1$  y  $M_2$  las matrices de medias muestrales de las variables explicativas para el grupo 1 y el grupo 2 respectivamente, y  $S$  el desvío estándar al interior de cada grupo. La maximización de esa distancia implica maximizar el cociente entre la dispersión intergrupos y la dispersión intragrupos. Si la combinación entre las variables explicativas es de la forma:

$$Y = w_1X_1 + w_2X_2 + \dots + w_pX_p$$

donde  $Y$  representa la variable dependiente,  $X_i$  las variables exógenas e independientes y  $w_i$  los ponderadores de éstas últimas.

Siendo  $\Sigma$  la matriz de varianzas y covarianzas para la muestra, entonces la distancia “ $D$ ” puede escribirse como:

$$D = W^T \cdot (M_1 - M_2) / (W^T \cdot \Sigma \cdot W)^{1/2}$$

Y la maximización correspondiente se produce para  $W = \Sigma^{-1} \cdot (M_1 - M_2)$

Para asignar un nuevo individuo a alguno de los grupos conformados a priori, es necesario definir previamente un criterio que podrá basarse alternativamente en el error de clasificación, la razón de verosimilitud, las probabilidades a posteriori y/o el costo de clasificación errónea. A partir de ello se configura la regla de clasificación necesaria para predecir la pertenencia de nuevos individuos a cada grupo: input fundamental de un sistema de decisión de crédito basado en Análisis Discriminante.

A su simplicidad de estimación y la buena performance que han demostrado este tipo de técnicas en su aplicación al problema de la predicción de incumplimientos, se contraponen como desventajas la necesidad de que las variables sigan una distribución Normal multivariada y las dificultades que surgen al trabajar con variables cualitativas. Por otra parte, la técnica es muy útil para definir sistemas de decisión como el de aprobación/rechazo de un crédito, pero no así para determinar una probabilidad de incumplimiento, o simplemente cuán lejos se está del punto de corte al momento de la solicitud.

## Modelos de Regresión

### **Modelo de Probabilidad Lineal (MPL)**

La siguiente opción es considerar la variable dependiente como una variable cualitativa donde los valores que se toman son los distintos estados entre los que se pretende clasificar a los individuos. Cualquiera de estas técnicas da lugar a un modelo econométrico que explica el comportamiento de los individuos en función de una combinación de las variables que los caracterizan a priori.

Los valores estimados por el modelo para la variable dependiente se asocian a la probabilidad de que la variable tome el valor 1 según la puntuación que presentan las variables explicativas en cada caso. La regresión por Mínimos Cuadrados Ordinarios (MCO) da lugar a un término de error determinado por las diferencias entre los valores observados y aquellos predichos por el modelo.

En el caso de que la variable dependiente  $Y$  se defina:

$Y_i = 0$  si el comportamiento es “bueno”

$Y_i = 1$  si el comportamiento es “malo”

el modelo resultante sería de la forma:

$$y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u_i$$

Debido a la especificación del MPL, nada asegura que la probabilidad condicional estimada se encuentre entre 0 y 1. Aunque con ésta técnica se supera uno de los inconvenientes del Análisis Discriminante (al permitir que las predicciones de la variable dependiente tomen valores dentro de un rango continuo) surge una nueva dificultad al no estar este rango acotado a los valores deseables para describir una probabilidad.

En el modelo de probabilidad lineal el efecto parcial de un cambio en una variable explicativa viene expresado directamente por el parámetro asociado a dicha variable:

$$\frac{\partial P(y_i = 1 | x_i)}{\partial x_j} = \beta_j$$

El resto de las ventajas del análisis discriminante se mantienen, ya que es una técnica simple en su metodología, de fácil interpretación y útil a la hora de hacer inferencia.

## Modelos Índice

### Modelos Logit y Probit

Debido a que los valores de las variables independientes no tienen por qué estar acotados a un rango que asegure la permanencia de la variable dependiente Y entre los límites [0,1], lo que sería deseable para describir correctamente una probabilidad, se pueden aplicar transformaciones a la variable dependiente que resuelven esta dificultad dando lugar a los modelos “Índice”.

$$P(y_i = 1 | x_i) = G(x_i' \beta) = G(r)$$

Donde r es una función “Índice” de la forma

$$r_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$$

y G(.) es una función que proyecta ese índice en la probabilidad condicional. Utilizando como G(.) la función de distribución de probabilidad de una variable aleatoria nos aseguramos que se obtienen valores acotados entre 0 y 1 para la probabilidad condicional.

Una de las funciones de distribución de probabilidad mas usadas es la logística, dando lugar a los modelos Logit:

$$G(r) = \Lambda(r) = \frac{e^r}{1 + e^r}$$

La otra función de distribución de probabilidad empleada es la de una normal estandarizada dando lugar a los modelos Probit:

$$G(r) = \Phi(r) = \int_{-\infty}^r \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}t^2}$$

La estimación de ambos modelos surge a través de la maximización de la función de verosimilitud.

A diferencia del modelo de probabilidad lineal el efecto parcial de una variable explicativa en los modelos Logit y Probit sobre la variable dependiente dependerá ahora del valor de  $x_i$ ,

Para el caso de una variable continua el efecto parcial es de la forma,

$$\frac{\partial P(y_i = 1 | x_i)}{\partial x_j} = \beta_j g(x_i' \beta)$$

De aquí surge que el efecto ya no es constante sino que varía según el individuo, para lo cual es necesario definir cómo se van a evaluar los valores, las dos alternativas son: la de obtener la media muestral del efecto parcial, o la de evaluar para  $\bar{x}$  (el valor de la media muestral de  $x$ ).

Para el caso de una variable discreta, el efecto viene dado por:

$$G[\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_{k-1} x_{k-1i} + \beta_k (x_{ki} + 1)] - G[\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_{k-1} x_{k-1i} + \beta_k (x_{ki})]$$

y en particular para el caso de una binaria el efecto parcial se define igual que para una discreta, con el agregado de  $x_{ki}$  toma el valor 0 en la ecuación planteada.

En ambos casos (variable discreta y binaria) para definir donde evaluar el efecto parcial se utilizan las mismas técnicas que para el caso de la continua.

#### Características del Probit y el Logit:

- Por como están definidas las funciones, las predicciones de Y pertenecerán al intervalo [0,1].
- Los efectos parciales ya no serán constantes como en el caso del MPL sino que van a depender de cada individuo.
- Entre las dos técnicas, el Logit se destaca frente al Probit por su sencillez de cálculo, aunque ambos modelos presentan resultados coherentes.
- No suponen una relación lineal entre la variable dependiente y las independientes, ni se requiere la distribución normal de las variables o la homogeneidad de varianzas.
- Los resultados son sensibles a las correlaciones entre variables independientes.

Mas allá de las diferencias entre éstas técnicas, las tres son consistentes en relación a la significación de las variables, al signo de los efectos parciales y en las estimaciones para valores de  $x_i$  cercanos a su media.

### Árboles de clasificación

Cuando un gran número de las variables explicativas son discretas, la técnica no paramétrica de árboles de clasificación suele ser la más apropiada para la discriminación.

La técnica se basa en una categorización de las variables explicativas, realizada de forma que maximice la diferencia entre las proporciones de malos entre los grupos formados para cada variable. La variable de mayor poder discriminatorio se convierte en la primera ramificación del árbol, dando lugar a dos nuevos nodos en los cuales se vuelve a aplicar el mismo criterio, para definir el siguiente nivel de ramificación. Como

resultado se obtiene un árbol de L niveles que finaliza cuando la discriminación que se puede conseguir con las variables restantes no alcanza un nivel aceptable de significación, o cuando la cantidad de individuos del último subgrupo es demasiado pequeña como para generar una nueva división.

La clasificación de nuevos individuos requiere ubicar el grupo al que pertenece en función de los valores que presenta para cada variable del árbol, comenzando por el nodo inicial. De esa forma se puede asignar una probabilidad igual a la proporción de “malos” observada para el último nodo al que el individuo clasificó. A diferencia de las técnicas anteriores, las variables se incorporan al análisis solamente cuando se llega al nodo correspondiente, por lo que en general no todas las variables son consideradas en la clasificación.

Debido a que la cantidad de ramificaciones puede dar lugar a un árbol muy extenso, esta técnica pierde simplicidad en su aplicación, y es muy inestable ante pequeños cambios en la muestra de desarrollo. Por ello, es muchas veces utilizada sólo como complemento en la construcción de los sistemas de Credit Scoring, dado que facilita la categorización de variables explicativas generalmente necesaria para encontrar relaciones lineales con la variable dependiente.

## Métodos no estadísticos: Sistemas Expertos y Redes Neuronales

La técnica de Redes Neuronales busca emular mediante expresiones matemáticas las características del funcionamiento del cerebro humano, incorporando a su vez la posibilidad de adaptación ante el influjo de nueva información relevante para el problema de análisis.

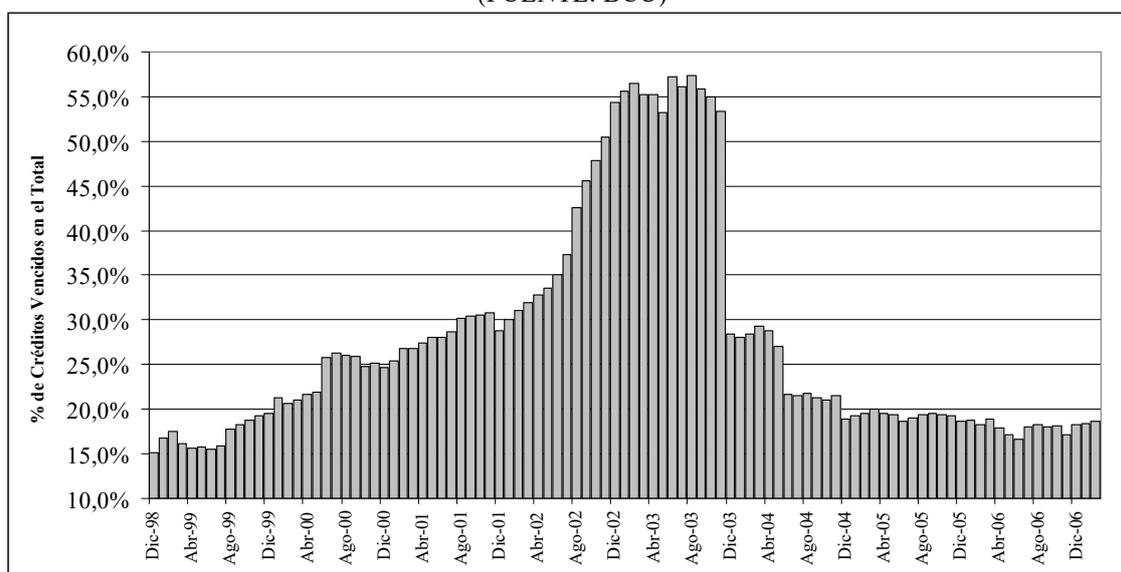
Al igual que la técnica de análisis discriminante, las Redes Neuronales son de mayor utilidad para generar sistemas de decisión del estilo Aprobación/Rechazo, y no tanto para ordenar una amplia gama de observaciones.

