

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ciencias Sociales y Humanísticas

ESTIMACIÓN DE UN MODELO DE *CREDIT SCORE* PARA DETERMINAR EL NIVEL
DE RIESGO DE LOS CLIENTES DE UNA EMPRESA MANUFACTURERA:

CASO ECUADOR

PROYECTO INTEGRADOR

Previo la obtención del Título de:

Economista

Presentado por:

Jéssica Tatiana Castillo Mejía

Carla Daniela Reyes Alvarado

GUAYAQUIL - ECUADOR

Año: 2019

DEDICATORIA

El presente trabajo de titulación queremos dedicárselo a nuestros padres, por ser los mejores en todo sentido. A Dios por haberlos escogido, sin duda alguna fue la mejor elección.

A toda nuestra familia, por siempre estar junto a nosotras y brindarnos su cariño incondicional. De forma especial, a nuestras hermanas que sin importar nuestras diferencias han estado con nosotras en todo momento apoyándonos.

Al profesor Milton Paredes, nuestro tutor de materia integradora, por su tiempo, paciencia y guía durante el desarrollo de nuestro proyecto.

A todas aquellas personas que han estado cerca de nosotras, amigos, compañeros de aula, profesores, personal administrativo de la institución, que nos brindaron su apoyo, conocimientos, alegrías y tristezas durante estos cinco años, consiguiendo que este sueño se haga realidad.

¡Lo logramos!

Tatiana Castillo, Carla Reyes.

AGRADECIMIENTOS

La palabra gracias expresa un mensaje y símbolo de gratitud inigualable, sin embargo, no siempre puede expresarlo todo...

Nuestro más sincero agradecimiento va dirigido hacia nuestros padres, por ser el pilar fundamental de nuestra vida y guías durante todo este proceso. A Dios, por la vida y salud que nos brinda día a día; y por habernos premiado con tan sabios consejeros, amigos y ejemplo a seguir.

Gracias a nuestras hermanas Daleska y Gabriela, por siempre estar a nuestro lado y llenarnos de maravillosos momentos y memorias que un día seguiremos compartiendo.

Gracias a cada uno de los miembros de nuestra familia en general, que siempre creyeron en nosotras y fueron nuestro soporte y motor en aquellos momentos en los que pensábamos que todo estaba perdido.

Gratitud eterna a aquellos profesores que formaron parte de nuestro desarrollo profesional y hoy juntos nos encontramos celebrando este logro. También a aquellos compañeros de aula que con sus risas y enseñanzas hicieron de nuestros días en esta institución más felices.

Finalmente, son tantas las personas que han formado parte de nuestra vida y que de una u otra forma han sido partícipes de esta meta cumplida que hoy les damos infinitas gracias. Gracias por los consejos, tiempo, apoyo o simplemente por su gesto o palabra de ánimo.

Tatiana Castillo, Carla Reyes.

DECLARACIÓN EXPRESA

"Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; Castillo Mejía Jéssica Tatiana y Reyes Alvarado Carla Daniela y damos nuestro consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual"

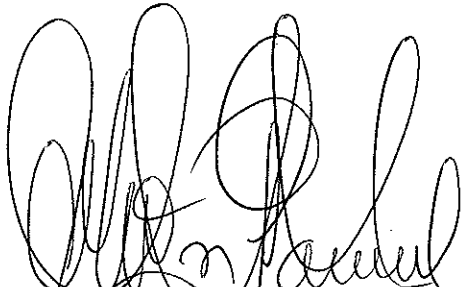


Jéssica T. Castillo Mejía

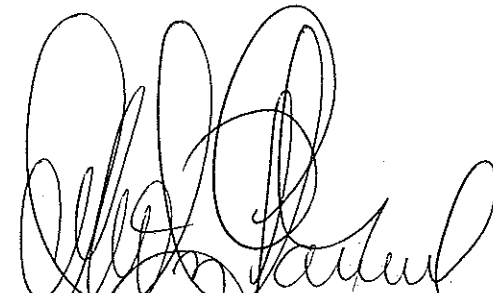


Carla D. Reyes Alvarado

EVALUADORES



Ing. Milton I. Paredes Aguirre
PROFESOR DE LA MATERIA



Ing. Milton I. Paredes Aguirre
PROFESOR TUTOR

RESUMEN

Actualmente diversos tipos de empresas han tenido que incorporar las ventas a crédito para que sus productos se mantengan vigentes en el mercado, esto se da debido a las diferentes situaciones económicas por las que atraviesa el mundo, donde para el caso ecuatoriano sobresalen tanto la inestabilidad política como el estancamiento del crecimiento económico. La problemática surge ante la escasez de herramientas cuantitativas que permitan predecir el comportamiento crediticio de cada cliente según sus características socioeconómicas, comerciales y financieras. Es por ello que, el objetivo del presente trabajo es plantear un modelo credit scoring que permita realizar un análisis discriminatorio que proporcione el material y sustento estadístico necesario para tomar una decisión respecto a un estudio crediticio. Para el presente proyecto se toma la información de la cartera de clientes de una empresa manufacturera chilena con sede en Ecuador, con la cual se generó un modelo logístico con alrededor de nueve grupos de variables robustas y significativas que determinan la probabilidad de que un cliente caiga en mora o impago de cuota con su respectiva interpretación.

Palabras clave: Modelo Scoring, riesgo de crédito, otorgamiento de crédito, Logit

ABSTRACT

Actually, a lot of companies have had to incorporate credit sales in order to their products remain value in the market, this is due to the different economic problems that the world is going through, where in the Ecuadorian case political instability stands out so much as the stagnation of economic growth. The problema begins due to the lack of quantitative tools that allow predicting the credit behavior of each client according to their socioeconomic, commercial and financial characteristics. That is why the main objective of this work is to propose a credit scoring model that allow us to make a discriminatory analysis in order to provided the material and statistical support necessary to make a decision regarding a credit study. For this project, information is taken from the client portfolio of a Chilean manufacturing company based in Ecuador, with which a logistics model was generated with about nine groups of robust and significant variables that determine the probability that a client will fall in default or non-payment quota with their respective interpretation.

