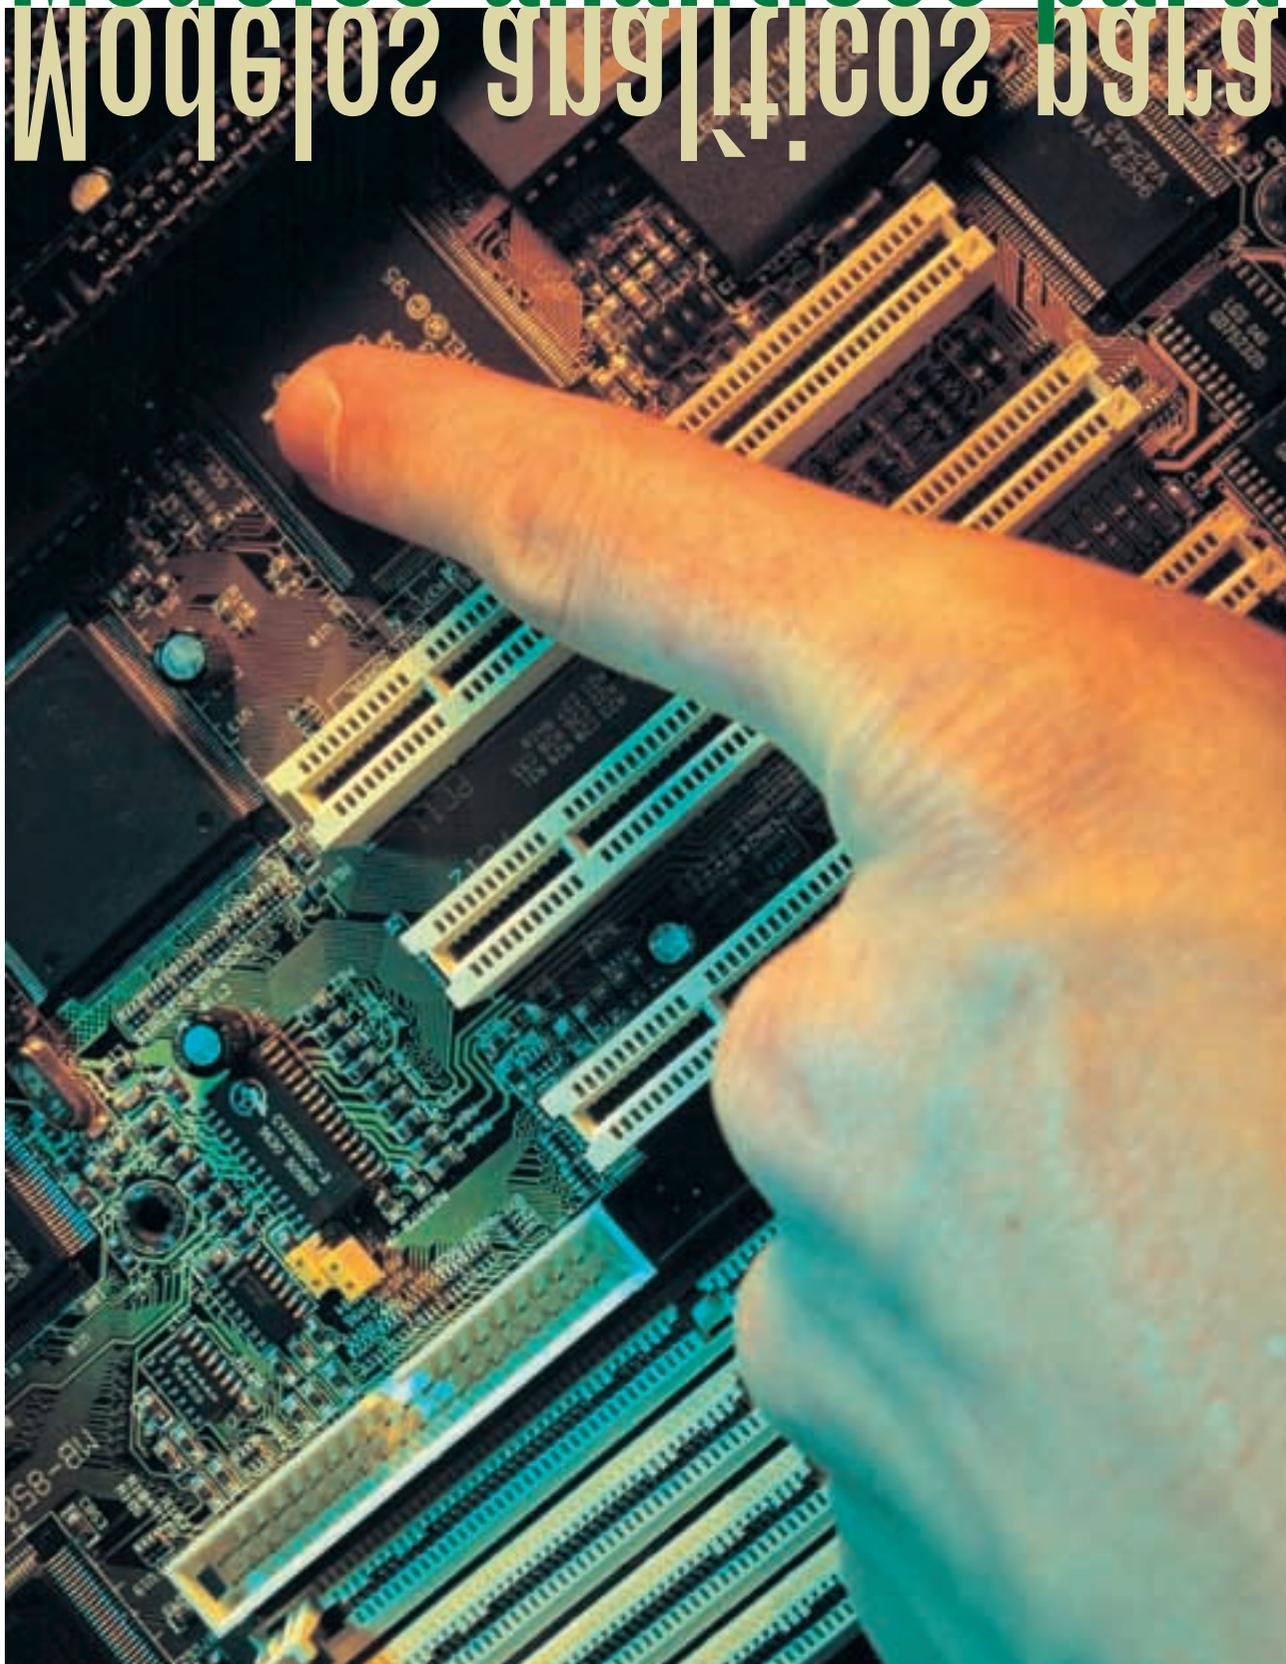


# Modelos analíticos para el

# Modelos analíticos para el



# manejo del riesgo de crédito

## ¿Se ha

**preguntado por qué su banco le otorgó el crédito hipotecario a usted y no a su colega? ¿Cuáles son los criterios para aceptar o rechazar una solicitud de crédito? ¿Cómo los bancos y otras instituciones financieras analizan miles de solicitudes cada mes a costos bajos y tiempos cortos, en casos extremos en línea?**

Los avances tanto en tecnología de información como en modelos analíticos permiten la automatización de las decisiones sobre aceptación o rechazo de una solicitud de crédito que hace pocos años atrás era “puro olfato del ejecutivo”.

El modelo más usado para la evaluación de créditos es el credit scoring que determina un puntaje (score) para un cliente solicitando un crédito.

Este artículo comenta el desarrollo del credit scoring durante los últimos 50 años y presenta una vista general sobre los modelos más usados. Luego se presenta la metodología propuesta por los autores que ha sido aplicada en varios proyectos de manejo de riesgo crediticio. En particular, se aplicó para el Instituto de Desarrollo Agropecuario, INDAP, servicio público que posee un importante programa de créditos a la Pequeña Agricultura. Entre los principales beneficios que se visualizan de la aplicación del modelo está la reducción de los tiempos y costos de evaluación, especialmente para clientes con buen comportamiento, y el mejoramiento de la objetividad de la evaluación, que en el caso en cuestión resulta un objetivo deseado.

### **Pablo Coloma**

Ingeniero Civil Industrial Universidad de Chile; Asesor Ministerio de Economía.



### **Richard Weber**

Ph.D. en Investigación de Operaciones, RWTH Aachen; Ingeniero en Matemáticas, RWTH Aachen, Alemania; Académico Ingeniería Industrial, Universidad de Chile.



### **José Guajardo**

Magíster en Gestión de Operaciones, Universidad de Chile; Ingeniero Civil Industrial, Universidad de Chile.

### **Jaime Miranda**

Magíster en Gestión de Operaciones, Universidad de Chile; Ingeniero Civil Industrial, Universidad de Chile; Académico Universidad Diego Portales.