### **2. Selección del período de análisis.**

### A) Justificación del período de comportamiento.

Para analizar la adecuación del período seleccionado para analizar comportamientos, se procedió a descartar la presencia de situaciones anormales que puedan afectar las estimaciones del modelo para el futuro. Se estudiaron las estadísticas del Banco Central del Uruguay y de registro de operaciones en Clearing de Informes. En el siguiente gráfico se aprecia la evolución de la relación de créditos vencidos contra el total, para todo el Sistema Bancario, observándose una relativa estabilidad en el período setiembre 2005 – agosto 2006.

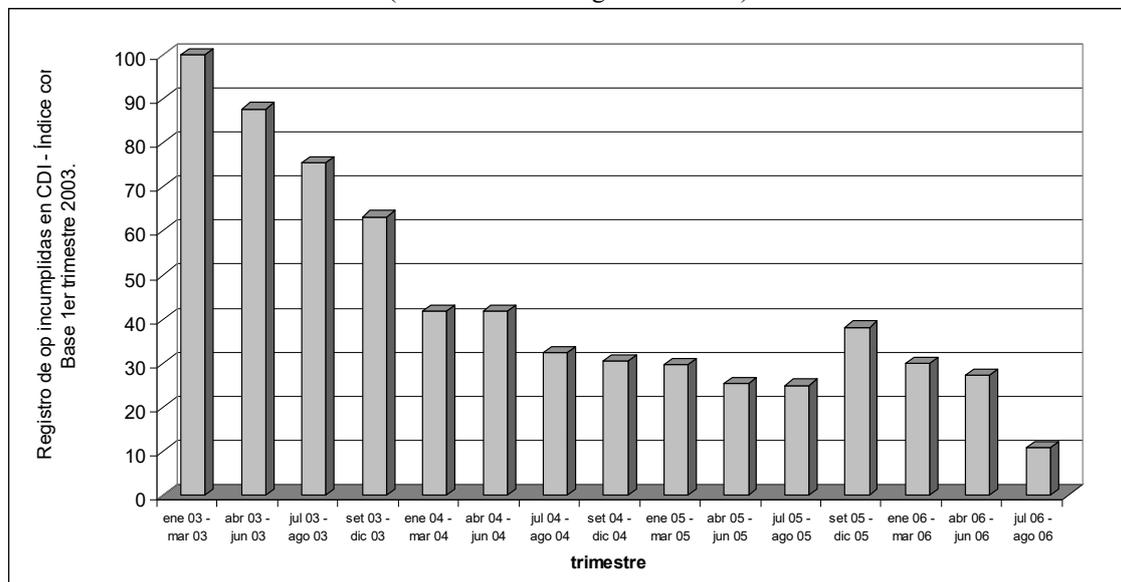
Gráfico 16 Porcentaje de créditos vencidos en el total, total Sistema Bancario, m/n y m/e  
(FUENTE: BCU)



En cuanto al registro de operaciones incumplidas en Clearing de Informes, se analizó la evolución del índice de registros del sector financiero (con base enero – marzo 2003). Este indicador refleja algunas variaciones entre los trimestres considerados (en particular en el trimestre setiembre-diciembre 2005) que se asocian principalmente a la modalidad de envío masivo de la información por parte de las empresas afiliadas del sector bancario. Sin embargo el promedio trimestral de registros dentro del período setiembre 2005 – agosto 2006 no refleja situaciones atípicas. Por otra parte el gráfico permite observar una tendencia decreciente en los registros a partir del primer trimestre

de 2003, que también se apreciaba en el cociente entre créditos vencidos y totales del BCU<sup>37</sup>.

Gráfico 17 Registro de operaciones incumplidas del sector financiero - Índice con base 1er trimestre 2003 (FUENTE: Clearing de Informes).



## B) Justificación del período de selección muestral

La adecuación del período de selección muestral también se justifica en base a estadísticas del Banco Central: se analiza la evolución de la serie “Cantidad de operaciones activas” para el total del Sistema Bancario, observando en particular el período mayo – agosto 2005. En primer lugar se observa que la operativa ha venido creciendo luego de superar los mínimos registrados en la crisis del año 2002. También se concluye la presencia de estacionalidad en la serie, que registra máximos anuales en el último mes del año. El segundo gráfico permite concluir que el período seleccionado es de operativa normal (aunque un poco menor de lo que podría haberse esperado) y que el período seleccionado no incorpora picos de estacionalidad.

<sup>37</sup> Incluso obviando la caída que se observa en aquel indicador en el último trimestre de 2003, que se debe principalmente a ajustes contables.

Gráfico 18 Cantidad de Operaciones Activas: Total Sistema Bancario (FUENTE: BCU)

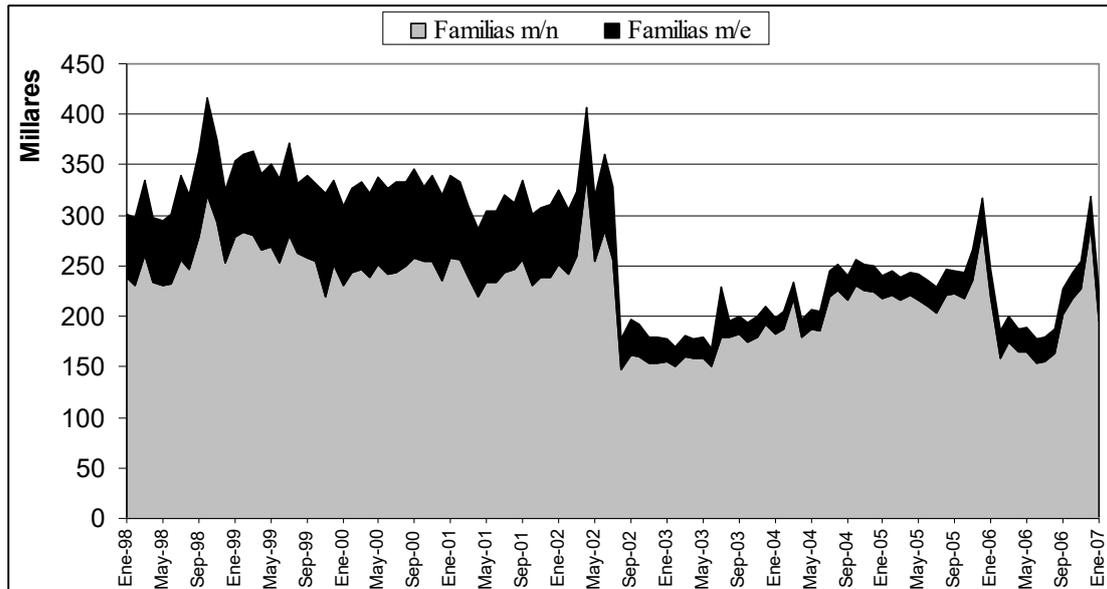
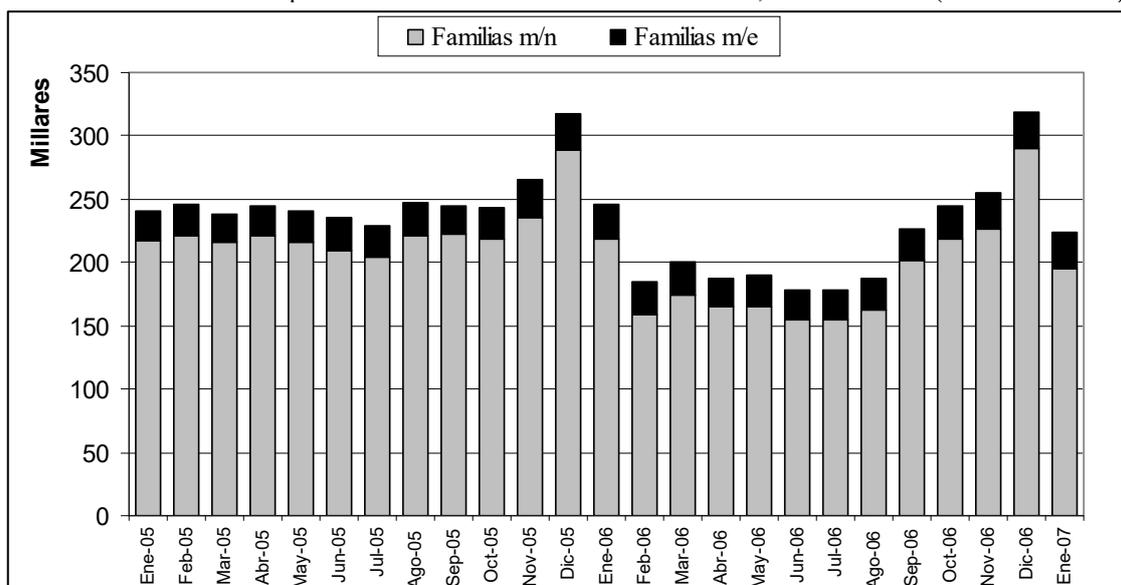


Gráfico 19 Cantidad de Operaciones Activas: Total Sistema Bancario, últimos 2 años (FUENTE: BCU)



### **3. Otros aspectos metodológicos.**

#### **A) Censura en la variable dependiente.**

Para construir modelos de clasificación insesgados es necesario que estos surjan de muestras aleatorias de la población objetivo, es decir, muestras aleatorias de la población conformada por todos aquellos individuos que solicitaron crédito en la institución en un determinado período de tiempo.