Keywords: scoring model, credit risk, credit granting, logit

ÍNDICE GENERAL

RESUMEN	I
ABSTRACT	II
ÍNDICE DE TABLAS	IV
CAPÍTULO 1.....	1
1. INTRODUCCIÓN.....	1
1.1 DESCRIPCIÓN DEL PROBLEMA	2
1.2 JUSTIFICACIÓN DEL PROBLEMA	3
1.3 OBJETIVOS.....	4
1.3.1 <i>Objetivo General</i>	4
1.3.2 <i>Objetivos Específicos</i>	4
1.4 MARCO TEÓRICO	4
1.4.1 <i>Definición de “crédito”</i>	4
1.4.2 <i>Administración del riesgo</i>	4
1.4.3 <i>Modelos de credit scoring</i>	5
1.4.4 <i>Evolución de los modelos de credit scoring en el tiempo</i>	5
CAPÍTULO 2.....	7
2. METODOLOGÍA.....	7
2.1 METODOLOGÍA CUALITATIVA.....	7
2.2 METODOLOGÍA CUANTITATIVA.....	8
2.2.1 <i>Fundamentación teórica</i>	8
2.2.2 <i>Selección de la muestra</i>	11
2.2.3 <i>Fuentes de Información</i>	11
2.2.4 <i>Selección de Variables</i>	11
2.2.5 <i>Validación del modelo</i>	11
CAPÍTULO 3.....	12
3. RESULTADOS.....	12
3.1 ANÁLISIS DE LOS COEFICIENTES DEL MODELO Y LA CONSISTENCIA DE SUS SIGNOS	
14	
3.2 ODDS RATIO	17

3.3 CONSISTENCIA DEL MODELO	17
CAPÍTULO 4.....	20
4. CONCLUSIONES Y RECOMENDACIONES	20
5. BIBLIOGRAFÍA.....	22

ÍNDICE DE TABLAS

Tabla 3-1 Modelo Logit	13
Tabla 3-2 Odds Ratios	17
Tabla 3-3 Regresiones OLS, Probit y Logit	17

CAPÍTULO 1

1. INTRODUCCIÓN

Con el fin de captar la mayor cantidad de clientes para mejorar el nivel de ventas, en la actualidad una gran cantidad de empresas distintas a las financieras tradicionales, han tenido que recurrir a las ventas a plazo o también conocidas como ventas a crédito debido a la falta de liquidez de sus clientes por diversas razones en donde predomina, para el caso actual del Ecuador, la inestabilidad política y estancamiento del crecimiento económico sufrido en los últimos años. Donde sin importar las condiciones siempre existe riesgo, en este caso particular riesgo de crédito, que implica que el deudor no pueda pagar su deuda por diferentes razones. Por ello, dentro de las últimas décadas y grandes avances matemáticos y estadísticos se han desarrollado herramientas que permitan predecir el comportamiento de las personas o sociedades si se les otorga un crédito, asignando una puntuación dada la información proporcionada por el cliente, a este tipo de herramientas se las conoce como credit scoring.

Entre los modelos estadísticos más utilizados en la literatura de credit scoring están los modelos discriminantes, de probabilidad lineal, logit, probit, árboles de decisión, redes neuronales, entre otros. Donde la implementación de cada modelo depende de las necesidades y tipo de información de cada empresa.

El objetivo principal de este proyecto de grado es estimar un modelo credit scoring mediante el uso de regresiones logísticas, con el cual se espera identificar aquellas variables propias de cada aplicante a un crédito que lo hacen más o menos riesgoso según parámetros previamente definidos. El mismo será aplicado a una empresa manufacturera multinacional chilena establecida en Ecuador, como complemento de los procesos en el área de crédito y cobranza para generar alternativas de solución de los problemas detectados, brindándole a la compañía la posibilidad de poseer medidas tanto preventivas como correctivas que reduzcan el nivel de carteras en default; y de esta manera generar más rentabilidad, solvencia y eficiencia.

Este documento está compuesto en primer lugar por un marco conceptual, en donde se define la palabra crédito y los distintos modelos de riesgo crediticio que han surgido a lo largo del tiempo desde su nacimiento. Después, se trata de explicar el método empleado por los analistas de la empresa en estudio, donde se detalla la

documentación y requisitos básicos que son necesarios posean para aplicar a un crédito. Posteriormente, se plantea la metodología a ser utilizada, sus ventajas y limitaciones; se da una breve explicación de las variables que son utilizadas y el porqué de su elección.

En el capítulo posterior se presentan los resultados obtenidos, se realiza un análisis de los datos más relevantes, las relaciones obtenidas de cada variable mediante odds ratios y una validación de la consistencia del modelo planteado. Finalmente, con los resultados obtenidos en el capítulo anterior, se procede a emitir las conclusiones y recomendaciones pertinentes para mejorar la elección de la cartera de clientes.

1.1 Descripción del problema

El problema presente en la mayoría de las organizaciones que manejan un sistema de crédito con sus clientes reside en que la decisión de otorgar o rechazar dicha solicitud de crédito ha dependido simplemente de su buen juicio, basado en la experiencia obtenida a través de decisiones crediticias anteriores sean estas propias o de sus socios comerciales. No obstante, estos juicios personales no siempre son acertados y se traducen en carteras en default, clientes con mora, aumento del costo de la gestión de cobranza, incremento de las provisiones de cuentas incobrables, procesos judiciales o incluso la bancarrota.

Este estudio será aplicado a una empresa multinacional de venta de productos de aseo personal, la misma que no se ha quedado atrás durante este proceso, y es así como la ejecutiva del área de crédito y cobranzas, indica han venido otorgando créditos desde los inicios de sus operaciones tanto a clientes masivos como institucionales que conforman su cartera.

Por lo anteriormente mencionado, se puede decir que esta sociedad está llevando a cabo procesos de análisis crediticios de una manera muy subjetiva e implementando políticas rigurosas que al parecer no están siendo las más adecuadas, ya que no cumplen con la cantidad de ventas planificadas; o que son necesarias elevar a comité para una posible aprobación, proceso que estaría bien si el volumen de solicitudes fuera bajo. Por ello, para mitigar dicha problemática en los últimos años a nivel mundial se han implementado sistemas de calificación cuantitativa como el método de *credit scoring*, para su uso en la evaluación de solicitudes de crédito a nivel minorita.

1.2 Justificación del problema

«La gestión de riesgos es fundamental para cualquier empresa cuya rentabilidad de negocio esté íntimamente ligada a los riesgos que asume. Cualquier entidad económica necesita identificar, valorar y cuantificar su exposición al riesgo, optimizando al mismo tiempo la rentabilidad, que se traslada directamente al cliente mediante unos precios más competitivos y la generación de mayores beneficios» (García Sánchez & Sánchez Barradas, 2005)

El problema planteado se presenta debido a la falta de implementación de herramientas cuantitativas aplicables a la hora de evaluar una solicitud de crédito, las mismas que al momento de comenzar a ser utilizadas, ayudarán a los analistas a tener un sustento de las decisiones que tomen; disminuyendo de esta forma la subjetividad y tiempo de respuesta de los estudios crediticios, además de reducir los costos administrativos por la gestión del cobro de cuentas no saldadas.

La aplicación de un modelo de credit score permitirá ayudar a mejorar cada uno de los procesos que se efectúan para el análisis de otorgamiento de crédito y a generar alternativas de solución de los problemas detectados, brindándole a la compañía la posibilidad de poseer medidas tanto preventivas como correctivas que reduzcan el nivel de carteras en default; y de esta manera generar más rentabilidad, solvencia y eficiencia a la empresa, lo cual permitirá mantener indicadores financieros positivos.

Los modelos de credit score han sido aplicados en su mayoría en sectores de banca o microcréditos, en los que se han encontrado resultados favorables de la predicción de pagos, estableciendo estrategias que eviten otorgar créditos de alto riesgo o impago, logrando fortalecer políticas, productos financieros y las respectivas ganancias. (Fernandez & Pérez, 2005) (Rayo, Lara, & Camino, 2010)

En el sector que se desarrolla la empresa a analizar, sector manufacturero, existen muy pocas aportaciones sobre el estudio de cartera de clientes sobre todo a nivel Ecuador, donde su análisis por lo general es subjetivo y depende de las experiencias de las personas al mando, por ello, se busca brindar una herramienta cuantitativa que facilite reducir el riesgo al momento de gestionar un requerimiento de crédito.