En términos generales, los modelos analíticos de Credit Scoring se pueden definir como un conjunto de métodos y técnicas cuantitativas que se utilizan para predecir la probabilidad de que un cliente falle y, por ende, no se recupere el crédito otorgado por alguna institución financiera.

## 1. Introducción

Los modelos analíticos para el manejo del riesgo de crédito o Credit Scoring han sido extensamente estudiados y utilizados por un sin fin de instituciones financieras hace más de 50 años, mostrando resultados exitosos en todo el mundo (Thomas 2006). En términos generales, los modelos analíticos de Credit Scoring se pueden definir como un conjunto de métodos y técnicas cuantitativas que se utilizan para predecir la probabilidad de que un cliente falle y, por ende, no se recupere el crédito otorgado por alguna institución financiera.

Durante muchos años el pronóstico y la administración del riesgo financiero estaba en manos de los analistas financieros, quienes cuantificaban el riesgo solamente a través de un conjunto de reglas propias del negocio. La historia de los modelos de Credit Scoring se remonta al año 1936 cuando Fisher introduce la idea de discriminar diferentes grupos dentro de una población específica. Esta idea fue desarrollada más ampliamente por Durand en 1941 donde fue aplicada en un contexto financiero para discriminar entre un “Buen” y un “Mal” pagador; ver (Thomas 2006).

En 1958 Bill Fair y Earl Isaac empezaron con el desarrollo de un sistema analítico que hoy en día conocemos como el FICO Score (Fair Isaac Corporation Score) una de las herramientas más usadas a nivel mundial en relación al análisis de riesgo de créditos.

En los años 60 con la creación de nuevos instrumentos financieros, como por ejemplo: las tarjetas de crédito, los modelos de Credit Scoring realzaron y mostraron su real importancia y utilidad. Según Meyer (1963) este tipo de modelos es superior como predictor que cualquier juicio experto cualitativo. Otro hito importante en este contexto fue el desarrollo del Z-Score propuesto por Altman (1968) que ha sido aplicado en muchas empresas del sector financiero.