Sin embargo, en la práctica esta es una condición de difícil cumplimiento, debido a la ausencia de observaciones de comportamiento para las solicitudes rechazadas<sup>38</sup>: la resolución de este inconveniente suele provocar cambios en el diseño muestral que derivan en la pérdida de aleatoriedad y representatividad de la muestra utilizada.

Por ejemplo, una de las soluciones más comunes para el problema de la censura es extraer de la muestra para desarrollo precisamente a la totalidad de las solicitudes rechazadas. La muestra final queda conformada por las solicitudes que bajo el criterio anterior de calificación hubieran sido aprobadas, y siempre que este criterio no sea independiente de la información disponible, se está generando un sesgo muestral que condiciona la futura aplicación de los modelos.

Otra alternativa utilizada para resolver el problema de la censura es hacer el supuesto de que todos los rechazados se habrían comportado negativamente de haber sido aprobada su solicitud. Si bien se pueden obtener muestras representativas, el efecto sobre la precisión del modelo puede ser aún más grave, ya que es probable que se esté infiriendo injustamente el comportamiento de un conjunto de individuos. Se trata de una medida conservadora y debe tenerse en cuenta que al perpetuarse la política de rechazos tradicional, como mínimo se seguirán asignando riesgos altos a los mismos que antes, incrementándose a partir de allí.

---

<sup>38</sup> Otra forma de censura en la variable dependiente, más frecuente en el caso de las tarjetas de crédito, está dada por el caso en que una vez aprobada la solicitud, esta no es ejercida por la contraparte. En esta situación tampoco puede definirse un comportamiento positivo o negativo, pero al contrario de la censura común, este tipo de censura todavía no ha sido suficientemente abordada a nivel académico.

Por otra parte, calificar a todos los rechazados como buenos, lejos de resolver el problema puede imprimir un sesgo aún más grave, ya que existen razones para creer que los rechazados por el método anterior son individuos que efectivamente tienen en promedio un riesgo mayor.

Varias opciones se han propuesto para resolver este inconveniente, dentro del debate denominado “**Reject Inference**” consistente en la propuesta de mecanismos para inferir el comportamiento de los individuos rechazados por el sistema anterior de clasificación.

Una de las propuestas es aprobar una determinada cantidad de solicitudes que mediante el método anterior hubieran sido rechazadas, asumiendo durante ese período de tiempo el costo financiero que esta medida traería como consecuencia. De esa manera sería posible modelar la probabilidad de incumplimiento para el segmento, configurando un modelo condicional para los “rechazados” que complete el análisis del riesgo.

Otra práctica similar es la de obtener información externa acerca del comportamiento de los rechazados con otras instituciones que sí concedieron crédito a estos individuos en ese momento (Hand, 1997)

Los métodos más sofisticados y que han provocado mayor intercambio académico incluyen el “Augmentation Method” de Hsia, la modelación del mecanismo de selección muestral como variables omitidas de Heckman, y el algoritmo EM de Feelders<sup>39</sup>.

El “**Augmentation Method**” propuesto por Hsia, es un método que implica la derivación de una función discriminante sobre la muestra total de desarrollo, que separe los aprobados de los rechazados. Para cada valor de la función discriminante se puede asociar un porcentaje de “aprobados”, cuyo inverso sirve como ponderador para los casos que llegaron a formar parte de la muestra. Esto implica que los “aprobados” que presentaban menor probabilidad de serlo, tendrán ponderaciones relativas superiores: bajo el supuesto de que sus características se asemejan más a las de los “rechazados”, la lógica es que este segmento de los “aprobados” se encargue de representar a aquellos

---

<sup>39</sup> Una combinación de estos métodos es propuesta por Crook y Banasik en “Reject Inference, Augmentation and Sample Selection” (2004)

que no llegaron a formar parte de la muestra final. La muestra ponderada de aprobados es luego utilizada para construir el modelo de clasificación de buenos y malos.

**La propuesta de Heckman** aborda el problema del sesgo muestral de una forma diferente: se basa en la consideración del problema como un sesgo de especificación común, dado por la omisión de variables relevantes: la explicación de que estas variables no estén formando parte del modelo radica en que al estar incluidas en el filtro o mecanismo de selección muestral, pasan a ser constantes al interior de la muestra que resulta seleccionada. Este sesgo se puede resolver a través de la estimación de un modelo que incluya las variables omitidas inicialmente, por lo que propone un estimador del mecanismo de selección muestral<sup>40</sup> que corrige el modelo inicial y da como resultado estimaciones consistentes de los parámetros (Heckman, 1979).

**El aporte de Feelders** (2000) al presente debate está dado por su consideración específica del caso en que la predicción de la probabilidad de incumplimiento se realiza por medio de la estimación de un modelo de análisis discriminante lineal o cuadrático. Bajo este supuesto propone la incorporación de los rechazados en la muestra a través de la formulación de un modelo de distribuciones mixtas. Esta medida resuelve el problema del sesgo, dando lugar a estimaciones insesgadas de los parámetros a través del “Algoritmo EM”<sup>41</sup>.

Todos los anteriores métodos tienen la característica de aplicarse bajo un cierto conjunto de supuestos. Con el objetivo de determinar un marco de adecuación de cada uno de los enfoques, nos basaremos en el trabajo de Little y Rubin (1987) donde se propone una clasificación de las distintas modalidades en las cuales se puede presentar la censura en la variable dependiente.

#### **Tipos de censura:**

1. Missing Completely at Random (MCAR): censura completamente aleatoria.
2. Missing at Random (MAR): censura aleatoria.
3. Missing Not at Random (MNAR): censura no aleatoria.

---

<sup>40</sup> Debe cumplirse la distribución normal de los residuos.

<sup>41</sup> Método propuesto por Dempster, Laird y Rubin en 1977 para realizar estimaciones por máxima verosimilitud en el caso de datos incompletos.

**La modalidad 1** es aquella en que la institución aprueba todas las solicitudes o una parte de ellas, pero siempre siguiendo un criterio aleatorio y sin considerar la información disponible. En estas condiciones la estimación de parámetros puede hacerse sin dificultad, ya que se trata de una muestra aleatoria.

**La modalidad 2** abarca los casos en que la decisión de aprobación/rechazo es función de un sub-conjunto de las variables disponibles, pero que para valores fijos de estas variables, la decisión no presenta relación con el comportamiento bueno o malo observado a posteriori. Estos son los supuestos de aplicación del Augmentation Method de Hsia. Se puede demostrar que un modelo logit o probit estimado solamente sobre la muestra de aprobados, da lugar a estimaciones insesgadas aunque ineficientes, por tratarse de una sub-muestra de la original, de aquí la propuesta de Hsia. Un modelo de Análisis Discriminante<sup>42</sup>, por el contrario, arrojaría estimaciones sesgadas de los parámetros, caso especialmente abordado por Feelders.

En **la modalidad 3** encontraríamos las instituciones que basan su decisión en una función de un sub-conjunto de las variables disponibles, al igual que en la modalidad anterior, pero con la diferencia de que aún sujetando los valores de esas variables todavía existe una relación con el comportamiento observado a posteriori. En este caso es necesario modelar el mecanismo de selección que define los rechazos, porque de otra manera no se obtendrían estimaciones insesgadas: este es el caso general abordado por Heckman.

En su trabajo de 2005, Crook y Banasik analizan en detalle las propuestas de Hsia y Heckman (“Augmentation..” y “Sample Selection..”), realizando estimaciones a partir de una muestra experimental de créditos que se aprobaron en un 100%, y que a su vez podían diferenciarse en créditos que normalmente habrían sido aprobados y créditos que normalmente habrían sido rechazados. Además de comparar los resultados de ambos métodos, los autores siguen la hipótesis de que la utilización conjunta de ambos métodos consigue resultados mejores que la utilización individual de cualquiera de ellos.

---

<sup>42</sup>Por no cumplirse el supuesto de normalidad de las probabilidades condicionadas  $P(X/B)$  y  $P(X/M)$ , donde  $X$  es la matriz de “características” y  $M, B$  los comportamientos “Malo” y “Bueno” respectivamente.

Los resultados revelan que ambos métodos mejoran la estimación de los modelos con respecto a la situación donde no se infiere el comportamiento de los rechazados, aunque el beneficio es de poca cuantía y casi insignificante para el caso de altas tasas de aprobación.

### **B) Cambios en la población.**

La construcción de un modelo de Credit Scoring requiere fijar un punto de observación suficientemente alejado en el tiempo, de forma tal que se obtenga un período de observación de comportamientos de duración adecuada. Si se pretende clasificar a los individuos en base a su probabilidad de incumplimiento a 12 meses, la lejanía del punto de observación puede estar implicando cambios en la población (debido a la evolución de los mercados, o la situación macro-económica) y restando validez a las predicciones.

Para detectar estos cambios poblacionales puede hacerse estadística descriptiva de las variables consideradas para el desarrollo del modelo, comparando los resultados para varios momentos del tiempo.

Si el supuesto implícito de que la población ha mantenido sus características en relación al riesgo de incumplimiento no se cumple, se puede optar por la reducción del período de comportamiento. Si el objetivo es medir esta variable en un período superior, puede servir a esta finalidad modelar la probabilidad de que los individuos que llegan al final del nuevo período en situación de default persistan en la misma situación hasta el final. Este método resuelve en cierta medida el problema, pero acarrea una importante pérdida de precisión cuyas consecuencias habrán de ser analizadas con detenimiento.