1.3 Objetivos

1.3.1 Objetivo General

Desarrollar un modelo estadístico que permita predecir parámetros de comportamiento crediticio en clientes nuevos o potenciales mediante variables socioeconómicas y macroeconómicas, con el objetivo que sea una herramienta rápida, eficiente y que asista en las decisiones de los analistas de crédito.

1.3.2 Objetivos Específicos

1. Evaluar el control de los procesos relacionados con la cartera de clientes de una empresa manufacturera.
2. Analizar las variables que determinan la viabilidad de otorgar crédito a los clientes para estimar un modelo de credit scoring en una empresa manufacturera.
3. Validar la precisión del modelo de credit score mediante la aplicación de regresiones logísticas.

1.4 Marco teórico

1.4.1 Definición de "crédito"

La palabra crédito puede ser definida como la promesa de pago que adquiere una persona (deudor) al momento de realizar un préstamo de dinero a otro individuo o institución (acreedor) en un periodo previamente establecido (Mester, 1997). Esta acción anteriormente era desarrollada en su gran mayoría por las instituciones financieras de un país, pero dado el constante cambio al que las sociedades se encuentran inmersas hoy en día, se ha creado la necesidad de que otro tipo de empresas, como por ejemplo las manufactureras, acepten pagos a plazo por parte de sus clientes.

1.4.2 Administración del riesgo

Desde la creación del Comité de Supervisión Bancaria de Basilea en 1974, se establecieron las primeras directrices de regulación de los sistemas financieros. En la segunda entrega de estas regulaciones conocida como Basilea II, recomiendan realizar un análisis de riesgo de cartera mediante indicadores financieros como ratios de liquidez, deuda, rendimientos y activos de los posibles aspirantes al crédito, sin embargo, no proporciona una metodología estándar y lo deja al criterio y responsabilidad de las entidades siempre que se acojan a la determinación del riesgo crediticio implícito en los clientes. (Rodríguez & Trespacios, 2015).

1.4.3 Modelos de credit scoring

Los modelos o métodos de *credit scoring* pueden ser explicados como “los métodos estadísticos formales utilizados para clasificar a los solicitantes de crédito en clases de riesgo "buenas" y "malas"” (Hand & Henley, 1997). Estos modelos utilizan variables predictoras de formularios de solicitud de crédito y otras fuentes para obtener estimaciones de las probabilidades de incumplimiento, es decir, relaciona información cuantitativa y cualitativa de los clientes. Se toma una decisión de aceptar o rechazar comparando la probabilidad estimada de incumplimiento con un umbral adecuado, adicional pueden ser utilizadas para seguimiento, control y recuperación del riesgo. Una de las principales características es que tienen una dimensión individual, es decir, se enfocan en el riesgo de impago de cada cliente, independiente de lo que ocurra con los otros miembros de la cartera crediticia y la diferencia de otros métodos como son los modelos VaR marginales o de cartera en conjunto.

Estos métodos han cobrado mayor relevancia en las últimas décadas dado el creciente otorgamiento de crédito al consumo, el desarrollo de las entidades financieras, y el crecimiento del sistema crediticio en América Latina.

1.4.4 Evolución de los modelos de credit scoring en el tiempo

Fue los años 60 cuando empezaron los estudios de *credit score* con Myres y Forge (1963), Beaver (1967) y Altman (1968) quienes en pequeñas y medianas empresas asignaban una puntuación a sus clientes para estimar la probabilidad de bancarrota por los créditos otorgados, a partir de modelos lineales discriminatorios.

Aunque le siguieron muchos estudios utilizando como metodología los modelos lineales discriminatorios, para 1970 el economista Yair Orgler introduce un nuevo paradigma mediante el uso de modelos de regresión multivariante, orientado a los créditos usando ratios de rentabilidad, liquidez, apalancamiento y actividad. Otro aporte importante fue el realizado en 1976, Apilado, Warner y Dauten quienes a partir de modelos lineales discriminatorios analizan la implicación de variables socioeconómicas en préstamos de alto nivel.

En 1980, Jhon C. Wiginton realiza un contraste entre los modelos Logit y el análisis discriminante, donde encontró que la estimación de máxima verosimilitud del modelo logit produce estimaciones de parámetros que dan una mayor proporción de clasificaciones correctas que las del modelo discriminante lineal y la posibilidad de medir

sensibilidad y puntos de corte más precisos. (Srinivasan & Kim, 1987) empiezan a comparar diversas metodologías y los resultados fueron que los árboles de decisión arrojan mejores resultados que las regresiones logísticas y estas a su vez superan al análisis discriminante.

A partir de la década de los 90 continúa una oleada de estudios cuyo principal objeto era comparar los métodos para hallar un modelo óptimo de estudio de *credit score*, dentro de estos estudios tenemos, un modelo de discriminación basado en Least – Absolute – Value, donde buscaba una alternativa para el clásico modelo discriminante (Glorfeld, 1990), comparación del modelo discriminatorio con los modelos de performance multivaridas (Crook, Hamilton, & Thomas, 1992)), también apostaron por las redes neuronales como alternativa de análisis (Zhai & Russell, 1999) (Fernandez & Pérez, 2005).

Belloti y Crook (2007) implementan una herramienta ignorada en los análisis de riesgo crediticio hasta ese momento que son la implementación de variables macroeconómicas tales como, tasa de interés, PIB, tasa de desempleo, indicadores financieros, entre otros, en modelos discriminantes, indicando que estas variables tienen una influencia directa en los clientes y su comportamiento.

Actualmente los métodos estadísticos estándar utilizados en la industria para desarrollar *credit score* son: análisis discriminante, regresión lineal, modelo logit y probit, árboles de decisión, redes neuronales y combinaciones de estas. Sin embargo, todos los métodos de credit scoring arrojan similares resultados, por lo que la elección de la metodología queda al criterio de los investigadores y en función de las necesidades de cada caso.

CAPÍTULO 2

2. METODOLOGÍA

Bajo el contexto presentado en la sección anterior, surge la necesidad de diseñar un modelo de credit score con el objetivo de poder asignar una puntuación y una probabilidad de mora a cada cliente real o potencial presente en esta compañía manufacturera. Ante esta problemática han surgido un sinnúmero de modelos estadísticos y econométricos avanzados, los cuales se inician con estudios de tipo binario, posteriormente se comenzaron a utilizar regresiones probit y logit, las cuales se encuentran vigentes hoy en día. La presente investigación se compone de dos enfoques una parte cualitativa, mediante el análisis de políticas, entrevistas, entre otros; y la parte cuantitativa donde se mostrará los modelos matemáticos y probabilísticos usados para determinar un modelo de credit score, que se adapte a las necesidades de la empresa.