Un punto clave de la implementación y posicionamiento de este tipo de modelos, se explica por el explosivo aumento de las solicitudes crediticias y de evaluaciones de riesgo financiero, en donde las antiguas reglas de operación quedan inoperantes ante estos nuevos requerimientos y los altos volúmenes de información. Además, si se considera que los procesos deben ser rápidos y eficientes, el grado de automatización de la toma de decisiones sobre el otorgamiento de un crédito hace fundamental la aplicación de este tipo de modelo. La figura 1 esquematiza algunos de los factores involucrados en el problema de credit scoring:

Figura 1: Elementos del problema de credit scoring



En términos prácticos, los modelos de Credit Scoring permiten una reducción significativa en los tiempos de ejecución de los distintos procesos financieros para el otorgamiento de un crédito, permitiendo con esto una mayor automatización y reduciendo en forma drástica la necesidad de la intervención humana en la evaluación y estimación del riesgo crediticio.

Los principales usuarios de este tipo de modelos son los bancos e instituciones financieras, así como las compañías de seguro o las cadenas de retail. Entre las principales características que tienen en común están la posibilidad de gestionar y administrar el riesgo (Risk Management), en donde al manejar importantes sumas de capital, pequeñas reducciones en el riesgo de la cartera significan enormes incrementos en la rentabilidad del negocio.

Los beneficios reportados por la aplicación de estos modelos no sólo afectan a los bancos e instituciones financieras, sino que directamente a todos los clientes del sector financiero, pues reduce la discriminación errónea de clientes que solicitan algún crédito y provee un análisis más objetivo y acabado de las solicitudes, siendo importante destacar el poder incorporar una enorme batería de variables, concentrando en un solo modelo múltiples factores que pueden afectar el riesgo de una solicitud.

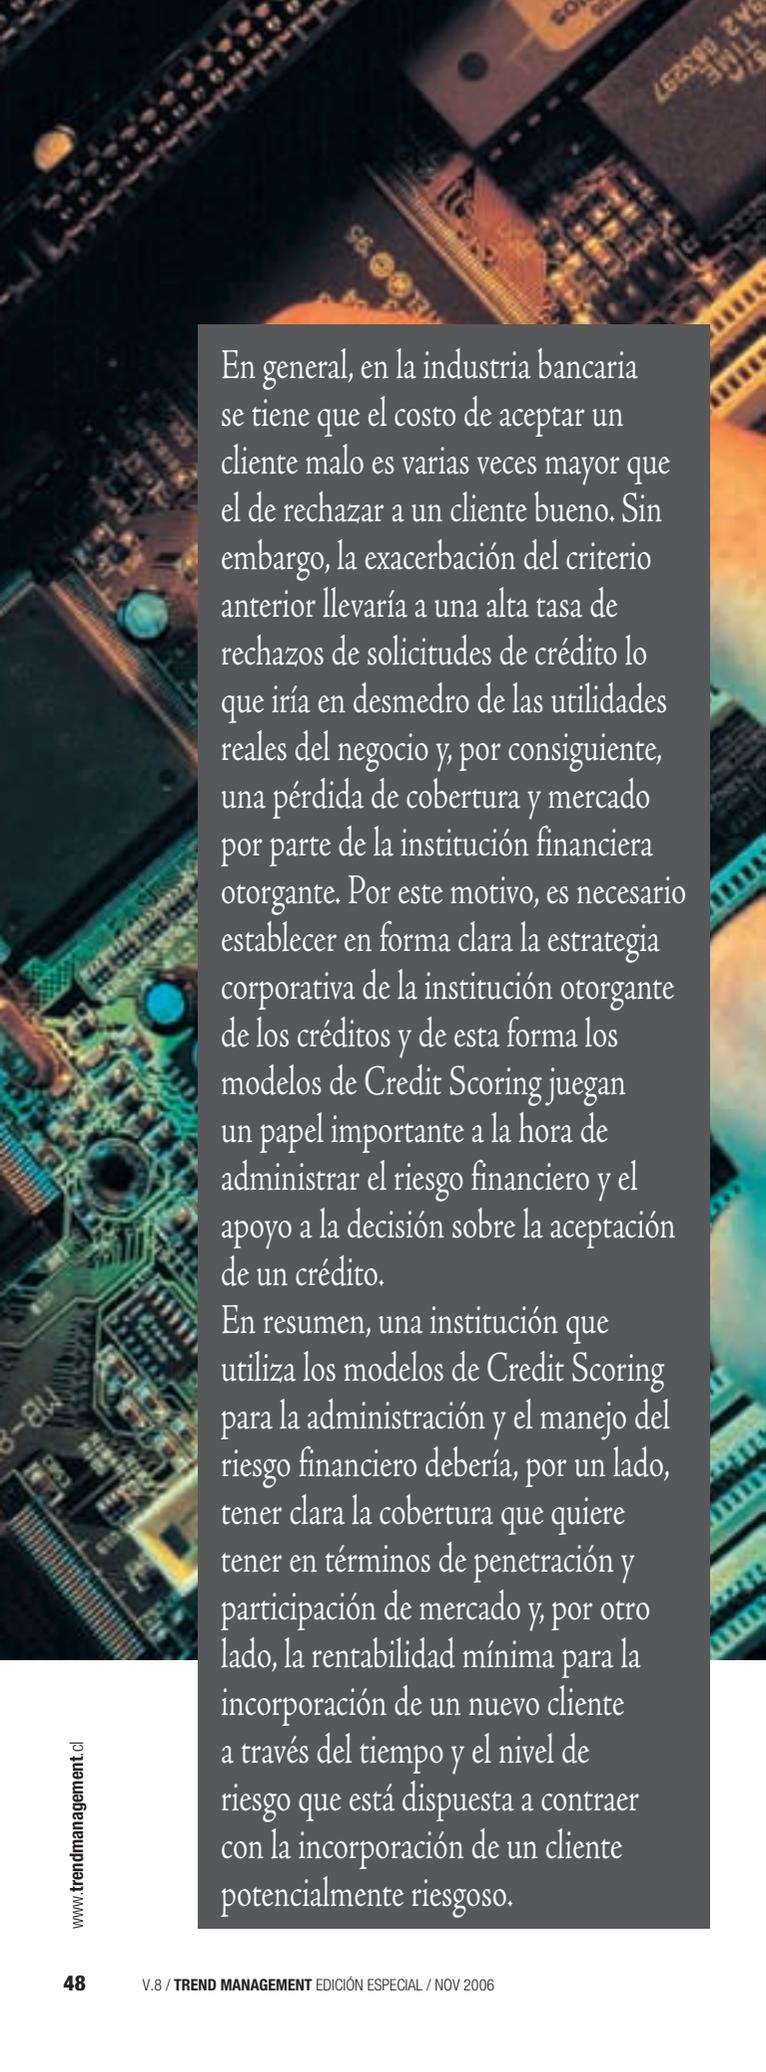
¿Cuál es la situación en Chile hoy? La Ley 19.812 regulariza el Régimen Jurídico del Scoring Crediticio o Modelo de Calificación Crediticia. Contrariamente al caso de EE.UU. donde estos sistemas han logrado una alta penetración en el sector financiero, en nuestro país no han tenido una difusión y utilización similar. Una de las explicaciones es que “los potenciales usuarios de éstos no han madurado lo suficiente para considerar a tal producto como una poderosa herramienta en la toma de decisiones crediticias” (NN 2004).