### **C) Valores faltantes.**

Por lo general la información utilizada para desarrollar los modelos de clasificación presenta problemas de valores faltantes para algunas variables explicativas. La razón principal es que una parte de la información proviene de formularios de solicitud completados por los propios solicitantes.

En este punto el tratamiento que se da a los datos faltantes también puede generar sesgos indeseables. **Si las observaciones con datos faltantes formaran un conjunto no aleatorio de la muestra, extraer estos datos sería nocivo para los resultados,** presentándose problemas de la misma naturaleza que los presentados en el caso de censura en la variable dependiente.

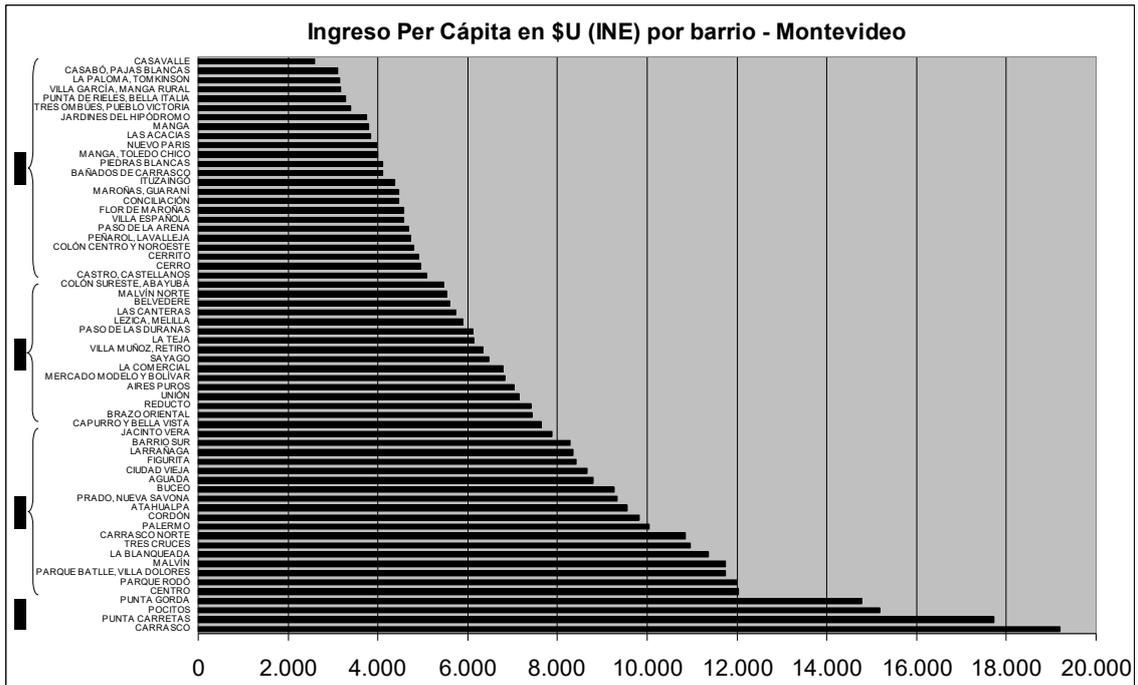
Las estrategias comúnmente utilizadas para lidiar con valores faltantes explicitadas por Hand y Henley (1997) son:

- Considerar el valor faltante como un atributo adicional
- Extraer las variables incompletas de entre las candidatas
- Sustituir los valores faltantes con algún criterio
- Sustituir los valores faltantes en forma iterativa por medio de algún modelo
- Extraer de la muestra los casos que presentan valores faltantes

#### 4. Determinación del ingreso per cápita de la zona de residencia en base a ECH-INE 2005.

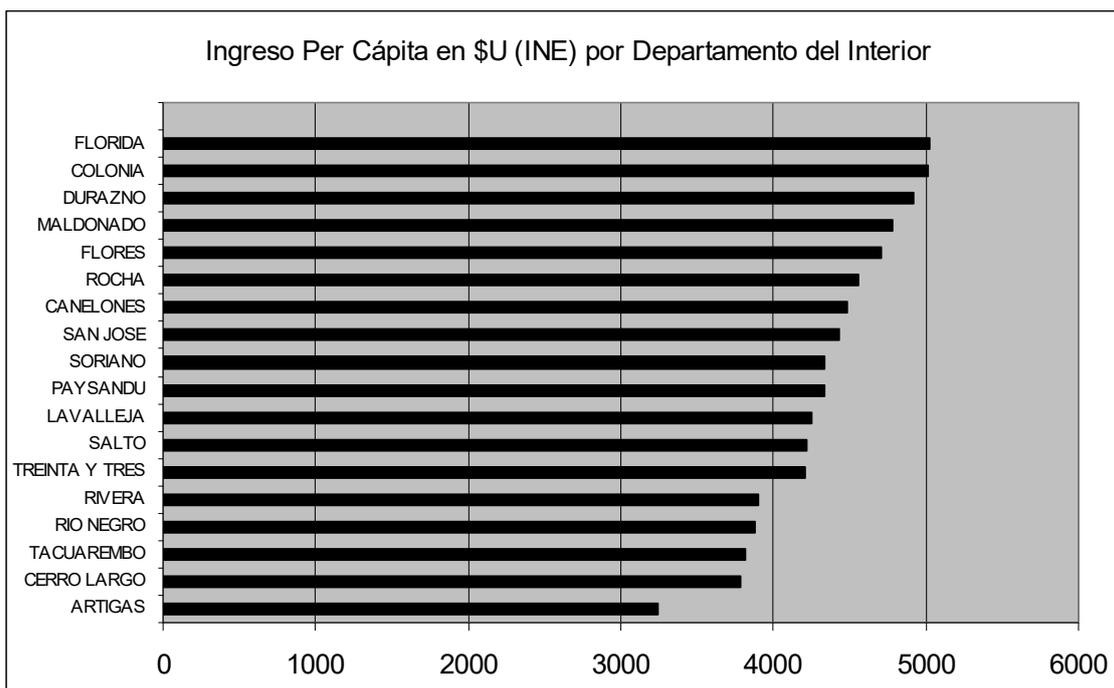
##### 1. Ingreso per cápita por barrio de Montevideo y delimitación de Zonas de Ingreso.

nombarrío	suma de ht11	suma de d16	Ing Prom p/c	Zona Ing
CARRASCO	9.116.216	475	19.192	ZONA1
PUNTA CARRETAS	12.355.956	697	17.727	ZONA1
POCITOS	31.287.191	2062	15.173	ZONA1
PUNTA GORDA	6.248.751	423	14.772	ZONA1
CENTRO	6.041.907	502	12.036	ZONA2
PARQUE RODÓ	3.667.333	306	11.985	ZONA2
PARQUE BATLLE, VILLA DOLORES	9.980.393	850	11.742	ZONA2
MALVÍN	10.071.113	858	11.738	ZONA2
LA BLANQUEADA	3.227.842	284	11.366	ZONA2
TRES CRUCES	4.786.059	437	10.952	ZONA2
CARRASCO NORTE	3.636.011	335	10.854	ZONA2
PALERMO	2.770.996	276	10.040	ZONA2
CORDÓN	8.385.103	853	9.830	ZONA2
ATAHUALPA	2.396.067	251	9.546	ZONA2
PRADO, NUEVA SAVONA	5.299.300	568	9.330	ZONA2
BUCEO	8.996.328	971	9.265	ZONA2
AGUADA	3.402.788	387	8.793	ZONA2
CIUDAD VIEJA	1.818.476	210	8.659	ZONA2
FIGURITA	2.622.564	312	8.406	ZONA2
LARRAÑAGA	4.580.446	549	8.343	ZONA2
BARRIO SUR	2.216.703	268	8.271	ZONA2
JACINTO VERA	2.009.491	255	7.880	ZONA2
CAPURRO Y BELLA VISTA	2.831.955	371	7.633	ZONA3
BRAZO ORIENTAL	3.130.444	421	7.436	ZONA3
REDUCTO	2.505.597	338	7.413	ZONA3
UNIÓN	7.063.623	988	7.149	ZONA3
AIRES PUROS	2.545.619	362	7.032	ZONA3
MERCADO MODELO Y BOLÍVAR	2.592.429	379	6.840	ZONA3
LA COMERCIAL	1.959.424	289	6.780	ZONA3
SAYAGO	2.067.571	319	6.481	ZONA3
VILLA MUÑOZ, RETIRO	2.041.303	322	6.339	ZONA3
LA TEJA	2.526.366	411	6.147	ZONA3
PASO DE LAS DURANAS	1.896.110	310	6.116	ZONA3
LEZICA, MELILLA	1.775.729	301	5.899	ZONA3
LAS CANTERAS	2.687.072	468	5.742	ZONA3
BELVEDERE	2.601.215	465	5.594	ZONA3
MALVÍN NORTE	3.044.473	551	5.525	ZONA3
COLÓN SURESTE, ABAYUBÁ	1.533.758	281	5.458	ZONA3
CASTRO, CASTELLANOS	1.588.750	312	5.092	ZONA4
CERRO	2.852.964	577	4.944	ZONA4
CERRITO	2.233.217	454	4.919	ZONA4
COLÓN CENTRO Y NOROESTE	2.233.205	465	4.803	ZONA4
PEÑAROL, LAVALLEJA	3.307.065	698	4.738	ZONA4
PASO DE LA ARENA	1.737.243	371	4.683	ZONA4
VILLA ESPAÑOLA	2.665.732	582	4.580	ZONA4
FLOR DE MAROÑAS	1.895.155	415	4.567	ZONA4
CONCILIACIÓN	1.329.139	298	4.460	ZONA4
MAROÑAS, GUARANÍ	1.786.702	401	4.456	ZONA4
ITUZAINGÓ	1.327.462	303	4.381	ZONA4
BAÑADOS DE CARRASCO	518.430	126	4.115	ZONA4
PIEDRAS BLANCAS	1.648.695	402	4.101	ZONA4
MANGA, TOLEDO CHICO	1.526.486	382	3.996	ZONA4
NUEVO PARIS	2.088.212	525	3.978	ZONA4
LAS ACACIAS	1.780.542	464	3.837	ZONA4
MANGA	1.353.436	356	3.802	ZONA4
JARDINES DEL HIPÓDROMO	1.637.987	437	3.748	ZONA4
TRES OMBÚES, PUEBLO VICTORIA	1.249.883	368	3.396	ZONA4
PUNTA DE RIELES, BELLA ITALIA	1.433.276	437	3.280	ZONA4
VILLA GARCÍA, MANGA RURAL	1.132.905	358	3.165	ZONA4
LA PALOMA, TOMKINSON	2.082.539	661	3.151	ZONA4
CASABÓ, PAJAS BLANCAS	1.682.376	541	3.110	ZONA4
CASAVALLE	1.660.845	641	2.591	ZONA4