2.1 Metodología Cualitativa

Con el fin de evaluar el control de los procesos relacionados con la cartera de clientes de la compañía en estudio, se decidió realizar una entrevista al gerente del área de crédito, para de esta forma tener una mayor comprensión del proceso que realizan sus analistas y conocer las políticas internas por las cuales se rigen, con esta información se podría llegar a conocer el tipo de cliente que busca atraer la empresa y de qué forma son calificados por los trabajadores, es decir, si la documentación y páginas de control revisadas son suficientes para alcanzar a cumplir con todas las políticas planteadas por la empresa para mantener el nivel de mora bajo, o consecuentemente no están siendo las más adecuadas y requieren de un análisis extra. Dentro de la documentación requerida, se encontraba: la solicitud de crédito, que es una declaración de la actividad que realiza el cliente; información básica como fecha de nacimiento, estado civil, dirección de domicilio y trabajo, ingresos, egresos, referencias de tipo personal, comercial y bancaria. Adicionalmente, el desglose de RUC actualizado, declaración de impuesto a la renta de los 3 años anteriores y de IVAS del año en curso, su calificación crediticia en la plataforma Predictor – Equifax, donde la puntuación oscila entre 100 y 999, donde la empresa en cuestión solo acepta para compras a crédito a clientes con mínimo 900 puntos.

2.2 Metodología Cuantitativa

Para determinar el modelo de credit scoring de la empresa manufacturera se realizará mediante un modelo logit, debido a las ventajas que ofrece la función logística al ser más flexible y de factible aplicación.

2.2.1 Fundamentación teórica

2.2.1.1 Modelo Logit

Las regresiones logísticas son de las herramientas más utilizadas al momento de modelar credit scoring, una de las principales razones de esto es que la variable dependiente o a explicar es una probabilidad, es decir, está acotada entre 0-1.

El modelo se basa en una función de distribución logística, que permite estimar la probabilidad, y al tratarse de una regresión identifica las variables más relevantes, se puede definir de la siguiente manera:

$$P(Y = 1 / X) = F(z) = \frac{\exp(z)}{1 + \exp(z)}, \quad -\infty < z < \infty \quad (2-1)$$

$$\text{Con } z = X^T \beta = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n \quad (2-2)$$

El modelo posee las siguientes características: la variable dependiente es dicotómica, es decir solo puede tomar valores de 1 (Cliente es definido como “Malo”) o 0 (Cliente es definido como “Bueno”) y las variables independientes pueden ser cualitativas o cuantitativas o una mezcla de ambas, de la que resulta un vector de coeficientes de cada variable independiente, al considerar este vector de coeficientes y las variables independientes se obtiene la probabilidad de que un individuo sea considerado bueno o malo.

La estimación de los parámetros del modelo logit se puede realizar a partir del modelo de máxima verosimilitud, que consiste en maximizar los coeficientes de la función de probabilidad para obtener la máxima capacidad predictiva.

2.2.1.2 Interpretación coeficientes

Entre las ventajas que presenta este modelo está la fácil y práctica interpretación de los resultados. Se pueden interpretar como probabilidades puras de que el evento ocurra, dado que los resultados están en el rango de 0-1. Sin embargo, existen otras formas de representar esta probabilidad, esto son los odds ratios.

Se puede definir a los odds ratios como la relación entre la probabilidad que ocurra un evento y la probabilidad que no ocurra. Por tanto, la relación entre odds y la propabilidad es:

$$Odds = \frac{\text{Probabilidad que un evento ocurra}}{1 - \text{Probabilidad que un evento ocurra}} \quad (2-3)$$

Al combinar la ecuación presentada anteriormente y la función logística, después de aplicar logaritmo natural, se obtiene el logaritmo de la razón de probabilidades, llegando a la ecuación:

$$L = \ln\left(\frac{P_i}{1 - P_i}\right) = X_i^T \beta = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n \quad (2-4)$$

Donde se puede interpretar de la siguiente manera, por ejemplo, β_1 mide el cambio en L dado un cambio unitario en x_1 , considerando constantes las otras variables. La interpretación se puede realizar a partir de los odds ratios, que es una medida de la magnitud de la relación existente entre dos variables; para el caso específico de una variable independiente con la variable dependiente. Los odds ratios pueden ser mayor o menor que 1, un odds ratio mayor a 1 representa una relación directa o positiva entre las variables relacionadas, mientras que un odds ratio menor a 1 se puede interpretar como una relación indirecta o negativa y en caso de que sea 1 significa que no existe ninguna relación entre las variables.

Estos se pueden calcular a partir de la estimación de los parámetros de cada variable del modelo:

$$odds\ ratio = e^\beta \quad (2-5)$$

2.2.1.3 Estructura del modelo

El enfoque principal del modelo de credit scoring, mediante el uso de regresiones logísticas, es estimar la probabilidad de falta de pago de un solicitante de crédito; para lo cual se requiere contar con la presencia de una variable que identifique si el cliente es bueno o malo, la misma estará representada por la letra Y, también conocida como variable dependiente.

La variable Y para este caso de estudio será una variable binaria, capaz de tomar los siguientes valores según sea el escenario:

$$Y = \begin{cases} 1: Si\ el\ cliente\ es\ definido\ como\ malo \\ 0: Si\ el\ cliente\ es\ definido\ como\ bueno \end{cases} \quad (2-6)$$

Parar poder definir a un solicitante de crédito como bueno (0) o malo (1), será necesario incurrir a “n” variables independientes representadas por la letra X que determinen este resultado, entre las cuales predominan características sociodemográficas propias de cada cliente (edad, sexo, estado civil, etc.), el comportamiento que hayan mantenido en el buró de crédito al momento de ser evaluados y/o el comportamiento que hayan tenido dentro de la institución en el caso de clientes viejos que manejaran otro tipo de pago.

2.2.1.4 Limitaciones del modelo

Un aspecto importante que se debe de tener en cuenta a la hora de desarrollar un modelo es conocer sus limitaciones y también el grado de confidencialidad que presenta el mismo.

Según Mester (1997), la precisión de sus predicciones va a depender exclusivamente del cuidado con el cual se haya construido el modelo. Otro punto primordial por considerar es el hecho de contar con una buena muestra, es decir, la misma debe estar alimentada lo suficiente tanto de clientes buenos como malos (aquellos que han pagado en los plazos establecidos vs. los que han demorado en hacerlo).

(Schreiner, 2002) indica además que una de las limitaciones del credit scoring es que asume que gran parte del riesgo está relacionado con características observables o cuantificables, como la edad del cliente, tipo de empleo, estado civil, entre otras; razón por la cual se asume que las relaciones entre las variables son lineales; caso contrario desarrollar el modelo con variables no lineales sería muy costoso y con resultados poco comprensibles.

Entre otra de sus limitaciones, se encuentra la existencia de una ventana temporal, la misma que requiere que el modelo sea actualizado cada cierto tiempo, ya que las características propias de cada cliente varían según la época y situación económica por la cual atraviesa el país de la institución donde se desea aplicar el modelo, puesto que los clientes son propensos a diversos tipos de afectaciones en época de crisis, la primera y más importante su nivel de ingresos.

Por último, existen tratados como por ejemplo el Equal Credit Opportunity Act (1994) en Estados Unidos que regula el suceso de negar o no un crédito a una persona según su edad, sexo, estado civil, etc.; por lo cual el modelo se volvería no aplicable en países donde existan este tipo de regulaciones, por más que se haya demostrado que son variables que influyen a la hora de caer en una cartera en default o no.

2.2.2 Selección de la muestra

La muestra debe recoger información que refleje de manera consistente el comportamiento de pago de los clientes y que de esta manera logren identificar características que revelen posibles acciones de conducta de los nuevos clientes. Para determinar una muestra representativa de la población se utiliza un indicador de tasa de morosidad de manera mensual, con la finalidad de establecer las fechas límites de las observaciones donde la cartera sea madura y estable. Para determinar el umbral con el que se define si un cliente es “bueno” o “malo”, se realiza mediante una definición empírica proporcionada por los ejecutivos que manejan la cartera crediticia.

2.2.3 Fuentes de Información

Para el análisis de las solicitudes de crédito se cuenta con dos tipos de informaciones: internas y externas. La fuente de información interna es aquella detallada y entregada por el cliente al momento de solicitar el crédito y comprende una solicitud de crédito donde detalla información socio demográfica y de sus relaciones comerciales, así como los documentos detallados en la sección anterior. Como fuente de información externa se tiene la proporcionada por el buró de crédito (Equifax), esta tiene como finalidad proporcionar información integral del cliente, debido a que representa el historial crediticio de cada persona.

2.2.4 Selección de Variables

Con el fin de determinar un conjunto de variables explicativas a ser incluidas en el modelo se realizó una exhaustiva revisión literaria, que junto a una entrevista con los ejecutivos del área de crédito de la empresa manufacturera en estudio, se logró determinar aquellas variables que tenían un mayor peso y generaban una alerta a la hora de un estudio crediticio, entre las variables que predominan se encuentran: la edad, sexo, canal, ingreso promedio neto mensual, activos vs. pasivos, puntuación del buró, entre otras que se irán desglosando y explicando a lo largo del capítulo de resultados.

2.2.5 Validación del modelo

Con la finalidad de comprobar la significancia estadística del modelo se realizarán varias modelaciones que sirven para comparar robustez y validar las relaciones con diferentes modelos, se realizará regresiones OLS, logit y probit para comparar que modelo se ajusta mejor a los datos.

CAPÍTULO 3

3. RESULTADOS

Una vez escogidas las variables independientes que formarían parte del modelo de credit scoring, donde previamente se realizaron un sinnúmero de combinaciones para establecer cuál de ellas arrojaba un mayor número de variables significativas con respecto a la literatura anteriormente planteada; y de esta forma se lograran cumplir los objetivos estipulados de este proyecto, se logra plantear una regresión logística que se ajuste al planteamiento del problema.

Por otra parte, se realiza un análisis más profundo de los objetivos, importancia y la metodología para desarrollar un modelo de credit scoring, se presentan los resultados obtenidos y lo que representan. Como se explicó en el capítulo anterior se desarrolla mediante un modelo Logit, adicional para verificar la consistencia del modelo se hacen modelos Probit y una regresión lineal (OLS).

Entre las principales características que se buscaba cumpla el modelo Logit, se encontraban las siguientes:

1. Obtener el mayor número de variables significativas dentro del modelo, a un nivel de significancia de al menos 95%.
2. Que exista una consistencia de signos en los coeficientes de las variables.
3. Cumplir con la prueba de multicolinealidad.

A continuación, se muestran los resultados obtenidos del modelo Logit, se modeló por grupos, es decir, se organizó por cliente, sus características demográficas, comerciales, financieras y el conjunto de créditos que le fueron otorgados a lo largo del periodo estudiado.

Tabla 3-1 Modelo Logit

Logistic regression		Number of obs = 16,920		Wald chi2(19) = .		Prob > chi2 = .		Pseudo R2 = 0.0878	
Log pseudolikelihood = -10538.748									
(Std. Err. adjusted for 153 clusters in cliente)									
Buenomalo1	Coef.	Robust Std. Err.	z	P> z	[95% Conf. Interval]				
prom_ingreso	5.72e-07	1.07e-07	5.33	0.000	3.62e-07	7.83e-07			
produbanco	-.5776288	.2352461	-2.46	0.014	-1.038703	-.1165548			
guayaquil	.4839323	.2413135	2.01	0.045	.0109664	.9568981			
pichincha	-.595496	.2390928	-2.49	0.013	-1.064109	-.1268827			
imbabura	1.656666	.3308249	5.01	0.000	1.008261	2.305071			
cañar	-3.187634	.3513753	-9.07	0.000	-3.876316	-2.498951			
cotopaxi	2.63819	.2974653	8.87	0.000	2.055169	3.221212			
manabi	.7036314	.3682373	1.91	0.056	-.0181005	1.425363			
sucumbios	.4615852	.177483	2.60	0.009	.1137249	.8094455			
esmeraldas	2.655533	.4820938	5.51	0.000	1.710647	3.60042			
y045	.6722243	.3336962	2.01	0.044	.0181917	1.326257			
y060	.8753259	.3480126	2.52	0.012	.1932338	1.557418			
y075	2.306101	.486886	4.74	0.000	1.351822	3.26038			
pn	-.6838656	.2282961	-3.00	0.003	-1.131318	-.2364134			
lim_creditomiles	-.002403	.0004067	-5.91	0.000	-.0032001	-.0016059			
antigüedadcomocliente_meses	.0181608	.0063841	2.84	0.004	.0056481	.0306735			
malo	.5115322	.2654885	1.93	0.054	-.0088156	1.03188			
excelente	-.7265949	.3572826	-2.03	0.042	-1.426856	-.0263338			
hombre	-.1004216	.1802324	-0.56	0.577	-.4536706	.2528275			
masivo	-.3157757	.3761651	-0.84	0.401	-1.053046	.4214943			
institucional	.798056	.2849249	2.80	0.005	.2396135	1.356498			
_cons	-.8452586	.4520416	-1.87	0.062	-1.731244	.0407267			

En la tabla anterior se encuentran los resultados de cada variable independiente que se utilizó para explicar la probabilidad de que un cliente sea Malo, como se explicó anteriormente, se define como malo aquellos clientes con mora mayor a 10 días en cada uno de los créditos otorgados, dentro de las ventajas que ofrece este modelo, está la independencia de las observaciones es decir es un análisis por cliente y sus atributos. Los coeficientes se entienden como la relación existente entre la variable y la probabilidad de que un cliente sea malo, el signo de este representa el tipo de relación, si es positivo es una relación directamente proporcional y si es negativo tiene una relación inversamente proporcional. Para verificar la relación existente entre estas variables, se utiliza la significancia estadística dada por $P > |z|$ la cual se interpreta de la siguiente manera, si la probabilidad de que se cometa un error de tipo I que sea un falso positivo es menor al 5% se verifica la significancia estadística de la variable y, por ende, si esta probabilidad es mayor a 5% es una variable no significativa. Dentro del modelo planteado existen ciertas variables que no son estadísticamente significativas, sin embargo, son relevantes al momento de evaluar las solicitudes de crédito y son usadas como control.

3.1 Análisis de los coeficientes del modelo y la consistencia de sus signos

En esta sección se busca confirmar que las estimaciones de los parámetros presentan coherencia con respecto a los signos obtenidos. Como se definió anteriormente la variable dependiente "Y" con 0 cuando un cliente es considerado "bueno" y 1 caso contrario, la presencia de un signo positivo en una variable independiente se traduciría como un aumento de riesgo de default o no pago.

- **Prom_ingreso:** Esta variable fue construida en base al Impuesto a la Renta cancelado en el 2018 por cada uno de los clientes que formaban parte de nuestra muestra, en donde dicho valor fue tratado con cálculos matemáticos que permitieran obtener un ingreso promedio neto mensual del cliente. El signo de esta variable fue positivo, por lo tanto, mientras menor sea el nivel de ingresos de un cliente, este será un 0,0000572% propenso más a caer en una cartera castigada.
- **Produbanco:** Variable dicotómica, que toma el valor 1 cuando un cliente mantiene relaciones financieras con Produbanco y 0 cuando no las posee. Para esta variable se obtuvo un signo negativo, por lo que se puede asumir la existencia de una menor probabilidad de riesgo de mora crediticia para aquellas personas que cuenten con una cuenta en Produbanco. Este resultado puede ser también explicado por el hecho de que la empresa en estudio mantiene relaciones financieras con este banco y el proceso de cobro a estos clientes es más rápido en efectivizarse.
- **Guayaquil:** Variable dicotómica, que toma el valor de 1 cuando un cliente mantiene relaciones financieras con Banco Guayaquil y 0 cuando no existen. Este variable dentro del modelo presenta signo positivo, por lo que vuelve más riesgosos a los clientes que posean una cuenta en esta institución a acceder a un crédito. Este resultado, no es del todo sorpresa, pues este banco es conocido por lo muy flexible al momento de otorgar cuentas, créditos y demás productos financieros a sus usuarios.
- **Pichincha:** Al igual que las anteriores variables referentes a entidades financieras, esta es dicotómica en relación a si el cliente posee relaciones financieras con esta entidad o no. Para esta variable se obtuvo un signo negativo, significativo al 5%, por lo que se podría inferir que si un cliente mantiene cuentas en esta entidad existe una relación inversa que sea categorizado como Malo, es

decir que entre en mora. Esta relación puede ser explicada por la magnitud de la entidad, ya que es el banco más grande del país.

- **Provincias:** La empresa mantiene relaciones comerciales en la mayoría de las provincias del país, en las más grandes como Guayas, donde se encuentra la matriz, otras como Pichincha, Cuenca, Loja y Manabí tienen departamentos comerciales o grupos de vendedores encargados de la zona, en el modelo planteado no se halló mayor relación estadística con las grandes provincias como Guayas, esto debido a que es la provincia con mayor cantidad de clientes. Dentro de la región Sierra, las provincias como Imbabura y Cotopaxi, con una relación positiva con la probabilidad de que un cliente sea riesgoso, mientras que Cañar presenta una relación inversa, es decir, que un cliente sea de esta provincia se traduce en menor probabilidad que entre en default.
- **Días de crédito:** Las formas de pago que ofrece la empresa son al contado, o por el contrario los usuarios pueden acceder a líneas de pago a plazo o también conocidas como crédito que van desde los 8 hasta los 75 días. Dentro del modelo logit, se pudo observar que a medida que aumentaban los días para poder pagar, el cliente se volvía más riesgoso. Así, un cliente que tiene aprobada una línea de crédito para 75 días es más riesgoso que uno de 60 o 45 días, uno de 60 días es más propenso a caer en mora que uno de 45 días y así sucesivamente.
- **Tipo de contribuyente:** Mediante el uso de esta variable se buscaba diferenciar cuando un cliente es una persona natural (1) y cuando es una persona jurídica (0), para la muestra tomaba el coeficiente de "pn" presenta signo negativo, por lo cual se puede decir que una persona natural es menos riesgosa que una jurídica. Este resultado posee lógica empresarial, pues las empresas por lo general atrasan los pagos a proveedores, poniendo siempre en primer lugar gastos de nómina y servicios básicos.
- **Límite de crédito:** Esta variable representa el cupo de crédito en miles de cada cliente, en esta existe diferencias significativas dependiendo del canal al que pertenecen, por ejemplo, el canal moderno (Supermercados y farmacias) poseen mayor crédito dado el volumen que representan, mientras que el canal tradicional (mayoristas y tiendas locales) no les otorgan tanto cupo y si desean aumentarlo deben presentar proyección de crecimiento. En el modelo planteado se evidencia una relación negativa con la probabilidad de ser calificado como mal cliente y por

ende tener cartera vencida. Esto es evidencia de la buena política implementada para extender el nivel de crédito a los clientes.

- **Antigüedad de los clientes:** Esta variable estima cuan antiguo es un cliente dentro de la institución, está medida en meses. El signo que presenta esta variable fue positivo, por lo que se puede asumir que mientras más tiempo forma parte una persona de la cartera de clientes de la empresa, es más probable que la misma caiga en mora crediticia.
- **Equifax:** Esta variable busca recoger y segmentar a los clientes por la calificación crediticia que tienen los clientes en el país, mediante una calificación que otorga del buró en el rango de 1 hasta 999, que segmenta como Malo al rango de 1 a 562, regular de 563 a 917 y excelente de 917 a 999, que es la misma segmentación que recogemos en las variables Malo y Excelente. En el modelo se presentó una relación positiva, es decir si un cliente se encuentra en el rango de calificado como malo en el equifax, presenta mayor probabilidad de caer en mora y por ende es más riesgoso, análogo a esto la variable Excelente presenta una relación inversa a la probabilidad de caer en mora. Por lo que esta herramienta es un buen indicador al momento de analizar una solicitud de crédito.
- **Sexo:** Es la variable por excelencia en cualquier tipo de estudio de las ciencias sociales y dentro de la literatura de modelos de credit score que recoge el sexo de los clientes, para el caso de las personas jurídicas se tomó el sexo del representante legal de la compañía, dentro del modelo esta variable no salió estadísticamente significativa y por ende no se puede otorgar ninguna interpretación, sin embargo, fue incluida como control.
- **Canal de distribución:** Dentro de la organización existen dos grandes segmentos, que tienen departamentos comerciales diferenciados, líneas de productos diferentes y políticas de venta diferentes, estos son el canal Masivo, que son aquellos productos de consumo masivo que tienen como destino las personas, mientras que el canal institucional está diseñado para cubrir a empresas y por lo general estos son los consumidores finales. En el modelo realizado la variable que representa a los clientes masivos no fue significativa, pero por el contrario la variable Institucional es significativa al 1% y con una relación positiva, es decir aquellos clientes de este canal podrían presentar mayor disposición o probabilidad a tener carteras vencidas.

3.2 Odds Ratio

Se calcularon los odds ratios de cada variable para verificar la relación existente entre las variables y la probabilidad de ser un cliente catalogado como Malo, donde se evidencia las relaciones ya sean estas positivas o negativas y adicional se identifica la magnitud de dicha relación.

Tabla 3-2 Odds Ratios

Logistic regression		Number of obs = 16,920		Wald chi2(19) = .		Prob > chi2 = .		Pseudo R2 = 0.0878	
Log pseudolikelihood = -10538.748		(Std. Err. adjusted for 153 clusters in cliente)							
Buenomalol	Odds Ratio	Robust Std. Err.	z	P> z	[95% Conf. Interval]				
prom_ingreso	1.000001	1.07e-07	5.33	0.000	1	1.000001			
produbanco	.5612276	.1320266	-2.46	0.014	.3539135	.8899813			
guayaquil	1.622442	.3915172	2.01	0.045	1.011027	2.603608			
pichincha	.5512891	.1318093	-2.49	0.013	.3450351	.880837			
imbabura	5.241805	1.73412	5.01	0.000	2.740831	10.02489			
cañar	.0412694	.0145011	-9.07	0.000	.020727	.0821712			
cotopaxi	13.98787	4.160906	8.87	0.000	7.808159	25.05847			
manabi	2.021079	.7442366	1.91	0.056	.9820623	4.159369			
sucumbios	1.586587	.2815923	2.60	0.009	1.120444	2.246662			
esmeraldas	14.23258	6.861437	5.51	0.000	5.532539	36.61361			
y045	1.958589	.6535736	2.01	0.044	1.018358	3.766916			
y060	2.399657	.8351109	2.52	0.012	1.213166	4.74655			
y075	10.03522	4.88601	4.74	0.000	3.864462	26.05945			
pn	.5046624	.1152125	-3.00	0.003	.3226078	.7894542			
lim_creditomiles	.9975999	.0004057	-5.91	0.000	.996805	.9983954			
antigüedadcomocliente_meses	1.018327	.0065011	2.84	0.004	1.005664	1.031149			
malo	1.667845	.4427935	1.93	0.054	.9912232	2.806337			
excelente	.4835527	.172765	-2.03	0.042	.2400625	.9740099			
hombre	.904456	.1630123	-0.56	0.577	.635292	1.287661			
masivo	.729223	.2743082	-0.84	0.401	.3488736	1.524238			
institucional	2.221219	.6328804	2.80	0.005	1.270758	3.882574			
_cons	.4294463	.1941276	-1.87	0.062	.177064	1.041567			

3.3 Consistencia del modelo

Con el fin de validar la consistencia del modelo planteado de credit score mediante modelo Logit, se procede a realizar la misma regresión mediante un modelo Probit y una regresión lineal, el modelo Probit que a diferencia del modelo logit que utiliza una función de probabilidad logística, modela los datos mediante una función normal de distribución. A continuación, se presentan los resultados obtenidos en una tabla comparativa:

Tabla 3-3 Regresiones OLS, Probit y Logit

VARIABLES	(1) Logit	(2) Probit	(3) OLS
prom_ingreso	5.72e-07*** (1.07e-07)	3.45e-07*** (6.33e-08)	1.27e-07*** (2.20e-08)

Produbanco	-0.578** (0.235)	-0.344** (0.136)	-0.124** (0.0508)
Guayaquil	0.484** (0.241)	0.292** (0.144)	0.103* (0.0537)
Pichincha	-0.595** (0.239)	-0.356** (0.142)	-0.131** (0.0514)
Imbabura	1.657*** (0.331)	0.978*** (0.207)	0.362*** (0.0731)
cañar	-3.188*** (0.351)	-1.685*** (0.205)	-0.379*** (0.0710)
Cotopaxi	2.638*** (0.297)	1.461*** (0.168)	0.455*** (0.0586)
Manabi	0.704* (0.368)	0.414* (0.221)	0.154* (0.0787)
Sucumbios	0.462*** (0.177)	0.278** (0.111)	0.0991*** (0.0379)
Esmeraldas	2.656*** (0.482)	1.594*** (0.274)	0.590*** (0.0943)
y045	0.672** (0.334)	0.405** (0.197)	0.145** (0.0700)
y060	0.875** (0.348)	0.528*** (0.205)	0.193*** (0.0727)
y075	2.306*** (0.487)	1.393*** (0.287)	0.493*** (0.0890)
Pn	-0.684*** (0.228)	-0.397*** (0.137)	-0.143*** (0.0492)
lim_creditomiles	-0.00240*** (0.000407)	-0.00145*** (0.000242)	-0.000534*** (8.50e-05)
antigüedadcomoc liente_meses	0.0182*** (0.00638)	0.0105*** (0.00377)	0.00379*** (0.00131)
Malo	0.512* (0.265)	0.292* (0.159)	0.105* (0.0571)
Excelente	-0.727**	-0.428**	-0.153**

	(0.357)	(0.217)	(0.0752)
Hombre	-0.100	-0.0703	-0.0322
	(0.180)	(0.109)	(0.0375)
Masivo	-0.316	-0.191	-0.0687
	(0.376)	(0.220)	(0.0794)
Institucional	0.798***	0.477***	0.169***
	(0.285)	(0.162)	(0.0587)
Constant	-0.845*	-0.485*	0.334***
	(0.452)	(0.264)	(0.0898)
Observations	16,920	16,920	16,920
R-squared			0.113

Robust standard errors in parentheses

*** $p < 0.01$, ** $p < 0.05$, * $p < 0.1$

En la tabla 2 se aprecian los coeficientes de cada variable para explicar la probabilidad de que un cliente entre en cartera vencida en los tres modelos antes mencionados, en la columna 1 el modelo Logit original, en la columna 2 el modelo Probit y por último en la columna 3 la regresión lineal, la significancia estadística de cada variable se aprecia mediante asteriscos (*), un asterisco representa que es estadísticamente significativo al 10%, dos al 5% y tres al 1%. Como se evidencia no existe mayor discrepancia en los resultados obtenidos con el modelo Logit con los otros dos, lo que representa robustez del modelo y de las variables utilizadas.

CAPÍTULO 4

4. CONCLUSIONES Y RECOMENDACIONES

En la actualidad, debido al crecimiento financiero constante y a la nueva forma de realizar las negociaciones es de gran importancia que las empresas tengan pleno conocimiento del riesgo que enfrentan y aún más en países emergentes como el caso de Ecuador, el cual enfrenta inestabilidad política y poco crecimiento económico; teniendo como fin la mejora de las operaciones crediticias se realizó un modelo de credit scoring.

La construcción de un modelo de credit scoring, aplicado a una empresa manufacturera, surgió ante la inquietud de lograr conseguir una herramienta matemática y estadística sólida que sea soporte en el proceso de validación de solicitudes de crédito y transferir o compartir esta responsabilidad entre la experiencia de los ejecutivos de crédito y un análisis estadístico.

Bajo este contexto se logró realizar un Modelo Logístico de credit scoring, considerando su frecuente utilización en la literatura precedente, además de sus ventajas al no requerir el supuesto de normalidad y realizar un análisis probabilístico individual. Se implementó el modelo con los clientes de la empresa manufacturera, su historial de pagos, información demográfica, comercial y financiera.

El desarrollo del proyecto permitió definir, luego de una larga revisión literaria, las determinantes que un potencial cliente requiere para acceder a un crédito, y así poder hallar aquellas variables en las que hay que poner mayor atención a la hora de evaluar una solicitud de crédito, para así poder contar con una aproximación de la calidad del cliente, entre las cuales se encuentran: el promedio de ingresos mensual, la institución financiera con quien mantenga relaciones comerciales, el tipo de organización al que pertenece, ubicación geográfica, sexo; dentro de la información comercial relevante está el cupo de crédito mensual solicitado, los días de crédito y el canal de distribución con el que desean trabajar siendo estos productos de consumo masivos o institucionales. Además de la herramienta Equifax, que es una calificación del historial crediticio de cada cliente.

Finalmente, mediante este trabajo se espera dar a conocer la importancia del nivel de riesgo que se encuentre presta a asumir la compañía, la capacidad de endeudamiento

o pago del cliente, y por último que la calificación del buró crediticio que tiene una empresa o persona natural es clave a la hora de conocer el comportamiento histórico de crédito y como se espera sea su comportamiento. De esta forma, los ejecutivos podrán seleccionar los clientes que deseen formen parte de la compañía según las políticas internas que se manejan.

La estimación probabilística de la calidad de los clientes existentes o potenciales resultó buena y validada con otros modelos, sin embargo, podría mejorarse teniendo como requisito proporcionar más información financiera, mejor discriminación de los horizontes comerciales, mejorando la categorización de variables y añadir aquellas que influyan directamente con el riesgo, sugeridas por expertos o que surjan de necesidades gerenciales.

Es importante que se valide constantemente el modelo de credit scoring para que se ajuste a los valores reales, nuevas necesidades y a las consideraciones de los expertos, con el fin de abarcar todos los aspectos posibles.

Cabe recalcar que los modelos de credit scoring dependen y se modelan de acuerdo con las necesidades de cada organización y se alimenta de la información solicitada por la misma en cada solicitud de crédito, por lo que la metodología y variables utilizadas en este trabajo no serán las mismas si se aplica en otra organización y dependerá de las políticas, objetivos, necesidades y el sector al que pertenezca cada una.

En forma general, se puede decir que la cartera de clientes de la empresa en estudio está conformada por un 20% de clientes buenos, que se encuentran dentro del rango de 1 a 0,7, un 29% de clientes medios determinados entre 0,69 a 0,5, y un 51% de clientes malos ubicados entre 0,49 a 0. Con esto, queda demostrado que el proceso realizado dentro de la empresa no es el más apropiado y se debe implementar de forma inmediata el uso de herramientas estadísticas durante la precalificación de créditos. Como dato importante y relevante de conocer, las estadísticas internas de la compañía demostraron que durante los años 2017 – 2018 se tuvo incremento del 8% al 18% de deuda vencida.

5. BIBLIOGRAFÍA

- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance*, 23(4), 589 - 609.
- Altman, E. I. (1980). Commercial bank lending: process, credit scoring, and costs of errors in lending. *Journal of Financial and Quantitative Analysis*, 15(4), 813-832.
- Apilado, V. P., Warner, D. C., & Dauten, J. J. (1974). Evaluative Techniques in Consumer Finance—Experimental Results and Policy Implications for Financial Institutions. *Journal of financial and Quantitative Analysis.*, 9(2), 275-283.
- Bellotti, T., & Crook, J. (2009). Credit scoring with macroeconomic variables using survival analysis. *Journal of the Operational Research Society*, 60(12), 1699-1707.
- Crook, J. N., Hamilton, R., & Thomas, L. C. (1992). A comparison of a credit scoring model with a credit performance model. *Service Industries Journal*, 12(4), 558-579.
- Fernandez, H., & Pérez, F. O. (2005). El modelo logístico : una herramienta estadística para evaluar el riesgo de crédito. *Revista Ingenierías Universidad de Medellín*, 4, 55-75.
- García Sánchez, M., & Sánchez Barradas, C. (2005). Riesgo de crédito en México: aplicación del Modelo CreditMetrics.
- Glorfeld, L. W. (1990). A robust methodology for discriminant analysis based on least-absolutevalue estimation. *Managerial and Decision Economics.*, 11(4), 267-277.
- Gutierrez Girault, M. A. (2007). Modelos de credit scoring: qué, cómo, cuándo y para qué [Credit scoring models: what, how, when and for what purposes]. *University Library of Munich, Germany.*(16377).
- Hand, D. J., & Henley, W. E. (1997). Statistical Classification Methods in Consumer Credit Scoring: a Review. *Royal Statistical Society*, 523-541.
- Majer, I. (2006). Application scoring: Logit model approach and the divergence method compared. *Doctoral dissertation, Warsaw School of Economics.*
- Mester, L. J. (1997). What's the point of credit scoring? *Business review*, 3-16.
- Myers, J. H., & Forgy, E. W. (1963). The development of numerical credit evaluation systems. *Journal of the American Statistical Association*, 58(303), 799-806.
- Orgler, Y. E. (1970). A Credit Scoring Model for Commercial Loans. *Journal of Money, Credit & Banking*. *Ohio State University Press*, 2(4).

- Rayo, S., Lara, J., & Camino, D. (2010). Un modelo de credit scoring para instituciones de microfinanzas en el marco de Basile II. *Journal of Economics, Finance & Administrative Science.*, 15(28), 89-124.
- Rodriguez, D. E., & Trespalacios, A. (2015). Medición de Valor en Riesgo en Cartera de Clientes a través de Modelos Logísticos y Simulación de Montecarlo. *Repositorio Institucional Universidad EAFIT.*
- Rodríguez-Guevara, D., Becerra-Arévalo, J., & Cardona-Valencia, D. (2017). Modelos y metodologías de credit score para personas naturales: una revisión literaria. *Revista CEA*, 3(5), 13-28.
- Saldaña, E. M., Cervantes, H. R., Salvador, B. R., & Sanabria, F. S. (s.f.). *Evaluación del Riesgo Crediticio, a través de Credit Scoring mediante Regresión logística: Un caso de estudio.*
- Schreiner, M. (2002). Ventajas y desventajas del scoring estadístico para las microfinanzas. *Microfinance Risk Management, Washington University in St. Louis.*, 1-40.
- Srinivasan, V., & Kim, Y. H. (1987). Credit Granting: A Comparative Analysis of Classification Procedures. *The Journal of Finance*, 42(3).
- Valencia Echeverri, A. (2017). Modelo Scoring para el otorgamiento de crédito de las Pymes. (*Master's thesis, Universidad EAFIT*).
- Wiginton, J. C. (1980). A note on the comparison of Logit and discriminant models of consumer credit behavior. *Journal of Financial and Quantitative Analysis*, 15(03), 757-770.
- Zhai, H., & Russell, J. S. (1999). Stochastic modelling and prediction of contractor default risk. *Construction Management & Economics*, 17(5), 563-576.
- Zhou, L., Lai, K. K., & Yen, J. (2009). Credit scoring models with AUC maximization based on weighted SVM. *International journal of information technology & decision making*, 8(4), 677-696.