Por la misma razón hemos visto fracasar varios proyectos de implementación de una solución de credit scoring ofrecida por empresas extranjeras que no se adaptan lo suficiente a la realidad chilena.

## 2. Evaluando el riesgo de crédito: metodología y métodos

La metodología comúnmente utilizada para la construcción de un modelo de Credit Scoring sigue en forma general el siguiente proceso: primero, se obtiene un conjunto o muestra de clientes o solicitudes clasificadas a priori como “Buenas” o “Malas”. Este juicio y clasificación previa depende principalmente de los objetivos generales de la institución otorgante y del evento que se quiera pronosticar. Por ejemplo, un modelo puede pronosticar la probabilidad de que un cliente no realice tres pagos consecutivos en los próximos 12 meses o calcular la probabilidad de recuperar (o no) un crédito. Luego en una segunda etapa, la información es compilada, preprocesada y transformada para su posterior análisis y modelación por medio de distintas técnicas analíticas, tanto basadas en conocimiento (sistemas expertos; Weber 1999) como basadas en los datos disponibles (data-driven).

Entre las técnicas basadas en datos, existen dos enfoques para la modelación y construcción de modelos analíticos de Credit Scoring: Estadísticas y Minería de Datos. El enfoque estadístico tradicional consiste en pronosticar la probabilidad de ocurrencia de cierto evento (por ejemplo determinar



En general, en la industria bancaria se tiene que el costo de aceptar un cliente malo es varias veces mayor que el de rechazar a un cliente bueno. Sin embargo, la exacerbación del criterio anterior llevaría a una alta tasa de rechazos de solicitudes de crédito lo que iría en desmedro de las utilidades reales del negocio y, por consiguiente, una pérdida de cobertura y mercado por parte de la institución financiera otorgante. Por este motivo, es necesario establecer en forma clara la estrategia corporativa de la institución otorgante de los créditos y de esta forma los modelos de Credit Scoring juegan un papel importante a la hora de administrar el riesgo financiero y el apoyo a la decisión sobre la aceptación de un crédito.

En resumen, una institución que utiliza los modelos de Credit Scoring para la administración y el manejo del riesgo financiero debería, por un lado, tener clara la cobertura que quiere tener en términos de penetración y participación de mercado y, por otro lado, la rentabilidad mínima para la incorporación de un nuevo cliente a través del tiempo y el nivel de riesgo que está dispuesta a contraer con la incorporación de un cliente potencialmente riesgoso.

cuándo caerá en mora un cliente) dado un conjunto de características o variables de entrada. Entre las técnicas estadísticas es posible nombrar el análisis discriminante (AD) y la regresión logística (RL).

El análisis discriminante, al igual que varias técnicas estadísticas, tiene una serie de supuestos estadísticos que deben ser cumplidos a cabalidad para que el modelo construido tenga cierta validez, supuestos que rara vez en los problemas reales se cumplen. Entre estos supuestos se puede mencionar que no se permite trabajar directamente con variables categóricas (por ejemplo: rubro, estado civil, separación de bienes, etc.) las cuales son comúnmente utilizadas en problemáticas de Credit Scoring. Además, esa técnica exige normalidad en las variables, lo que tampoco se tiene necesariamente en la práctica.

La técnica estadística más utilizada por la industria financiera corresponde a la regresión logística (Thomas et al., 2002). Esta técnica es menos restrictiva siendo una alternativa sobre la utilización del análisis discriminante. Con esta técnica, es posible incorporar tanto variables categóricas como variables continuas. Además, al construir este tipo de modelos es posible obtener el grado de importancia relativa de cada una de las variables de entrada y poder cuantificar su efecto, en términos de explicabilidad y relevancia respecto de la variable objetivo del estudio.

En los últimos años, han aparecido una serie de técnicas nuevas llamadas Minería de Datos (Weber 2000), las cuales han sido utilizadas también para la construcción de modelos de Credit Scoring. Estas técnicas tienen la ventaja de no tener demasiados requerimientos y supuestos para las variables de entrada, aumentando su validez. Entre las técnicas más utilizadas están los árboles de decisión, los support vector machines y las redes neuronales. Esta última técnica ha sido intensamente utilizada para la construcción de modelos de Credit Scoring para la comprensión de patrones complejos de un determinado segmento de clientes, teniendo la capacidad de modelar relaciones no lineales entre las variables (West, 2000).

El modelo basado en la regresión logística está constituido por dos elementos básicos: un conjunto de pesos relacionados a un grupo de variables o atributos que caracterizan a un conjunto de clientes o solicitudes, y un umbral o punto de corte. Con el conjunto de pesos es posible caracterizar los patrones que describen ambas poblaciones (buenos y malos) y determinar cuál o cuáles de las variables de entrada utilizadas son realmente importantes y, aportan en términos de una buena predicción de la clase. Respecto del punto de corte, éste determina la frontera entre ser un “Mal” o “Buen” cliente.

Tanto para técnicas estadísticas como para las técnicas de minería de datos, el modelo se evalúa en términos de su capacidad predictiva en la discriminación entre clientes buenos y malos. La capacidad predictiva de un modelo puede ser definida de múltiples maneras, siendo una de las más utilizadas el error de clasificación. Este error se obtiene de la comparación entre la clase predicha por el modelo de Credit Scoring respecto de la clase real definida a priori.

Cabe destacar que existen dos tipos de errores que puede cometer el modelo, comúnmente denominados error tipo I y II. El error tipo I se origina al clasificar como “Mal” cliente a un cliente que en realidad era “Bueno” y, en caso contrario, el error tipo II se relaciona con clasificar a un cliente como “Bueno”, siendo que en realidad era un “Mal” cliente. El error tipo I genera un costo de oportunidad al no recibir las utilidades generadas para la institución financiera por un crédito no cursado y, por su parte, el error de tipo II genera una pérdida para la institución al tener aumentar el riesgo total de la cartera aumentando la probabilidad de no recuperar el monto prestado.

En general, en la industria bancaria se tiene que el costo de aceptar un cliente malo es varias veces mayor que el de rechazar a un cliente bueno.

Sin embargo, la exacerbación del criterio anterior llevaría a una alta tasa de rechazos de solicitudes de crédito lo que iría en desmedro de las utilidades reales del negocio y, por consiguiente, una pérdida de cobertura y mercado por parte de la institución financiera otorgante. Por este motivo, es necesario establecer en forma clara la estrategia corporativa de la institución otorgante de los créditos y de esta forma los modelos de Credit Scoring juegan un papel importante a la hora de administrar el riesgo financiero y el apoyo a la decisión sobre la aceptación de un crédito.

En resumen, una institución que utiliza los modelos de Credit Scoring para la administración y el manejo del riesgo financiero debería, por un lado, tener clara la cobertura que quiere tener en términos de penetración y participación de mercado y, por otro lado, la rentabilidad mínima para la incorporación de un nuevo cliente a través del tiempo y el nivel de riesgo que está dispuesta a contraer con la incorporación de un cliente potencialmente riesgoso.

### 3. EL CASO INDAP: Credit Scoring para microempresarios agrícolas

El equipo de consultores desarrolló una metodología genérica para proyectos de credit scoring que ha sido exitosamente aplicada en varios proyectos. A continuación expondremos el caso del sistema implementado para INDAP.

El Instituto de Desarrollo Agropecuario, INDAP, es el principal servicio del Estado de Chile en apoyo de la pequeña agricultura ([www.indap.cl](http://www.indap.cl)). Creado en 1962, INDAP constituye un organismo público descentralizado cuyo principal objetivo es fomentar y potenciar el desarrollo de la pequeña agricultura. Así, INDAP define como su misión el “Promover condiciones, generar capacidades y apoyar con acciones de fomento, el desarrollo productivo sustentable de la agricultura familiar campesina y sus organizaciones”. Actualmente tiene una cobertura anual con distintos instrumentos de fomento en torno a los 100.000 pequeños productores y campesinos, atendidos a través de 100 Agencias de Área repartidas por todo el territorio nacional.

En dicho contexto, una de las más importantes acciones de fomento que desarrolla INDAP consiste en facilitar el acceso a financiamiento a pequeños agricultores que desarrollen actividades productivas. Esta acción se realiza a través de dos grandes líneas. La primera es la provisión de créditos directos que se focalizan preferentemente en aquellos microempresarios agrícolas con más dificultad de acceso al sistema financiero. La segunda, corresponde al Programa de Articulación Financiera que desarrolla un conjunto de acciones de fomento para incentivar la oferta de créditos a través de diversas Instituciones Financieras. Producto de estas dos grandes líneas de acción, el mercado del crédito a la pequeña agricultura se ha desarrollado en forma importante y exitosa durante los últimos 4 años, llegando a atender en la actualidad a una cartera crediticia de alrededor de 90.000 microempresarios agrícolas, esto es, casi un tercio del crédito a la microempresa en Chile.

Dentro del marco del plan de modernización impulsado por INDAP, uno de los objetivos que se persigue es la profesionalización del proceso de entrega de créditos a través de un mejor análisis de riesgo. Como se ha discutido anteriormente, el desarrollo de modelos analíticos de credit scoring constituye una herramienta de vital importancia en el proceso de evaluación de créditos, y es por ello que el Departamento de Ingeniería Industrial de la Universidad de Chile ha desarrollado un sistema de credit scoring para apoyar el proceso de evaluación de riesgo de crédito en INDAP. Mediante la generación de este sistema, INDAP tiene mejor información para la toma de decisiones en el proceso de evaluación de un crédito: aceptar un crédito, solicitar mayores garantías a los créditos más riesgosos, focalizar el seguimiento futuro de los créditos, etc.

### CARACTERÍSTICAS DEL PROBLEMA

¿Cuál es la probabilidad de que un crédito no se recupere? Esa es la pregunta central que define el objetivo de los modelos de credit scoring desarrollados en el caso INDAP. En torno a dicho objetivo, hay que hacer precisiones de diversa naturaleza para una correcta definición del problema.

En primer lugar, la idea es apoyar la toma de decisiones en el momento en que se evalúa un crédito. Por ello, la pregunta objetivo se plantea en el momento de evaluación del crédito, y el modelo debe ser capaz de predecir basándose en la información con que se cuenta al momento de evaluar el crédito.

En segundo lugar, la unidad de análisis es la solicitud de crédito asociada a un determinado cliente. Así, un crédito de determinadas características (cuya fecha de vencimiento ya expiró) que fue otorgado a un cliente de determinadas características se definió como “malo” si no se recuperó el monto colocado. En caso contrario se considera como “bueno”. Lo que se predice es la probabilidad de no recuperación de un crédito, valores más cercanos a 1 indican mayor riesgo de no recuperación, valores más cercanos a 0 indican menor riesgo de no recuperación. De acuerdo a esto, un cliente no es malo o bueno en sí mismo, sino que puede ser bueno para un determinado tipo de créditos, malo en otros (como se verá, esto depende de diversos factores).

Adicionalmente, para el desarrollo de los modelos se cuenta con información del cliente (edad, estado civil, predios, etc.), características del crédito (plazo, monto, rubro, etc.) y comportamiento de pago anterior del cliente con INDAP (moras, condonaciones, renegociaciones, etc.). Es interesante hacer notar, en este contexto, que por un tema de no discriminación se excluyeron del análisis algunas variables como la etnia o el sexo de un cliente, dado que en una primera versión el modelo asignó pesos bajos a estas variables, es decir que no influyen mucho en el comportamiento de un cliente.

Finalmente, se recalca que el objetivo para INDAP es tener un mejor manejo del riesgo, manteniendo una amplia cobertura. A diferencia de una empresa privada, en la que el objetivo es maximizar sus utilidades, en el caso de INDAP se trata de maximizar el beneficio social que generan los recursos públicos utilizados en la colocación de créditos, lo que en parte tiene que ver con entregar oportunidades de financiamiento a quien no las obtiene de otra fuente. Es decir, es un tema que tiene que ver con la cobertura de usuarios, con el requisito de mantener un uso eficiente de los recursos públicos.

### ENFOQUE DE SOLUCIÓN

Desde la perspectiva de la modelación, la solución que se diseñó consta de dos etapas: segmentación del universo de créditos/clientes, construcción de modelos predictivos para cada segmento. A continuación se revisan los aspectos más relevantes de ambas etapas.

¿Son los montos de los créditos de largo plazo comparables con los montos de los créditos de corto plazo? ¿Tendrán un comportamiento similar en términos de riesgo? ¿Para efecto de utilización de variables explicativas, puede tratar de igual manera a clientes antiguos y nuevos?

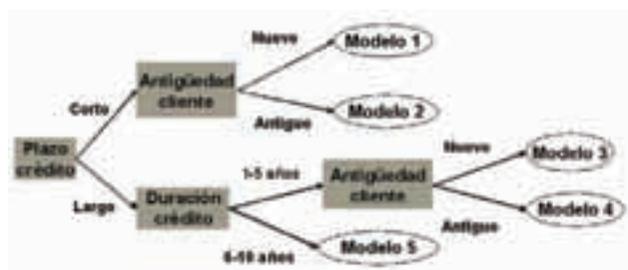
Dependiendo de la aplicación, preguntas como las anteriores pueden hacer que sea razonable pensar en disminuir la heterogeneidad del universo total de créditos/clientes mediante el diseño de una segmentación que resulte apropiada desde un punto de vista de la lógica del negocio, y también desde una perspectiva estadística para la construcción de modelos robustos.

En el caso de INDAP, de acuerdo a la opinión de los expertos del negocio, existe una división natural entre créditos de corto y largo plazo, fundamentalmente porque el objeto del financiamiento tiene naturaleza

y por tanto condiciones de riesgo, totalmente distintas. El crédito de corto plazo tiene por objeto fundamental el financiamiento del capital de trabajo para un negocio cuyo horizonte es relativamente corto, normalmente algún cultivo anual. Por el contrario, el crédito de largo plazo se orienta principalmente al financiamiento de inversiones en activos fijos necesarios para el desarrollo de negocios de horizonte más largo. Como tal, este último está afecto a una condición natural de mayor riesgo puesto que su éxito depende de un horizonte de plazo de más difícil predictibilidad. Adicionalmente, el proceso de evaluación que sigue un cliente nuevo es distinto que un cliente antiguo. En el caso de este último, se dispone de la información del comportamiento crediticio que ha tenido, antecedente de gran relevancia para la evaluación del riesgo y por tanto es indispensable de ser incorporado como variable para el modelo. A partir de lo anterior surge la decisión de dividir la muestra utilizando las variables 'plazo' del crédito (corto, largo) y 'antigüedad' del cliente (nuevo, antiguo).

Adicionalmente, por razones técnicas se separaron los créditos de largo plazo con duración mayor a 6 años, teniendo dichos créditos un tratamiento especial en lo metodológico. De esta manera, se propuso una segmentación del universo total en cinco segmentos como lo muestra la siguiente figura:

Figura 2: Segmentación del universo total



Dicha segmentación se validó desde una perspectiva estadística sobre múltiples variables mediante diversos análisis (ANOVA, Levene, entre otros) e indicadores (proporciones, entropía, coeficiente de partición, entre otros), que mostraron que existía heterogeneidad entre los segmentos y niveles razonables de homogeneidad intra segmentos.

**Para cada segmento se construyeron modelos predictivos distintos. ¿Cómo?**

Tal como se comentó, existen diversos métodos para construir este tipo de modelos, variando su exactitud, complejidad, costos, etc. Se experimentó con regresión logística, árboles de decisión, redes neuronales y support vector machines, de acuerdo a las metodologías que actualmente definen el estado del arte en cada caso. Los resultados obtenidos con técnicas complejas no fueron sustancialmente superiores a aquellos obtenidos con regresión logística, técnica que además tiene una mayor facilidad de interpretación e implementación, por lo que se optó por generar modelos de regresión logística para predecir la probabilidad de no recuperación de un crédito.

Dado que se pronosticará un evento dicotómico (ser "bueno" o "malo") en base a la información de las variables independientes (x1, ..., xm), la regresión logística busca determinar la probabilidad de ocurrencia del evento dicotómico en función de la información contenida en las variables independientes, asumiendo una relación funcional como se muestra la siguiente ecuación:

$$\pi(x) = \frac{e^{\beta_0 + \beta_1 x_1 + \dots + \beta_m x_m}}{1 + e^{\beta_0 + \beta_1 x_1 + \dots + \beta_m x_m}}$$

Lo anterior expresa que la probabilidad de ocurrencia del evento que se estudia (denotado por  $\pi(X)$ ) es función de los valores de las variables independientes  $X=(x_1, \dots, x_m)$ . De esta manera, cuando se quiere ajustar un modelo de regresión logística a un conjunto de n observaciones  $(X_i, Y_i)$ ,  $i = 1, \dots, n$ , lo más común es estimar el valor de los coeficientes  $(\beta_0, \dots, \beta_m)$  de acuerdo al método de máxima verosimilitud (Hosmer, Lemeshow 2000). En términos generales, el método de máxima verosimilitud encuentra los valores de los parámetros desconocidos que maximizan la probabilidad de obtener el conjunto de datos observados.

Antes de desarrollar los modelos analíticos, sin embargo, es vital considerar el conocimiento de los expertos de INDAP para plantear un modelo basado en información atinente. Rondas de reuniones con personal de distinto tipo, casos de análisis guiados en conversación, y sesiones multipersonales se llevaron a cabo para conocer en la práctica qué factores pueden explicar el riesgo de no pago de un crédito, lo que a la postre resultó vital para la identificación de fuentes de información apropiadas. En base a dicha información, se implementan mecanismos de selección de variables de selección hacia adelante y eliminación hacia atrás, para construir distintos modelos "candidatos" y seleccionar las variables que tienen mayor potencial en la explicación de la variable objetivo.

Dado que la finalidad del problema es la clasificación de una solicitud de crédito de acuerdo a la probabilidad que dicha solicitud resulte ser "buena" o "mala", los distintos modelos creados con un subconjunto de los datos (conjunto de entrenamiento) son posteriormente evaluados sobre un conjunto independiente de datos (conjunto de testeo) que permite tener una estimación del porcentaje de acierto que el modelo tendría en la práctica.

**RESULTADOS OBTENIDOS**

El modelo de regresión logística pronosticará la probabilidad de no recuperación de un crédito. De esta manera, es conveniente estudiar la distribución de probabilidades del modelo de acuerdo a la clase real del crédito ("bueno" o "malo") con miras a la evaluación del modelo; la siguiente figura ilustra lo anterior para el modelo del universo de cliente antiguos con créditos de corto plazo:

Figura 3: Probabilidades del modelo para el conjunto de testeo



El gráfico muestra, como es esperable, que el modelo generado pronostica valores altos (en promedio 0.64) para la probabilidad de no recuperación de un crédito para las solicitudes que en realidad fueron "malas" (NO RECUPERADA) y valores bajos (en promedio 0.36) para la probabilidad de no recuperación de un crédito para las solicitudes que en realidad fueron "buenas" (RECUPERADA). La definición de un puntaje de corte permite evaluar los errores tipo 1 y tipo 2 del modelo.

¿Queremos ser parte como país de estos nuevos desafíos? Una mayor cercanía de las universidades donde se hace ciencia e investigación aplicada y las instituciones públicas y privadas interesadas en incorporar herramientas prácticas y no necesariamente complejas a su proceso de toma de decisiones, será de vital importancia para la modernización de la gestión de las organizaciones innovadoras y – finalmente – de nuestra sociedad.

Otra ventaja de la construcción de este tipo de modelos es la interpretación de la importancia de las variables. Por ejemplo, en el caso de INDAP para el universo de créditos de corto plazo para cliente antiguos, resultaron ser variables relevantes (entre otras) el monto del crédito y el comportamiento de mora anterior del cliente. De esta manera, los modelos de regresión logística permiten inferir en términos aproximados cuánto más probable o menos probable se hace la no recuperación del crédito si cambia una característica; por ejemplo, a partir del modelo construido se sabe que si la tasa de solicitudes morosas anteriores crece en x%, la probabilidad de no recuperación del crédito crece en y%. Dicha información permite a INDAP manejar de mejor manera el riesgo de sus créditos, e implementar políticas de acción acorde a los requerimientos.

La aplicación del modelo en la gestión crediticia de Indap permite vislumbrar claros beneficios. En primer lugar, la aplicación del modelo puede permitir a INDAP un mejor manejo del riesgo y de la cobertura de clientes. Por ejemplo, es posible reducir el riesgo de su cartera a un valor deseado, ajustando los niveles de cobertura a este objetivo, o, con otra perspectiva, maximizar la cobertura a alcanzar acotando el riesgo a un valor tolerable.

En segundo lugar, el modelo permitirá la reducción de los tiempos de evaluación, especialmente en el caso de cliente que aparezcan con alta probabilidad de pago cuya aprobación puede realizarse con menos trámites. Esto tendrá un impacto positivo sobre los propios costos de evaluación de la institución, pero también es de gran relevancia desde la perspectiva del costo de transacción del cliente que solicita un crédito. Es altamente probable, de acuerdo a los resultados del modelo, que estos clientes hayan tenido un buen comportamiento anterior; por tanto, la aplicación de esta herramienta es una buena forma de premiar a estos clientes.

En tercer lugar, la aplicación del modelo permite agregar mayor objetividad al proceso de evaluación, cuestión que es muy valorada en este caso específico, pues permite, con un mecanismo eficiente de asignación, mantener la transparencia en la aplicación de recursos públicos.

En cuarto lugar, el desarrollo de este modelo puede llegar a ser una importante contribución al desarrollo del microcrédito agrícola en Chile. En efecto, una de los obstáculos que enfrenta el desarrollo de este mercado de financiamiento es la falta de información de los clientes y por tanto del riesgo que representan. Adicionalmente, ha existido una alta percepción de riesgo asociado al negocio agrícola en general. Los avances en los últimos años en esta materia han sido importantes, básicamente producto de información crediticia que INDAP ha aportado al mercado y de la generación instrumentos de garantía estatales focalizados en el sector. Sin embargo, la creación de este modelo, que será compartido con las principales instituciones financieras que están desarrollando plataformas de crédito a la microempresa agrícola, sin duda que constituye un nuevo paso en el desarrollo de este mercado que debería contribuir a desarrollarlo y perfeccionarlo.

#### 4. NUEVOS DESAFÍOS

Los modelos de credit scoring se han implementado desde hace unos 50 años, teniendo como motivación original la predicción qué clientes ‘fallarán’ en el pago de su crédito, la reducción en los niveles de subjetividad en la entrega de créditos, y la automatización del proceso de evaluación para disminuir los costos administrativos.

Dentro de los desafíos actuales se encuentra la determinación no sólo de si un cliente va a fallar o no, sino cuándo un cliente va a fallar. En este caso, es posible -mediante análisis de supervivencia por ejemplo (Banasik et al. 1999) - estudiar la probabilidad que un cliente falle en el siguiente instante de tiempo (e.g. en el siguiente mes), dado que hasta el momento el cliente no ha fallado, permitiéndose incorporar los eventos que van ocurriendo durante el tiempo.

Asimismo, otra de las direcciones actuales es evaluar los clientes de manera global en función de si se estima resultarán “rentables” para el banco o institución que otorga los créditos. En este caso, el profit scoring está alineado con los objetivos de negocio de la institución y debe relacionarse con modelos de venta cruzada, entre otros. En la misma línea, una tendencia actual -denominada acceptance scoring- tiene relación con la estimación de cuán probable es que un cliente acepte una oferta de crédito de determinadas características, por ejemplo, estimar cuán probable es que un cliente acepte una oferta de una línea de crédito por 2 millones de pesos. En este caso, el mix de productos cobra relevancia y los modelos de acceptance scoring pueden servir de input para el desarrollo de modelos de profit scoring.

¿Queremos ser parte como país de estos nuevos desafíos? Una mayor cercanía de las universidades donde se hace ciencia e investigación aplicada y las instituciones públicas y privadas interesadas en incorporar herramientas prácticas y no necesariamente complejas a su proceso de toma de decisiones, será de vital importancia para la modernización de la gestión de las organizaciones innovadoras y – finalmente – de nuestra sociedad.

**Agradecimientos:** Los autores les agradecen al Núcleo Científico Milenio “Sistemas Complejos de Ingeniería” P04-066-F por el apoyo brindado en la elaboración y financiamiento de este estudio. ●

#### 5. Referencias

- Altman, E. I. (1968): Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy, *Journal of Finance*, (Sep-1968), 589-609
- Banasik, J. Crook, J.N. and Thomas, L.C. (1999): Not if but when will borrowers default. *Journal of the Operational Research Society* 50, 1185-1190
- Frame, W.S., Srinivasan, A., & Woosley, L. (2001). The effect of credit scoring on small-business lending. *Journal of Money, Credit and Banking* 33(3), 813-25
- Brent A. Gloy, B.A., Eddy L. Ladue, E. L., and Michael A. Gunderson, M. A. (2004). "Credit Risk migration experienced by agricultural lenders". Working paper, Cornell University, May 2004.
- Hosmer, D. and Lemeshow, S. (2000). *Applied Logistic Regression*. Wiley, New York.
- Visit Limsombunchai, V., Christopher Gan, Ch., and Minsoo Lee, M. (2005): "An analysis of Credit Scoring for agricultural loans in Thailand". *American Journal of Applied Sciences* 2(8): 1198-1205.
- Yang Liu, Y., Schumann, M. (20052b): Data mining feature selection for credit scoring models. *Journal of the Operational Research Society* (2005), 1-10
- Mays, E. (2004). *Credit Scoring for Risk Managers The Handbook for Lenders*. South- Western, Thomson Learning.
- N.N. (2004): Análisis de la Ley 19.812 y Régimen Jurídico del Scoring Crediticio o Modelo de Calificación Crediticia. *Revista Chilena de Derecho Informática* 4, Mayo 2004
- Thomas, L. C. (2006). *Credit Scoring: The state of the art*. FORESIGHT 3, 33-37.
- Thomas, L.C. (2000). A survey of credit and behavioural scoring: forecasting financial risk of lending to consumers. *International Journal of Forecasting* 16, 149-172.
- Thomas, L.C., Edelman, D.B., & Crook, J.N. (2002). *Credit scoring and its applications*. SIAM Monographs on Mathematical Modeling and Computation. Philadelphia, PA: Siam.
- Weber, R. (1999): Applications of Fuzzy Logic for Creditworthiness Evaluation. In: R. R. Ribeiro, H.-J. Zimmermann, R. R. Yager, and J. Kacprzyk (eds.): *Soft Computing in Financial Engineering*, Physica-Verlag, Heidelberg, 388-401
- Weber, R. (2000): Data Mining en la Empresa y en las Finanzas Utilizando Tecnologías Inteligentes. *Revista Ingeniería de Sistemas XIV*, No 1, 61-78
- West, D. (2000). "Neural Network credit scoring models". *Computers and operations research* 27, Pág. 1131-1152