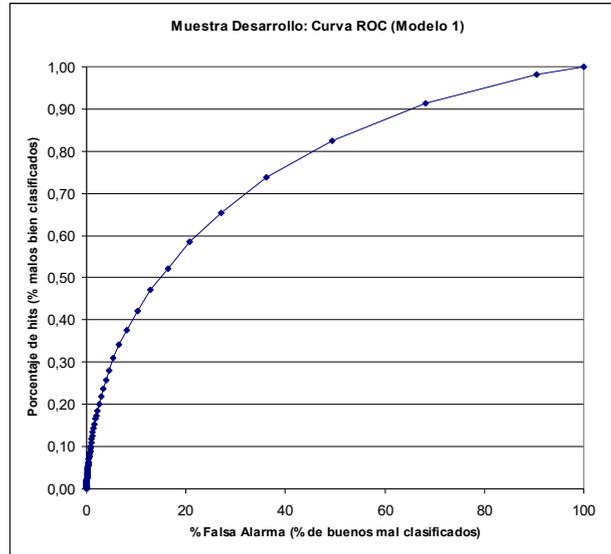
**2. Ingreso per cápita por departamento del Interior.**

Departamento	suma de ht11	suma de d16	Ing Prom p/c
FLORIDA	3.391.503	675	5.024
COLONIA	7.075.667	1.411	5.015
DURAZNO	3.318.555	674	4.924
MALDONADO	9.791.678	2.046	4.786
FLORES	2.259.766	480	4.708
ROCHA	4.726.437	1.038	4.553
CANELONES	26.765.916	5.975	4.480
SAN JOSE	5.591.566	1.262	4.431
SORIANO	4.903.010	1.132	4.331
PAYSANDU	6.435.109	1.486	4.330
LAVALLEJA	3.228.679	760	4.248
SALTO	6.673.357	1.583	4.216
TREINTA Y TRES	2.729.539	649	4.206
RIVERA	5.571.396	1.428	3.902
RIO NEGRO	3.137.939	808	3.884
TACUAREMBO	4.324.308	1.134	3.813
CERRO LARGO	4.326.528	1.144	3.782
ARTIGAS	4.436.790	1.366	3.248



## 5. Cálculo de los estadísticos “Roc” y “Accuracy Ratio”.

La curva ROC (Receiver Operating Characteristic) grafica para cada punto de corte, el porcentaje de malos que se aciertan (evento denominado tasa de “hits”) contra el porcentaje de buenos que se clasifican como malos (evento denominado “falsa alarma”).



El análisis de performance del modelo se basa en la medición de cuánto se aproxima la curva ROC al punto (0;100), donde se acierta el 100% de los malos con un nivel de “falsa alarma” de 0%. Cuando esto ocurre, la curva coincide con los ejes y el área debajo de ella vale 1: el modelo es perfecto.

Por el contrario, si el modelo asignara las probabilidades en forma aleatoria, la medida del área debajo de la curva ROC sería de 0,5: este valor se toma como el mínimo a partir del cual el modelo realiza un aporte significativo a la discriminación.

La estimación del indicador se construye a través de las formas geométricas que quedan debajo de la curva. La sumatoria de todas las áreas da lugar a la siguiente ecuación:

$$ADROC = \sum \frac{1}{2} \cdot (P(p_m \geq c_i) + P(p_m \geq c_{i-1})) \cdot P(p_b = c_i)$$

donde  $p_m$  y  $p_b$  son las probabilidades de incumplimiento estimadas para la población de malos y buenos respectivamente, y  $c_i$  es el punto de corte de referencia<sup>43</sup>.

<sup>43</sup> En la ecuación se está sumando el área de los trapecios que quedan debajo de la curva ROC. El porcentaje de buenos que tienen una probabilidad estimada igual a  $c_i$ , se multiplica por la suma del porcentaje de “hits” del punto de corte  $i$  y del punto de corte  $i-1$ , (porcentaje de los malos cuya

El valor calculado en la muestra de desarrollo para el Modelo 1 es 0,76 y para el Modelo 2 es 0,75.

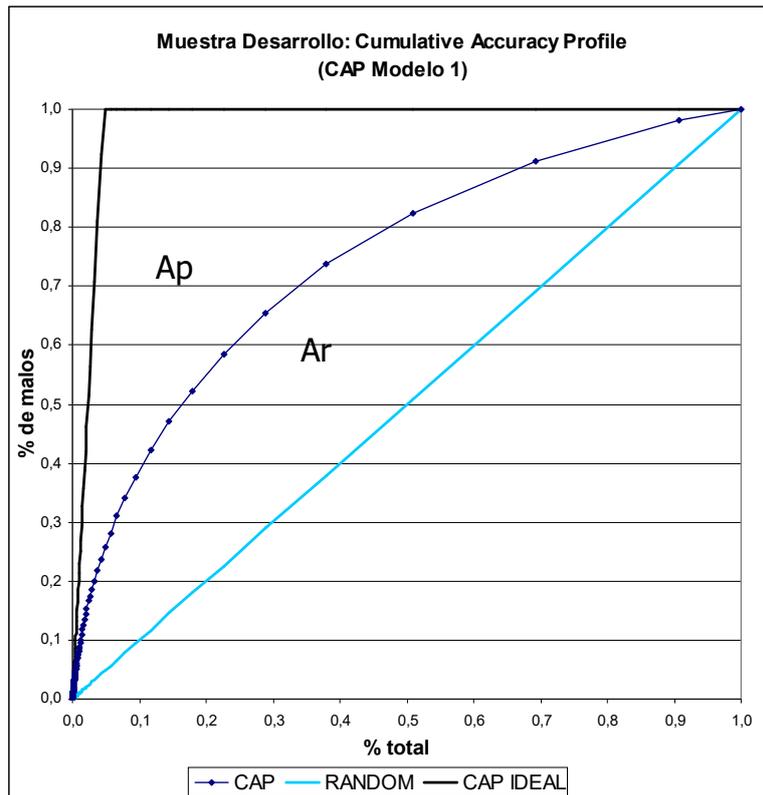
La curva CAP (“Cumulative Accuracy Profiles”) se forma a través de la asociación de la proporción de malos y la proporción total de casos calculada para cada probabilidad de incumplimiento ordenada en forma decreciente.

Si la curva CAP coincidiera con la diagonal, el modelo estaría otorgando idéntica probabilidad de incumplimiento a un malo que a cualquier individuo tomado al azar. Un modelo perfecto acumularía el 100% de los malos para el nivel de probabilidad que acumula un porcentaje de la muestra equivalente a la tasa de malos global.

En el gráfico pueden compararse las pendientes de la curva CAP y la diagonal para la muestra de desarrollo: en los tramos de alta probabilidad la proporción de malos supera claramente a la de buenos. A su vez, la CAP ideal está representada por la curva que se encuentra más cerca del eje vertical: el 100% de los malos se concentra en el primer 4.9% de la muestra total.

---

probabilidad de incumplimiento es mayor o igual a  $c_i$  y  $c_{i-1}$ ).



La calidad del modelo puede medirse a través de la comparación de las áreas entre las tres curvas: el área “Ar” comprendida entre la CAP del modelo y la CAP de un modelo “random” es una medida de la discriminación del modelo, que debe compararse con el área “Ap” entre la CAP ideal y la CAP random. El ratio entre ambas medidas da lugar al Accuracy Ratio:

$$AR = Ar / Ap$$

Engelmann et al. demuestran que este estadístico se relaciona con el área debajo de la curva ROC mediante la fórmula:

$$AR = 2 \cdot ADROC - 1$$

$$AR (\text{Muestra Desarrollo} / \text{Modelo 1}) = 2 \cdot 0,75627434 - 1 = 0,513.$$

## **6. Análisis de correlaciones entre el monto de las operaciones incumplidas y la probabilidad de incumplimiento a priori.**

### **A) Estimación del monto promedio de los créditos otorgados.**

Para estimar el monto promedio de los créditos otorgados se manejaron varias alternativas, una de ellas fue la utilización del monto promedio de las operaciones incumplidas registradas en el período de 12 meses utilizado para analizar comportamientos.

El supuesto implícito que es necesario cuestionar de antemano es que dado un cierto nivel de riesgo a priori no observable por el prestatario, los montos concedidos en préstamo son independientes de dicho nivel de riesgo.

El primer mecanismo que puede operar en contra de este supuesto es que luego de los diversos filtros ya aplicados a los solicitantes, las entidades todavía sean capaces de discriminar el riesgo entre los aprobados, y por ende puedan decidir otorgar menores montos a los individuos más riesgosos. Otro mecanismo podría operar en forma contraria, y es el que lleva a los individuos más riesgosos, a sabiendas de que no van a devolver el crédito, a verse incentivados a solicitar montos altos.

A continuación se presenta la salida de SPSS para el análisis de correlaciones entre el monto de las operaciones incumplidas y la probabilidad estimada a priori por el modelo 1 en la muestra de incumplidores utilizada para desarrollo:

**Correlaciones**

		Probabilidad pronosticada	monto default
Probabilidad pronosticada	Correlación de Pearson	1	-,014
	Sig. (bilateral)		,447
	N	2808	2808
monto default	Correlación de Pearson	-,014	1
	Sig. (bilateral)	,447	
	N	2808	2808

Dado a que no se detecta una correlación significativa entre las variables, se utilizará el monto promedio del total de operaciones incumplidas como estimación del monto promedio del resto de las operaciones. En forma previa se analizaron estas variables en busca de detectar y sustituir outliers para evitar que afecten el análisis de resultados.

**B) Análisis de outliers para las variables Monto y Saldo Incumplido en período de comportamientos.**

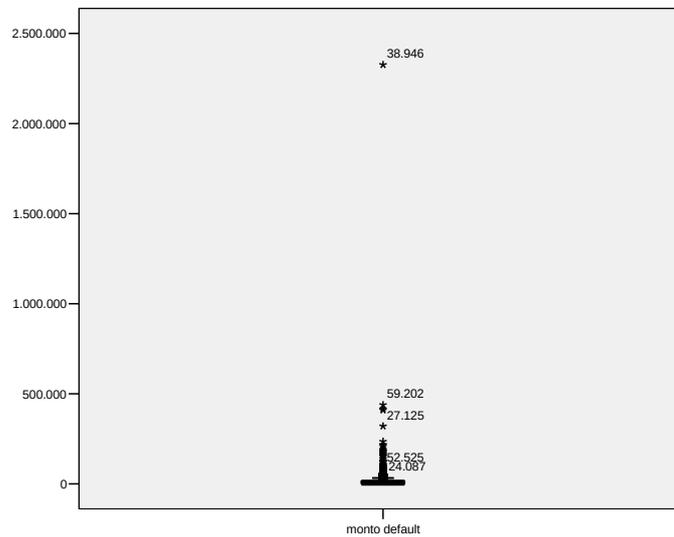
**Estadísticos**

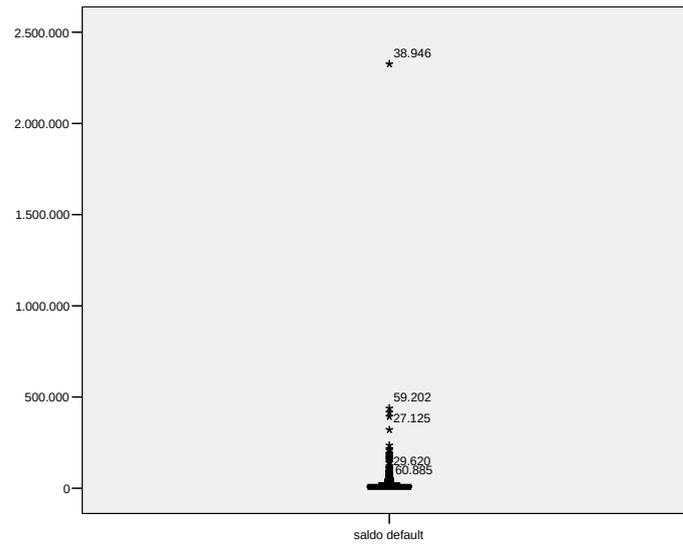
		monto default	saldo default
N	Válidos	2808	2808
	Perdidos	0	0
Media		14174,53	13168,12
Mediana		7263,80	6575,00
Máximo		2326166	2326166
Percentiles	25	3268,80	2977,75
	50	7263,80	6575,00
	75	14978,26	13367,38
	95	43189,37	40991,09

Valores extremos

			Número del caso	Valor
monto default	Mayores	1	38946	2326166
		2	59202	438354
		3	38182	414940
		4	25168	409013
		5	27125	320272
	Menores	1	28246	260
		2	59554	267
		3	7287	271
		4	16205	275
		5	10689	275
saldo default	Mayores	1	38946	2326166
		2	59202	438354
		3	38182	414940
		4	25168	391971
		5	27125	320272
	Menores	1	53078	250
		2	54772	257
		3	28246	260
		4	55498	267
		5	59554	267

Diagrama de Cajas





El monto del caso 38946 de la muestra de incumplidores se sustituyó por el monto máximo del resto de los casos, y lo mismo se realizó para el respectivo saldo incumplidor. Los estadísticos descriptivos de las dos variables luego de la sustitución se presentan a continuación.

**Estadísticos**

		monto default	saldo default
N	Válidos	2808	2808
	Perdidos	0	0
Media		13502,24	12495,82
Mediana		7263,80	6575,00
Máximo		438354	438354
Percentiles	25	3268,80	2977,75
	50	7263,80	6575,00
	75	14978,26	13367,38
	95	43189,37	40991,09

## 7. Vínculo entre los valores de intersección hallados para “RC” y “g”.

Dado que el costo total de cada error  $ii$  ( $\$E_{ii}$ ) depende del monto promedio de los préstamos  $\$P$ , y de la tasa de ganancia promedio por préstamo, la relación de costos utilizada en el análisis de la tabla de clasificación para el punto de corte  $p = 0,046$  puede expresarse en términos de  $\$P$  y  $g$ , de la siguiente manera:

$$RC = \$ E_i / \$ E_{ii} = \$ E_i / (\$P.g)$$

Despejando  $g$  se obtiene:

$$g = (\$ E_i / \$P). RC$$

En el análisis inicial se había concluido que la relación de costos necesaria para que la utilización de la regla fuera beneficiosa en la muestra de desarrollo era de 8,76. Si se cumplieran los supuestos estipulados<sup>44</sup>, dados los valores ciertos de las variables que relacionan este indicador con la tasa de ganancia “ $g$ ”, se debería arribar a un valor de esa tasa que también equilibre la ecuación:

$$RC = \$ E_i / \$ E_{ii} = \$ E_i / (\$ P.g)$$

Valores observados (muestra desarrollo):

Monto promedio préstamos ( $\$ P$ ): 13.502,24

Saldo Incumplido promedio ( $\$ E_i$ ): 12.495,82

Sustituyendo los valores observados de  $\$E_i$  y  $\$P$ , se obtiene:

$$RC = 0.9254 / g$$

$$g = 0.9254 / 8.76 = 0.1056$$

---

<sup>44</sup> El costo de los errores es constante para distintos niveles de probabilidad de incumplimiento.

La condición expresada en términos de  $g$  implica una tasa mayor que la  $g = 0,1024$  encontrada; ¿por qué no se mantiene esta relación?:

Dado que **los \$ Ei no son constantes** para los distintos niveles de riesgo (o probabilidad de incumplimiento a priori), el ahorro se hace nulo antes de que la tasa llegue al valor de 10.56%. De hecho, los \$Ei para incumplimientos con  $p \geq 0,046$  en la muestra para desarrollo valen en promedio menos que los \$Ei con  $p < 0,046$ . Esto quiere decir que los errores que la regla logra evitar “pesan” menos que los otros (y que el promedio muestral), y **en consecuencia** es menor la contrapartida en términos de \$Eii que puede soportar la ecuación para mantenerse en 0.

Como \$P es constante, esto se traslada a  $g$ , dando como resultado un valor de intersección para  $g$  de 0,1024.

## Anexo III: Salidas y resultados.

### 1. Diagnóstico de Multicolinealidad

#### Modelo 1.

Coefficientes<sup>a</sup>

Modelo		Estadísticos de colinealidad	
		Tolerancia	FIV
1	Sexo	,969	1,032
	Edad	,020	49,130
	Transf_Edad	,022	45,941
	DummyCasado	,103	9,662
	DummyDivorciado	,298	3,358
	DummySoltero	,103	9,701
	MVD_1	,369	2,708
	MVD_2	,286	3,500
	MVD_4	,409	2,442
	DURAZNO	,955	1,047
	ARTIGAS	,959	1,042
	CERROLARGO	,968	1,033
	TACUAREMBO	,959	1,043
	RIONEGRO	,955	1,047
	RIVERA	,968	1,033
	TREINTAYTRES	,959	1,042
	SALTO	,894	1,118
	COLONIA	,892	1,121
	LAVALLEJA	,919	1,088
	PAYSANDU	,849	1,178
	SORIANO	,911	1,097
	SANJOSE	,850	1,176
	CANELONES	,444	2,252
	ROCHA	,959	1,043
	FLORES	,982	1,018
	MALDONADO	,724	1,380
	FLORIDA	,934	1,071
	Transf_Cant_ConsHist	,517	1,935
	Cant_Consfin_6m	,654	1,529
	Cant_Consfin_1m	,861	1,161
	Cant_Cons_SNF_6m	,966	1,035
	Cant_afi_fin	,262	3,824
	Fidelidad	,552	1,812
	Dummy_IncsAbrilporEdad	,218	4,592
	Dummy_Incs_finporDummy_Incscrisis	,349	2,867
	Dummy_Incs_Fin	,160	6,246
	Dummy_ExtraviosCI	,990	1,010

a. Variable dependiente: VARIABLE DEPENDIENTE

**Modelo 2.**

**Coefficientes<sup>a</sup>**

Modelo		Estadísticos de colinealidad	
		Tolerancia	FIV
1	Sexo	,969	1,032
	Edad	,020	49,059
	Transf_Edad	,022	45,882
	DummyCasado	,104	9,658
	DummyDivorciado	,298	3,356
	DummySoltero	,103	9,695
	INE_Interior	,081	12,305
	DummyMVDporINE_ Interior	,081	12,286
	Transf_Cant_ConsHist	,519	1,926
	Cant_Consfin_6m	,655	1,528
	Cant_Consfin_1m	,861	1,161
	Cant_Cons_SNF_6m	,968	1,033
	Cant_afi_fin	,262	3,818
	Fidelidad	,553	1,809
	Dummy_ IncsAbrilporEdad	,218	4,587
	Dummy_Incs_ finporDummy_Incscrisis	,349	2,864
	Dummy_Incs_Fin	,160	6,237
	Dummy_ExtraviosCI	,991	1,009

a. Variable dependiente: VARIABLE DEPENDIENTE

## 2. Salidas Regresión Logística en SPSS

### Modelo 1.

### Logistic Regression

**Case Processing Summary**

Unweighted Cases <sup>a</sup>		N	Percent
Selected Cases	Included in Analysis	60479	100.0
	Missing Cases	0	.0
	Total	60479	100.0
Unselected Cases		0	.0
Total		60479	100.0

a. If weight is in effect, see classification table for the total number of cases.

#### Dependent Variable Encoding

Original Value	Internal Value
BUENO	0
MALO	1

### Block 0: Beginning Block

**Iteration History<sup>a,b,c</sup>**

Iteration	-2 Log likelihood	Coefficients
		Constant
Step 1	28449.312	-1.814
0 2	23290.129	-2.592
3	22737.843	-2.950
4	22723.704	-3.020
5	22723.690	-3.022
6	22723.690	-3.022

a. Constant is included in the model.

b. Initial -2 Log Likelihood: 22723.690

c. Estimation terminated at iteration number 6 because parameter estimates changed by less than .001.

**Classification Table<sup>a,b</sup>**

Observed			Predicted		
			VARIABLE DEPENDIENTE		Percentage Correct
			BUENO	MALO	
Step 0	VARIABLE DEPENDIENTE	BUENO MALO	0 0	57671 2808	.0 100.0
Overall Percentage					4.6

a. Constant is included in the model.

b. The cut value is .046

**Variables in the Equation**

	B	S.E.	Wald	df	Sig.	Exp(B)
Step 0 Constant	-3.022	.019	24457.944	1	.000	.049

**Variables not in the Equation**

Step	Variables	Score	df	Sig.
0	Sexo	1.620	1	.203
	Edad	452.024	1	.000
	Transf_Edad	364.390	1	.000
	DummyCasado	250.170	1	.000
	DummyDivorciado	11.480	1	.001
	DummySoltero	213.670	1	.000
	MVD_1	255.780	1	.000
	MVD_2	56.124	1	.000
	MVD_4	120.421	1	.000
	DURAZNO	.095	1	.758
	ARTIGAS	9.235	1	.002
	CERROLARGO	.246	1	.620
	TACUAREMBO	3.395	1	.065
	RIONEGRO	.773	1	.379
	RIVERA	8.735	1	.003
	TREINTAYTRES	.068	1	.794
	SALTO	16.489	1	.000
	COLONIA	1.566	1	.211
	LAVALLEJA	.623	1	.430
	PAYSANDU	8.082	1	.004
	SORIANO	10.547	1	.001
	SANJOSE	.890	1	.346
	CANELONES	19.154	1	.000
	ROCHA	6.888	1	.009
	FLORES	1.672	1	.196
	MALDONADO	8.831	1	.003
	FLORIDA	2.538	1	.111
	Transf_Cant_ConsHist	1.382	1	.240
	Cant_Consfin_6m	1426.681	1	.000
	Cant_Consfin_1m	748.752	1	.000
	Cant_Cons_SNF_6m	147.680	1	.000
	Cant_afi_fin	1145.426	1	.000
	Fidelidad	601.426	1	.000
	Dummy_IncsAbril by Edad	256.309	1	.000
Dummy_Incs_Fin by Dummy_IncsCrisis	94.000	1	.000	
Dummy_Incs_Fin	305.449	1	.000	
Dummy_ExtraviosCI	78.657	1	.000	

a. Residual Chi-Squares are not computed because of redundancies.

**Block 1: Method = Enter**

**Omnibus Tests of Model Coefficients**

		Chi-square	df	Sig.
Step 1	Step	2777.418	37	.000
	Block	2777.418	37	.000
	Model	2777.418	37	.000

**Model Summary**

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	19946.273 <sup>a</sup>	.045	.143

a. Estimation terminated at iteration number 7 because parameter estimates changed by less than .001.

**Hosmer and Lemeshow Test**

Step	Chi-square	df	Sig.
1	12.154	8	.144

**Contingency Table for Hosmer and Lemeshow Test**

		VARIABLE DEPENDIENTE = BUENO		VARIABLE DEPENDIENTE = MALO		Total
		Observed	Expected	Observed	Expected	
Step 1	1	5990	6002.433	58	45.567	6048
	2	5983	5971.359	65	76.641	6048
	3	5935	5945.250	113	102.750	6048
	4	5934	5917.987	114	130.013	6048
	5	5901	5887.554	148	161.446	6049
	6	5854	5848.480	194	199.520	6048
	7	5811	5798.012	237	249.988	6048
	8	5724	5722.051	324	325.949	6048
	9	5588	5586.619	460	461.381	6048
	10	4951	4991.254	1095	1054.746	6046

Classification Table<sup>a</sup>

Observed			Predicted		
			VARIABLE DEPENDIENTE		Percentage Correct
			BUENO	MALO	
Step 1	VARIABLE DEPENDIENTE	BUENO MALO	41070 912	16601 1896	71.2 67.5 71.0
Overall Percentage					

a. The cut value is .046

Variables in the Equation

Step	Variable	B	S.E.	Wald	df	Sig.	Exp(B)	95.0% C.I. for EXP(B)	
								Lower	Upper
1	Sexo	-.093	.041	5.127	1	.024	.911	.841	.988
	Edad	-.077	.010	60.120	1	.000	.926	.908	.944
	Transf_Edad	.000	.000	23.656	1	.000	1.000	1.000	1.001
	DummyCasado	-.538	.127	17.824	1	.000	.584	.455	.750
	DummyDivorciado	-.147	.142	1.075	1	.300	.863	.654	1.140
	DummySoltero	-.408	.135	9.108	1	.003	.665	.510	.867
	MVD_1	-1.215	.098	154.488	1	.000	.297	.245	.359
	MVD_2	-.544	.072	57.566	1	.000	.581	.504	.668
	MVD_4	.025	.075	.112	1	.738	1.025	.885	1.187
	DURAZNO	-.422	.314	1.806	1	.179	.656	.355	1.213
	ARTIGAS	.435	.253	2.964	1	.085	1.545	.942	2.535
	CERROLARGO	-.277	.363	.580	1	.446	.758	.372	1.545
	TACUAREMBO	.162	.288	.314	1	.575	1.175	.668	2.068
	RIONEGRO	-.596	.370	2.596	1	.107	.551	.267	1.138
	RIVERA	.413	.290	2.034	1	.154	1.511	.857	2.666
	TREINTAYTRES	-.342	.352	.945	1	.331	.710	.356	1.416
	SALTO	.448	.165	7.394	1	.007	1.566	1.133	2.163
	COLONIA	.045	.189	.056	1	.812	1.046	.723	1.513
	LAVALLEJA	.053	.223	.057	1	.812	1.054	.682	1.631
	PAYSANDU	.199	.149	1.775	1	.183	1.220	.911	1.633
	SORIANO	.231	.187	1.532	1	.216	1.260	.874	1.817
	SANJOSE	-.665	.185	12.911	1	.000	.514	.358	.739
	CANELONES	-.131	.080	2.675	1	.102	.877	.750	1.026
	ROCHA	.549	.261	4.439	1	.035	1.732	1.039	2.888
	FLORES	.363	.408	.791	1	.374	1.437	.646	3.198
	MALDONADO	-.003	.114	.001	1	.982	.997	.798	1.246
	FLORIDA	.212	.229	.856	1	.355	1.236	.789	1.938
	Transf_Cant_ConstHist	1.150	.125	84.390	1	.000	3.158	2.471	4.036
	Cant_Constfin_6m	.218	.019	134.124	1	.000	1.244	1.199	1.290
	Cant_Constfin_1m	.261	.030	75.643	1	.000	1.298	1.224	1.376
	Cant_Const_SNF_6m	.096	.021	21.713	1	.000	1.100	1.057	1.145
	Cant_afi_fin	.216	.019	123.731	1	.000	1.241	1.195	1.289
	Fidelidad	-.011	.003	15.786	1	.000	.989	.983	.994
	Dummy_IncsAbril by Edad	.014	.002	34.119	1	.000	1.014	1.009	1.019
	Dummy_Incs_Fin by Dummy_IncsCrisis	-.359	.102	12.501	1	.000	.698	.572	.852
	Dummy_Incs_Fin	.228	.128	3.171	1	.075	1.256	.977	1.615
	Dummy_ExtraviosCl	.310	.052	35.709	1	.000	1.364	1.232	1.510
	Constant	-1.203	.295	16.629	1	.000	.300		

a. Variable(s) entered on step 1: Sexo, Edad, Transf\_Edad, DummyCasado, DummyDivorciado, DummySoltero, MVD\_1, MVD\_2, MVD\_4, DURAZNO, ARTIGAS, CERROLARGO, TACUAREMBO, RIONEGRO, RIVERA, TREINTAYTRES, SALTO, COLONIA, LAVALLEJA, PAYSANDU, SORIANO, SANJOSE, CANELONES, ROCHA, FLORES, MALDONADO, FLORIDA, Transf\_Cant\_ConstHist, Cant\_Constfin\_6m, Cant\_Constfin\_1m, Cant\_Const\_SNF\_6m, Cant\_afi\_fin, Fidelidad, Dummy\_IncsAbril \* Edad, Dummy\_Incs\_Fin \* Dummy\_IncsCrisis, Dummy\_Incs\_Fin, Dummy\_ExtraviosCl.

## Modelo 2.

### Logistic Regression

**Case Processing Summary**

Unweighted Cases <sup>a</sup>		N	Percent
Selected Cases	Included in Analysis	60479	100.0
	Missing Cases	0	.0
	Total	60479	100.0
Unselected Cases		0	.0
Total		60479	100.0

a. If weight is in effect, see classification table for the total number of cases.

#### Dependent Variable Encoding

Original Value	Internal Value
BUENO	0
MALO	1

### Block 0: Beginning Block

**Iteration History<sup>a,b,c</sup>**

Iteration	-2 Log likelihood	Coefficients
		Constant
Step 1	28449.312	-1.814
0	2	-2.592
	3	-2.950
	4	-3.020
	5	-3.022
	6	-3.022

a. Constant is included in the model.

b. Initial -2 Log Likelihood: 22723.690

c. Estimation terminated at iteration number 6 because parameter estimates changed by less than .001.

**Classification Table<sup>a,b</sup>**

Observed			Predicted		
			VARIABLE DEPENDIENTE		Percentage Correct
			BUENO	MALO	
Step 0	VARIABLE DEPENDIENTE	BUENO MALO	0 0	57671 2808	.0 100.0
Overall Percentage					4.6

a. Constant is included in the model.

b. The cut value is .046

**Variables in the Equation**

		B	S.E.	Wald	df	Sig.	Exp(B)
Step 0	Constant	-3.022	.019	24457.944	1	.000	.049

**Variables not in the Equation<sup>a</sup>**

Step	Variables	Score	df	Sig.
0	Sexo	1.620	1	.203
	Edad	452.024	1	.000
	Transf_Edad	364.390	1	.000
	DummyCasado	250.170	1	.000
	DummyDivorciado	11.480	1	.001
	DummySoltero	213.670	1	.000
	MVD_1	255.780	1	.000
	MVD_2	56.124	1	.000
	MVD_4	120.421	1	.000
	INE_Interior	422.525	1	.000
	DummyMVD by INE_ Interior	355.933	1	.000
	Transf_Cant_ConsHist	1.382	1	.240
	Cant_Conshin_6m	1426.681	1	.000
	Cant_Conshin_1m	748.752	1	.000
	Cant_Cons_SNF_6m	147.680	1	.000
	Cant_afi_fin	1145.426	1	.000
	Fidelidad	601.426	1	.000
	Dummy_IncsAbril by Edad	256.309	1	.000
	Dummy_Incs_Fin by Dummy_IncsCrisis	94.000	1	.000
	Dummy_Incs_Fin	305.449	1	.000
Dummy_ExtraviosCI	78.657	1	.000	

a. Residual Chi-Squares are not computed because of redundancies.

**Block 1: Method = Enter**

**Omnibus Tests of Model Coefficients**

		Chi-square	df	Sig.
Step 1	Step	2727.609	21	.000
	Block	2727.609	21	.000
	Model	2727.609	21	.000

**Model Summary**

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	19996.082 <sup>a</sup>	.044	.141

a. Estimation terminated at iteration number 7 because parameter estimates changed by less than .001.

**Hosmer and Lemeshow Test**

Step	Chi-square	df	Sig.
1	23.844	8	.002

**Contingency Table for Hosmer and Lemeshow Test**

		VARIABLE DEPENDIENTE = BUENO		VARIABLE DEPENDIENTE = MALO		Total
		Observed	Expected	Observed	Expected	
Step 1	1	5988	6001.778	60	46.222	6048
	2	5984	5969.750	64	78.250	6048
	3	5929	5943.299	119	104.701	6048
	4	5930	5914.891	117	132.109	6047
	5	5904	5884.711	144	163.289	6048
	6	5838	5846.535	210	201.465	6048
	7	5825	5796.537	223	251.463	6048
	8	5701	5721.424	347	326.576	6048
	9	5623	5589.762	425	458.238	6048
	10	4949	5002.312	1099	1045.688	6048

Classification Table<sup>a</sup>

Observed			Predicted		
			VARIABLE DEPENDIENTE		Percentage Correct
			BUENO	MALO	
Step 1	VARIABLE BUENO		40939	16732	71.0
	DEPENDIENTE MALO		916	1892	67.4
	Overall Percentage				70.8

a. The cut value is .046

Variables in the Equation

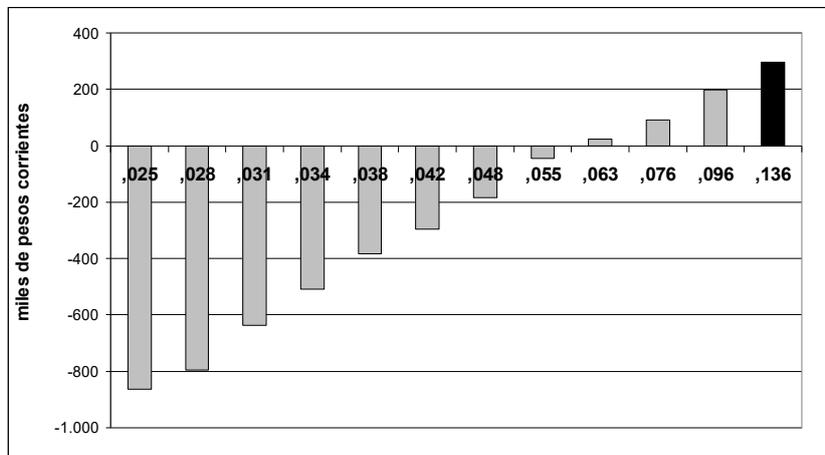
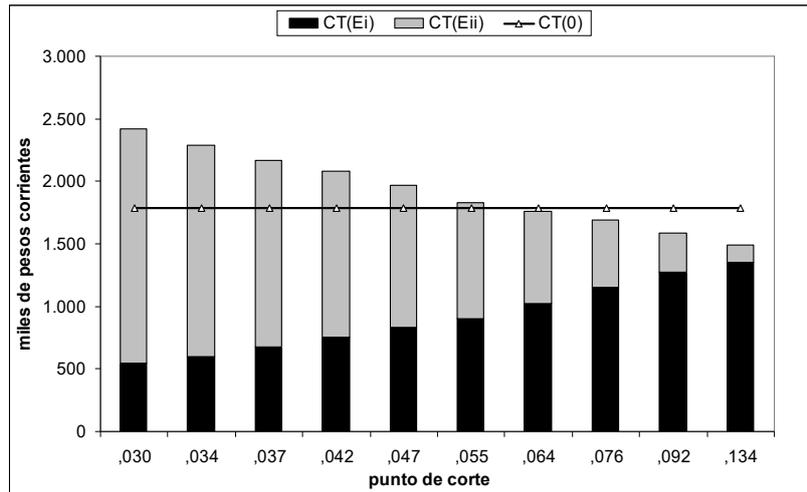
	B	S.E.	Wald	df	Sig.	Exp(B)	95.0% C.I. for EXP(B)	
							Lower	Upper
Step 1 <sup>a</sup>								
Sexo	-.092	.041	5.042	1	.025	.912	.842	.988
Edad	-.076	.010	58.916	1	.000	.927	.909	.945
Transf_Edad	.000	.000	23.136	1	.000	1.000	1.000	1.001
DummyCasado	-.529	.127	17.236	1	.000	.589	.459	.756
DummyDivorciado	-.141	.142	.989	1	.320	.869	.658	1.147
DummySoltero	-.402	.135	8.814	1	.003	.669	.513	.872
MVD_1	-.293	.874	.112	1	.737	.746	.135	4.137
MVD_2	-.231	.307	.564	1	.453	.794	.435	1.450
MVD_4	-.191	.209	.841	1	.359	.826	.549	1.243
INE_Interior	.000	.000	1.351	1	.245	1.000	1.000	1.000
DummyMVD by INE_Interior	.000	.000	1.690	1	.194	1.000	1.000	1.000
Transf_Cant_ConsHist	1.179	.125	89.497	1	.000	3.252	2.547	4.152
Cant_Consfin_6m	.216	.019	132.205	1	.000	1.241	1.196	1.288
Cant_Consfin_1m	.258	.030	74.399	1	.000	1.295	1.221	1.373
Cant_Cons_SNF_6m	.095	.020	21.581	1	.000	1.100	1.057	1.145
Cant_afi_fin	.211	.019	119.162	1	.000	1.235	1.189	1.283
Fidelidad	-.012	.003	16.803	1	.000	.988	.983	.994
Dummy_IncsAbril by Edad	.014	.002	35.093	1	.000	1.014	1.009	1.019
Dummy_Incs_Fin by Dummy_IncsCrisis	-.355	.101	12.265	1	.000	.701	.575	.855
Dummy_Incs_Fin	.229	.128	3.227	1	.072	1.258	.979	1.615
Dummy_ExtraviosCl	.311	.052	35.918	1	.000	1.364	1.233	1.510
Constant	-.651	.619	1.108	1	.292	.521		

a. Variable(s) entered on step 1: Sexo, Edad, Transf\_Edad, DummyCasado, DummyDivorciado, DummySoltero, MVD\_1, MVD\_2, MVD\_4, INE\_Interior, DummyMVD \* INE\_Interior, Transf\_Cant\_ConsHist, Cant\_Consfin\_6m, Cant\_Consfin\_1m, Cant\_Cons\_SNF\_6m, Cant\_afi\_fin, Fidelidad, Dummy\_IncsAbril \* Edad, Dummy\_Incs\_Fin \* Dummy\_IncsCrisis, Dummy\_Incs\_Fin, Dummy\_ExtraviosCl.

**3. Resultados validación *Out of Simple* (Modelo 1).**

		COMPORTAMIENTO		Total	Regla (aprueba si p<)	APROBADOS	
		BUENO	MALO			BUENO	MALO
Probabilidad pronosticada (Categorizada)	<= ,008	147	0	147	0,00	0	0
	,009 - ,010	146	1	147	,009	147	0
	,011 - ,013	149	2	151	,011	293	1
	,014 - ,015	135	5	140	,014	442	3
	,016 - ,017	161	3	164	,016	577	8
	,018 - ,019	142	6	148	,018	738	11
	,020 - ,021	145	2	147	,020	880	17
	,022 - ,024	154	7	161	,022	1.025	19
	,025 - ,027	139	6	145	,025	1.179	26
	,028 - ,030	153	4	157	,028	1.318	32
	,031 - ,033	131	4	135	,031	1.471	36
	,034 - ,037	153	7	160	,034	1.602	40
	,038 - ,041	119	8	127	,038	1.755	47
	,042 - ,047	142	5	147	,042	1.874	55
	,048 - ,054	154	6	160	,048	2.016	60
	,055 - ,062	143	11	154	,055	2.170	66
	,063 - ,075	147	9	156	,063	2.313	77
	,076 - ,095	170	12	182	,076	2.460	86
,096 - ,135	125	6	131	,096	2.630	98	
,136+	103	38	141	,136	2.755	104	
	<b>2.858</b>	<b>142</b>	<b>3.000</b>	1,00	<b>2.858</b>	<b>142</b>	

Análisis para g=0,10:



Análisis para distintos niveles de g:

