

UNIVERSIDAD PERUANA UNIÓN
FACULTAD DE CIENCIAS EMPRESARIALES
Escuela Profesional de Contabilidad



**Variables predictoras de Impago de responsables financieros
en una universidad privada**

Tesis para obtener el Título Profesional de Contador Público

Autor:

Benjamín David Trinidad Ticse

Asesor:

Dr. Christian Vallejos Angulo

Tarapoto, marzo de 2023

DECLARACIÓN JURADA DE AUTORÍA DE TESIS

Yo, Dr. Christian Vallejos Angulo, de la Facultad de Ciencias Empresariales, Escuela Profesional de Contabilidad, de la Universidad Peruana Unión.

DECLARO:

Que la presente investigación titulada: **“VARIABLES PREDICTORAS DE IMPAGO DE RESPONSABLES FINANCIEROS EN UNA UNIVERSIDAD PRIVADA”** del autor Benjamín David Trinidad Ticse tiene un índice de similitud de 11% verificable en el informe del programa Turnitin, y fue realizada en la Universidad Peruana Unión bajo mi dirección.

Y estando de acuerdo, firmo la presente declaración en la ciudad de Tarapoto a los 16 días del mes de marzo del año 2023



Dr. Christian Vallejos Angulo

ACTA DE SUSTENTACIÓN DE TESIS

En san Martín, Tarapoto, Morales, a los 16 día(s) del mes de marzo del año 2023 siendo las 08:30 horas se reunieron los miembros del jurado en la Universidad Peruana Unión campus Tarapoto, bajo la dirección del (de la) Presidente(a): Dr. Avelino Sebastián Villafuerte De La Cruz, el (la) secretario(a): Dr. Juan Félix Quispe Gonzales los demás miembros, Dr. Edual Delmar Santos Gutierrez; CPCC. Erika Liliana Castro Carlos, y el asesor(a): Dr. Christian Daniel Vallejos Angulo, con el propósito de administrar el acto académico de sustentación de la tesis titulado:

“Variables predictoras de impago de responsables financieros en una universidad privada, 2021.”

de los (las) bachiller (es): a) Benjamín David Trinidad Ticse b) c) Conducente a la obtención del título profesional de:

Contador Público

El presidente inició el acto académico de sustentación invitando al (a la) / a (los) (las) candidato (a)/s hacer uso del tiempo determinado para su exposición. Concluida la exposición, el Presidente invitó a los demás miembros del jurado a efectuar las preguntas, y aclaraciones y la emisión del dictamen del jurado.

Posteriormente, el jurado procedió a dejar constancias escrita sobre la evaluación en la presente acta, con el dictamen siguiente:

Bachiller (a): Benjamín David Trinidad Ticse

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
APROBADO	18	A-	MUY BUENO	SOBRESALIENTE

Bachiller (b):

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	

Bachiller (c):

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	

Finalmente, el Presidente del jurado invito al (a la) / (los) (las) candidato (a)/s a ponerse de pie, para recibir la evaluación final y concluir el acto académico de sustentación procediéndose a registrar las firmas respectivas.

.....
Presidente/a

.....

Secretario/a

.....
Asesor

.....
Miembro

.....
Miembro

.....
Bachiller (a)

.....
Bachiller (b)

.....
Bachiller (c)

Resumen

Objetivo: Identificar variables predictoras de impago en responsables financieros en una universidad privada. **Metodología:** El diseño de la investigación es explicativo, pues se discriminan variables que ayudan a predecir la probabilidad de impago mediante la regresión logística binaria (logit). **Resultados:** Las variables: tipo de vivienda, escolaridad, estatus laboral, trabajo adicional, deudas al banco y trabajo adicional del cónyuge, tienen un p-valor 0.000 menor al 1% lo que indica que contribuyen al modelo en forma significativa para predecir impago en responsables financieros. **Conclusión:** La presente investigación muestra que existen 6 variables predictoras de impago en responsables financieros. Estas variables adecuadamente manejadas ayudarían a optimizar las decisiones que se toman en relación al riesgo crediticio en las instituciones educativas privadas, mejoraría el flujo de efectivo, favorecería a tomar decisiones crediticias más rápidas y permitiría un monitoreo más cercano de las cuentas por cobrar existentes priorizando la cobranza. Asimismo, reduciría el costo del análisis crediticio, costos de cobranzas y morosidad en las instituciones ya mencionadas.

Palabras clave: Puntuación crediticia, Minería de Datos, Probabilidad de impago, responsable financiero, Credit Scoring, Default.

Abstract

Objective: To identify predictor variables of non-payment in financial officers in a private university. **Methodology:** The research design is explanatory, since variables that help to predict the probability of default are discriminated by means of binary logistic regression (logit). **Results:** The variables: type of housing, schooling, employment status, additional work, debts to the bank and additional work of the spouse, have a p-value of 0.000 less than 1%, which indicates that they contribute significantly to the model to predict non-payment in financially responsible persons. **Conclusion:** The present research shows that there are 6 predictor variables of non-payment in financially responsible individuals. These variables, if properly managed, would help to optimize the decisions made in relation to credit risk in private educational institutions, improve cash flow, favor faster credit decisions and allow closer monitoring of existing accounts receivable, prioritizing collection. It would also reduce the cost of credit analysis, collection costs and delinquency in the aforementioned institutions.

Keywords: Credit Score, Data Mining, Probability of Default, Financial Responsible, Credit Scoring, Default.

1. Introducción

La calificación crediticia o credit scoring, es la valoración automática del riesgo frente a un crédito (Marginson, 2020)(Puertas & Martí, 2012), por lo tanto, es un tema de vital importancia para las instituciones financieras, pues una extensión en 1% en relación a la puntuación crediticia ayudaría a recuperar grandes pérdidas para este tipo de empresas (Wang, Ma, Huang, & Xu, 2012). Existen muchos métodos de calificación crediticia, tanto tradicionales, estadísticas y de inteligencia artificial que ayudan a minimizar el riesgo crediticio en las empresas (Abdou & Pointon, 2011). A pesar de los diferentes métodos de calificación crediticia, la regresión logística continúa siendo el método más utilizado para predicción de incumplimiento de pago (Gurný & Gurný, 2013; Teles, Rodrigues, Kozlov, Rabêlo, & Albuquerque, 2020).

Por otro lado, en relación a la educación superior, ha aumentado la cantidad de universidades y por ende estudiantes a nivel mundial (SUNEDU, 2020), se presume que a nivel mundial existen 20 000 universidades y alrededor de 200 millones de estudiantes (Altbach & De Wit, 2020). Actualmente en el Perú, los estudiantes de universidades privadas representan el 71.1 a 80.8% (aprox. 1 072 800) frente a un 19.2 a 29.9% de estudiantes en universidades públicas (436 300) (Benites, 2021), la cantidad de estudiantes que eligen universidades privadas ha ido incrementándose en los últimos diez años (2010-2019), asimismo, en una década se ha pasado de 74 a 139 universidades que brindan servicios académicos de los cuales 50 son universidad públicas, 41 son privadas asociativas y 48 privadas societarias (SUNEDU, 2020).

Asimismo, con la llegada de la pandemia COVID-19, este fenómeno ha afectado financieramente a las universidades privadas en primer lugar y luego a las públicas (Marginson, 2020). Pues las universidades privadas dependen de la matrícula y las pensiones para el sostén de la misma (Altbach & De Wit, 2020), La federación de Instituciones Privadas de educación superior calcula que por temas de impago (30% en algunas universidades), deserción y otros problemas, probablemente 10 universidades tengan que cerrar (Benites, 2021; La Tercera, 2020). Es probable también que en el afán de tener más estudiantes, las universidades privadas matriculaban más estudiantes sin realizar una evaluación financiera al responsable financiero.

Por todo lo mencionado, existen pocas investigaciones de probabilidad de incumplimiento de pago en instituciones no financieras, en este caso universidades privadas. Sin embargo, existen estudios realizados en entidades financieras como Cooperativas de Ahorro y Crédito (Minga, 2019; Perez, 2017), Cajas municipales (Quiroz, 2020, Atencio, 2019, y empresas en el sector textil (Aldana, Garavito, & Ramos Botia, 2019). El problema de impago en universidades privadas es serio y merece ser analizado para poder brindar herramientas y enfrentar a esta amenaza. Las universidades privadas tienen dificultades para saber si un cliente (responsable financiero), es decir pueda pagar la educación de su menor, en ese sentido, ¿cómo discriminar a los clientes buenos de los clientes malos? O ¿qué medidas debo tomar para la evaluación crediticia a los responsables financieros de las universidades privadas? Estas preguntas ayudan a las instituciones a orientarse y tomar decisiones correctas para que puedan tener una buena rentabilidad.

La presente investigación es relevante por el aporte institucional, el cual está esbozado por la necesidad urgente en las instituciones de educación superior particulares de gestionar los créditos que se dan al estudiante, ya que éste, según el cronograma de pagos, tiene que cancelar la pensión de enseñanza. Por lo cual este instrumento ayudará a tomar políticas saludables para el trabajo del área de créditos y

cobranzas en las instituciones educativas privadas. Asimismo, es relevante por el aporte teórico que brinda al área de créditos y cobranzas de las universidades privadas, ampliando de esta manera las teorías existentes sobre los riesgos crediticios, sin embargo, el presente estudio corroborará las teorías existentes que muestran las ventajas y desventajas de otorgar el servicio educativo a estudiantes que no cuentan los recursos económicos para estudiar. También, esta investigación resalta en metodología porque identifica variables predictoras de impago mediante la regresión logit. Esta herramienta es el soporte para la toma de decisiones en el área de créditos y cobranza. En último lugar, como relevancia social está basada en que los datos producto de este trabajo científico, servirán para que los responsables de las instituciones educativas privadas puedan tomar conciencia de la gestión del riesgo crediticio y su impacto en general en la universidad.

Hasta donde se ha investigado, este estudio representa el primer intento de analizar variables predictoras de impago en empresa de servicios educativos privadas (universidades). Este documento tiene la siguiente estructura: (1) la calificación crediticia y sus métodos, (2) el impago y sus métodos para predecirlo, (3) la regresión logística, (4) resultados de la investigación, y (5) comentarios y conclusión.

Calificación crediticia y sus métodos

La calificación crediticia es el proceso evaluativo para otorgar o no un crédito a una persona, minimizando el riesgo de impago, como tal pertenece a la gestión de cuentas por cobrar, es decir, es el área de cobranzas y créditos el que determina la calificación crediticia, otorgamiento de crédito y por ende la gestión del riesgo crediticio (Horngren, Harrison Jr., & Smith Baber, 2003; Elizondo & Altman, 2004; Ross, Westerfield, & Jaffe, 2010; Ortiz, 2011; Morales & Morales, 2015). Dicha área intenta minimizar la probabilidad de perder dinero como efecto del incumplimiento contractual del cliente a lo que también se llama riesgo crediticio (Rodríguez, n.d.; Quispe, 2013).

Asimismo, existen métodos de calificación crediticia, que en esencia la mayoría son buenos (Finlay, 2009). Entre estos métodos tenemos: (1) analizar el carácter, capacidad, capital, colaterales y condiciones, conocidas como las 5 "C" (Delgado, 2009); (2) método de capacidad financiera; (3) análisis discriminante (Morales & Morales, 2015); (4) Z score de Altam; (5) CreditMetrics (Elizondo & Altman, 2004). Generalmente la clasificación crediticia y la predictibilidad están asociados como parte del proceso de los análisis de riesgo crediticio, existen modelos estadísticos de calificación crediticia como: (1) máquina de vectores de soporte (SVM), (2) árboles de decisión, (3) regresión logística, (4) redes neuronales, y otros modelos mixtos (Huang & Day, 2013) que serán vistos en el siguiente párrafo.

Impago (default) y sus métodos para predecirlo

El incumplimiento de pago o default es cuando el cliente no cumple con sus compromisos financieros, sin embargo, se puede predecir a partir del análisis de ciertas variables (Minga, 2019). Existen muchos métodos para predecir la probabilidad de impago, tenemos los modelos tradicionales como las 5C ó 8C ejecutados por personas en base a criterios y experiencias pasadas, sin embargo las inconsistencias de muchos expertos, elevados costos para capacitar personas, la demora de procesar información, etc. ha dado paso nuevos modelos para la puntuación crediticia como los métodos estadísticos donde se encuentran la regresión lineal (LR) y logística, el análisis discriminante lineal (Liberati, Camillo, & Saporta, 2015), árboles de decisión (DT) y sus variantes (Wang et al., 2012) y modelos basados en métodos de inteligencia artificial llamadas redes neuronales (NN) (Jagric & Jagric, 2011; Blanco, Pino-Mejías, Lara, & Rayo, 2013), algoritmos genéticos (GA), algoritmos difusos (Cubiles-De-La-Vega, Blanco-Oliver, Pino-Mejías, & Lara-Rubio, 2013; Nalić &

Martinovic, 2020), en relación a estos últimos han evolucionado a modelos modernos llamados modelos híbridos, dentro de la calificación crediticia, basados en el algoritmo de selección de características y clasificadores de conjuntos, es decir hacen uso de la inteligencia artificial (Ping & Yongheng, 2011; Yao & Chen, 2019; Nalić, Martinović y Žagar, 2020), el Sistema de Inferencia Neuro Difusa Adaptativo (ANFIS) (Akkoc, 2012) que es una propuesta de puntuación en tres etapas, basado en técnicas estadísticas y NF (Neuro Fuzzy).

Tanto los modelos estadísticos como la inteligencia artificial pertenecen a técnicas de minería de datos que son aplicados a diferentes campos, en este caso son usados para la calificación crediticia (Kambal, Osman, Taha, Mohammed y Mohammed, 2013).

Marqués, García y Sánchez (2013) han elaborado una revisión de la literatura sobre la aplicación de la computación evolutiva a la calificación crediticia, en dicho trabajo elaboran un recuento de investigaciones realizadas del 2000 al 2012 agrupadas en tres grupos: la clasificación, la selección de variables y optimización de parámetros. Actualmente el campo que se ocupa de analizar datos para poder predecir conductas de impago es la minería de datos (Imtiaz & J., 2017).

Regresión logística

Tener una cantidad de datos (Big data) y usarlos para el análisis predictivo se ha vuelto en un recurso importante para el ámbito empresarial y académico (Gunasekaran et al., 2017), es decir, predecir el default tiene una injerencia importante hoy. Así como los otros métodos de predecir impago, la regresión logística, introducida por Berkson (1944), es una buena alternativa para este problema (Zhou, Lai, & Yen, 2009; Ruiz, Gomes, Rodrigues, & Gama, 2019). Dicho modelo se caracteriza por ser el más usado en la industria bancaria (Jagric & Jagric, 2011) y por trabajar con la variable dependiente discreta llamadas también Dummy (Gordon, 2015). Estas variables son binomiales y oscilan entre 1 si ocurre el evento y 0 cuando no ocurre el evento, asimismo, las variables independientes o predictoras pueden ser categóricas o continuas, estas variables son agrupadas (Cox, 1958; Kocenda & Vojtek, 2009) y recodificadas como variables dummy de modo que las respuestas oscilan entre 0 y 1, de eso modo es posible para aplicar la regresión logística (Welc & Esquerdo, 2018). En relación a la predictibilidad, la regresión logística predice mejor las variables categóricas que la regresión lineal, es decir, es el más apropiado para predicción de incumplimiento porque representa mejor la relación funcional entre las variables dependientes (Y) e independientes (X) (Gurný & Gurný, 2013; Teles, Rodrigues, Kozlov, Rabêlo, & Albuquerque, 2020). Se debe agregar que Srinivasan y Kim (1987), realiza una comparación de modelos de clasificación financiera comparando 4 modelos: (1) Análisis Discriminante Múltiple (MDA); (2) Regresión Logística (logit); (3) Programación de Objetivos (GP); Algoritmo de Participación Recursiva (RPA); y un modelo de juicio basado en el Proceso de Jerarquía Analítica (AHP) en las cuales la regresión logística tiene menos sesgos a comparación de los otros modelos.

La ecuación de la regresión logística es:

$$\text{Logit}(p) = \log \left[\frac{p}{1-p} \right] = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n$$

En la ecuación anterior “ p ” representa la probabilidad del resultado, $\beta_1 \dots \beta_n$ representa los coeficientes de regresión en la combinación lineal de predictores descriptivos $X_1 \dots X_n$ y α es el intercepto.

Cabe señalar que la regresión logística también se llama modelo logit, que se diferencia del modelo probit por su calidad y comprensión en la clasificación de un

objeto, asimismo, a su vez la variable dependiente binaria se la llama logits (Welc & Esquerdo, 2018). La tabla 1 muestra el proceso de aplicación del modelo logit.

Tabla 1. El procedimiento de estimación del modelo logit para una variable dependiente binaria

Paso 1	<p>Transforme una variable dependiente binaria Y de la siguiente forma:</p> $Y = \begin{cases} 1 & \text{si el evento analizado ha ocurrido} \\ 0 & \text{si el evento analizado no ha ocurrido} \end{cases}$ <p>en la variable de probabilidad P de la siguiente forma</p> $P = \begin{cases} 0,999 & \text{si el evento analizado ha ocurrido} \\ 0,001 & \text{si el suceso analizado no ha ocurrido} \end{cases}$
Paso 2	<p>Transforme cada observación de una variable de probabilidad P en una variable logit L con la siguiente fórmula:</p> $L_i = \log \frac{p_i}{1 - p_i}$ <p>Donde:</p> <p>L_i— valor del logit para i-la observación, p_i— probabilidad de un evento en el caso de i-la observación.</p>
Paso 3	Estimar la regresión de la variable logit L frente al conjunto de sus variables explicativas y calcular sus valores ajustados.
Paso 4	<p>Invierta los valores ajustados de las observaciones individuales de la variable logit L en las probabilidades con la siguiente fórmula:</p> $p_i = \frac{10^{L_i}}{1 + 10^{L_i}}$

Fuente: Welc y Edquedo, 2018.

2. Metodología

La presente investigación explicativa (Cooper y Schindler citado en Jonker & Pennink, 2010) tiene un diseño no experimental de corte transversal ya que la obtención de los datos se realizó una sola vez en la unidad de análisis (Bernal, 2006), se utilizó un instrumento de recolección de datos y se aplicó de manera virtual. Es interés de los investigadores analizar las causas que del impago en responsables financieros.

La población objeto de estudio estuvo constituido por 1648 responsables financieros de una universidad privada de educación superior que incluía sus sedes, de los cuales sus hijos o en algunos casos ellos mismos estuvieron matriculados en el año 2021. También los encuestados pertenecían a la modalidad presencial y Semipresencial de la mencionada universidad, aunque por motivos de la pandemia COVID 19, las clases fueron virtuales.

Una vez tenida la carta de la comisión de ética de la universidad se procedió a aplicar el instrumento de manera virtual. Los datos obtenidos se procesaron mediante el programa estadístico SPSS en su versión 22. En el caso de las variables cualitativas (sexo, estado civil, permanencia en la residencia actual, tipo de vivienda, grado

académico y actividad económica) han sido reconvertidas en variables dummy para que se pueda aplicar la regresión logística (Welc & Esquerdo, 2018).

3. Resultados

A continuación, se presentan las tablas de los resultados de la presente investigación.

En la tabla 2 se observan las 26 variables predictoras incluidas por los investigadores que podrían ser causales del impago de los responsables financieros, estas variables son cualitativas (estado civil, escolaridad, etc.) y también cuantitativas (sueldo), como ya se mencionó anteriormente, las variables cualitativas han sido recodificadas a variables binarias (Dummy) para que puedan ser procesadas en la regresión logística.

Tabla 2

Variables predictoras de impago

N°	Variables predictoras
1	Estado civil soltero
2	Estado civil casado
3	Estado civil conviviente
4	Estado civil divorciado
5	Número de hijos menores de edad que tiene el Responsable Financiero
6	Residencia más de 5 años
7	Residencia de 3 a 5 años
8	Residencia de 1 a 2 años
9	Tipo de vivienda del Responsable Financiero
10	Títulos a su propiedad del Responsable Financiero
11	Escolaridad sin estudios
12	Escolaridad primaria/secundaria
13	Escolaridad técnico/universitaria
14	Actividad económica del Responsable Financiero
15	Actividad económica del Responsable Financiero(1)
16	Actividad económica del Responsable Financiero(2)
17	Actividad económica del Responsable Financiero(3)

- 18 Actividad económica del Responsable Financiero(4)
- 19 Actividad económica del Responsable Financiero(5)
- 20 Actividad económica del Responsable Financiero(6)
- 21 Estatus laboral empleado
- 22 Estatus laboral contratado
- 23 Estatus laboral independiente con negocio propio
- 24 Cuántos años viene laborando el Responsable Financiero
- 25 Ingresos aproximados mensuales en soles del Responsable Financiero
- 26 El responsable financiero (persona que paga tus estudios) tiene un trabajo adicional
- 27 El responsable financiero (persona que paga tus estudios) tiene actualmente deudas al banco por algún préstamo
- 28 El cónyuge (esposa/o) del responsable financiero (persona que paga tus estudios) tiene algún trabajo
- 29 Ingreso aproximado mensual en soles del cónyuge del responsable financiero (persona que paga tus estudios)

Nota. Elaborado por el autor

La tabla 3 muestra los casos incluidos en la presente investigación, en total fueron 1648, estos fueron responsables financieros tanto de la modalidad presencial y Semipresencial.

Tabla 3

Total de casos procesados

Casos sin ponderar^a		N	Porcentaje
Casos seleccionados	Incluido en el análisis	1648	99,9
	Casos perdidos	1	,1
	Total	1649	100,0
Casos no seleccionados		0	,0
Total		1649	100,0

En la tabla 4 se observa la codificación de las variables de la investigación. Las variables predictoras ya fueron vistas en la tabla 2, ahora se observa la codificación de la variable dependiente impago. Esta variable es binaria (Dummy), por lo tanto, su codificación oscila en "0" y "1", el "0" corresponde a mal pagador y el "1" a buen

pagador, es decir el "1" indica la probabilidad de que sea un buen pagador en base a las variables predictoras.

Tabla 4

Codificación de variable dependiente

Valor original	Valor interno
Mal pagado	0
Buen pagador	1

En la tabla 5 se observa el Bloque "0" o bloque de inicio que nos indica el modelo inicial en la que se utiliza la constante de la ecuación y omitimos todos los predictores de regresión se observa que 920 son buen pagador y 720 mal pagador, aquí se observa que el modelo será aceptado en 928 de las 1648 veces lo que corresponde a una tasa de acierto del 56,3%.

Tabla 5

Bloque de inicio

Observado		Pronosticado		
		Probabilidad de impago		Porcentaje correcto
		Mal pagado	Buen pagador	
Probabilidad de impago	Mal pagado	0	720	,0
	Buen pagador	0	928	100,0
Porcentaje global				56,3

En la tabla 6 se muestra el resumen del el R cuadrado de Nagelkerke es 0,145, indica que el modelo propuesto explica el 14,5% de la variable dependiente impago, es muy bajo el porcentaje y no es bueno hacer estimaciones.

Tabla 6

Resumen del modelo

Paso	Logaritmo de la verosimilitud -2	R cuadrado de Cox y Snell	R cuadrado de Nagelkerke
1	2069,279 ^a	,108	,145

Nota. a. La estimación ha terminado en el número de iteración 4 porque las estimaciones de parámetro han cambiado en menos de .001.

En la tabla 7 se observan los resultados de la ecuación en el cual se muestran las variables predictoras que entrarían al modelo por su significancia. Las variables que no ingresan serían estado civil (soltero p-0.779, casado p-0.428, conviviente p-0.396, divorciado p-0.568, número de hijos (p-0.452), residencia (más de 5 años p-0.356, de 3 a 5 años p-0.512, de 1 a 2 años p-0.963), títulos de propiedad a nombre del responsable financiero (p-0.122), escolaridad (tiene primaria o secundaria p-0.210, tiene carrear técnica o universitaria p-0.330), en relación a las actividad económica del responsable financiero tampoco es significativa, estatus laboral independiente con negocio propio (p-0.406), cuántos años viene laborando el responsable financiero (p-0.319), ingresos aproximados mensuales en soles del responsable financiero (p-0.053), ingreso aproximado mensual en soles del cónyuge del responsable financiero (p-0.988).

Tabla 7

Variables en la ecuación

		B	Error estándar	Wald	gl	Sig.	Exp(B)
Paso 1 ^a	Estado civil soltero	,127	,452	,079	1	,779	1,135
	Estado civil casado	,364	,459	,629	1	,428	1,440
	Estado civil conviviente	,417	,491	,722	1	,396	1,517
	Estado civil divorciado	,336	,588	,327	1	,568	1,399
	Número de hijos menores de edad que tiene el Responsable Financiero	-,032	,042	,565	1	,452	,969

Residencia más de 5 años	,159	,172	,851	1	,356	1,172
Residencia de 3 a 5 años	,141	,215	,431	1	,512	1,152
Residencia de 1 a 2 años	,011	,226	,002	1	,963	1,011
Tipo de vivienda del Responsable Financiero	,466	,128	13,243	1	,000	1,593
Títulos de propiedad del Responsable Financiero	,187	,121	2,391	1	,122	1,206
Escolaridad sin estudios	-,778	,296	6,908	1	,009	,459
Escolaridad primaria/secundaria	-,307	,245	1,572	1	,210	,736
Escolaridad técnico/universitaria	-,220	,226	,951	1	,330	,802
Actividad económica del Responsable Financiero			8,302	6	,217	
Actividad económica del Responsable Financiero(1)	,072	,170	,182	1	,669	1,075
Actividad económica del Responsable Financiero(2)	-,426	,253	2,841	1	,092	,653
Actividad económica del Responsable Financiero(3)	,279	,159	3,063	1	,080	1,322

Actividad económica del Responsable Financiero(4)	,175	,278	,396	1	,529	1,191
Actividad económica del Responsable Financiero(5)	-,186	,329	,319	1	,572	,830
Actividad económica del Responsable Financiero(6)	,118	,216	,301	1	,584	1,126
Estatus laboral empleado	,434	,163	7,046	1	,008	1,543
Estatus laboral contratado	,640	,194	10,925	1	,001	1,897
Estatus laboral independiente con negocio propio	,132	,159	,691	1	,406	1,142
Cuántos años viene laborando el Responsable Financiero	,006	,006	,994	1	,319	1,006
Ingresos aproximados mensuales en soles del Responsable Financiero	,000	,000	3,729	1	,053	1,000
El responsable financiero (persona que paga tus estudios) tiene un trabajo adicional	,392	,143	7,553	1	,006	1,480

El responsable financiero (persona que paga tus estudios) tiene actualmente deudas al banco por algún préstamo	-,726	,110	43,567	1	,000	,484
El cónyuge (esposa/o) del responsable financiero (persona que paga tus estudios) tiene algún trabajo	,323	,126	6,537	1	,011	1,381
Ingreso aproximado mensual en soles del cónyuge del responsable financiero (persona que paga tus estudios)	,000	,000	,000	1	,988	1,000
Constante	-,468	,530	,783	1	,376	,626

a. Variables especificadas en el paso

En la tabla 8 se muestran las variables que entrarían al modelo por ser significativas. La variable “Tipo de vivienda...” tiene un p-valor 0.000 menor al 1% lo que indica que contribuyen al modelo en forma altamente significativa, asimismo, la variable “Escolaridad (esta variable fue dicotomizada y esta variable corresponde a alguien que no tiene estudios o no tiene escolaridad)” tiene una p-valor de 0.009, de la misma manera la variable “Estatus laboral Empleado del Responsable Financiero” tiene un p-valor de 0.008 y “Estatus laboral contratado del Responsable Financiero” tiene un p-valor de 0.001, al mismo tiempo la variable “El responsable financiero (persona que paga tus estudios) tiene un trabajo adicional” tiene un p-valor de 0.006, también la variable “El responsable financiero tiene actualmente deudas al banco por algún préstamo” tiene un p-valor 0.000, finalmente la variable “El cónyuge (esposa/o) del responsable financiero tiene algún trabajo” tiene un p-valor de 0.011, todas la variable mencionadas tienen un p valor menor que el nivel de significancia 0,05, esas variables son significativas y contribuyen significativamente al modelo. Cabe recalcar que la variable “Ingresos aproximados mensuales en soles del Responsable Financiero” tiene un p-valor 0.053 y es mayor al nivel de significancia por poco.

Tabla 8*Variables en la ecuación*

	B	Error estándar	Wald	gl	Sig.	Exp(B)
Tipo de vivienda del Responsable Financiero	,466	,128	13,243	1	,000	1,593
Escolaridad sin estudios	-,778	,296	6,908	1	,009	,459
Estatus laboral empleado	,434	,163	7,046	1	,008	1,543
Estatus laboral contratado	,640	,194	10,925	1	,001	1,897
Ingresos aproximados mensuales en soles del Responsable Financiero	,000	,000	3,729	1	,053	1,000
El responsable financiero (persona que paga tus estudios) tiene un trabajo adicional	,392	,143	7,553	1	,006	1,480
El responsable financiero (persona que paga tus estudios) tiene actualmente deudas al banco por algún préstamo	-,726	,110	43,567	1	,000	,484

El cónyuge (esposa/o) del responsable financiero (persona que paga tus estudios) tiene algún trabajo	,323	,126	6,537	1	,011	1,381
--	------	------	-------	---	------	-------

4. Discusión

Como se mencionado anteriormente, hasta donde se ha investigado no hay artículos sobre calificación crediticia en universidades privadas, la mayoría de las investigaciones se encuentran en el sector bancario (credit scoring). Sin embargo, en las investigaciones en el sector bancario, Kocenda y Vojtek (2009), Blanco et al., (2013), en su investigación hallan que las variables sociodemográficas, dentro de ellas las cualitativas como (sexo, estado civil, área de trabajo, educación, etc.) juegan un papel decisivo en el proceso de concesión del crédito, por tanto, no deberían excluirse de la especificación del modelo de scoring de créditos. Asimismo, variables cuantitativas como ingresos salariales, edad, número de hijos, etc. (Nalić & Martinovic, 2020) son importantes en los modelos predictivos en instituciones financieras (Kambal et al., 2013, Ruiz et al. 2019).

Aunque dichos estudios fueron en el sector financiero, en el sector educativo seis variables cualitativas predicen el impago, Kocenda, Vojtek hallaron que el nivel de educación es un fuerte predictor de impago, en nuestro caso la escolaridad con un $p=0.009$ es significativo, el cual indica que una persona sin estudios tendrá más riesgo de ser mal pagador que los que tienen escolaridad. Del mismo modo, existe una alta probabilidad que aquellos sin una vivienda propia sean malos pagadores.

Aunque la variable “ingresos” con un p -valor 0.053 no es estadísticamente significativo, es decir, es un factor relativamente fuerte en el modelo, Kocenda y Vojtek lo consideran como un principal predictor. Esta variable debería seguir siendo estudiada en estudios posteriores o en muestras diferentes.

El estado civil, edad y género tienen bajos valores predictivos (no significativos) en este estudio, Kocenda y Vojtek llegan a la misma conclusión, podría ser porque las personas, independientemente de su género, edad y estado civil, han desarrollado hábitos financieros según su realidad que definitivamente son relevantes en el impago.

Es claro que las variables cuantitativas y cualitativas son importantes al momento de plantear modelos predictivos para credit scoring. En el caso de las universidades privadas hay poca información sobre la gestión de los créditos, el propósito de este estudio fue de manera general identificar las variables que son significativas para predecir el impago, queda para una investigación posterior poder elaborar modelos híbridos que ayuden a mejorar la predictibilidad y por ende mejorar la gestión crediticia (reducción de morosidad).

Los variables significativas encontradas en esta investigación (Tipo de vivienda, Escolaridad, Estatus laboral, Tiene un trabajo adicional, Deudas al Banco, Trabajo adicional el cónyuge (esposa/o) del Responsable Financiero) llegarán a ser la base para que desarrollen más investigaciones tomando como base lo ya mencionado. De esta manera el problema de calificación crediticia en universidades privadas puede ser mejorado.

5. Conclusiones

El estudio ha identificado que las variables predictoras de impago son: tipo de vivienda, escolaridad, estatus laboral, trabajo adicional, deudas al banco y trabajo adicional del cónyuge. Estas variables tienen un p-valor 0.000 menor al 1% lo que indica que contribuyen al modelo en forma significativa para predecir impago en responsables financieros. Cabe recalcar que la variable “Ingresos aproximados mensuales en soles del Responsable Financiero” tiene un p-valor 0.053 y es ligeramente mayor al nivel de significancia, lo cual indica que esta variable puede tener un impacto significativo en estudios posteriores o en muestras diferentes.

Estas variables predictoras adecuadamente manejadas, ayudarían a optimizar las decisiones que se toman en relación al riesgo crediticio en las instituciones educativas privadas, mejoraría el flujo de efectivo, favorecería a tomar decisiones crediticias más rápidas y permitiría un monitoreo más cercano de las cuentas por cobrar existentes priorizando la cobranza. Asimismo, reduciría el costo del análisis crediticio, costos de cobranzas y morosidad en las instituciones ya mencionadas. Finalmente, la elaboración de instrumentos, basados en variables predictoras confiables, ayudarán a discriminar entre malos y buenos clientes que sean capaces de asumir sus obligaciones.

En una investigación futura, aplicar otras técnicas de minería de datos, como redes neuronales, lógica difusa, análisis discriminante o técnica híbrida, con el fin de lograr un rendimiento de modelo y una capacidad de interpretación aún mejores.

Referencias

- Abdou, H. A., & Pointon, J. (2011). Credit Scoring, Statistical Techniques and Evaluation Criteria: a Review of the Literature. *Intelligent Systems in Accounting, Finance and Management*, 18(2–3), 59–88. <https://doi.org/10.1002/isaf.325>
- Akkoç, S. (2012). An empirical comparison of conventional techniques, neural networks and the three stage hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) model for credit scoring analysis: The case of Turkish credit card data. *European Journal of Operational Research*, 222(1), 168–178. <https://doi.org/10.1016/j.ejor.2012.04.009>
- Aldana Joya, Y. A., Garavito León, M. del P., & Ramos Botia, I. J. (2019). *Diseño de un modelo para la evaluación del riesgo financiero en las microempresas del sector textil en la ciudad de Bogotá D.C.* Universidad de la Salle Facultad. Retrieved from https://ciencia.lasalle.edu.co/cgi/viewcontent.cgi?article=1559&context=finanzas_comercio
- Altbach, P. G., & De Wit, H. (2020). Postpandemic Outlook for Higher Education is

- Bleakest for the Poorest. *International Higher Education*, (101), 3–5. Retrieved from <https://www.internationalhighereducation.net/api-v1/article/!/action/getPdfOfArticle/articleID/2904/productID/29/filename/article-id-2904.pdf>
- Atencio, J. J. (2019). *Evaluación de clientes mediante el Credit Scoring para créditos condumo de las cajas municipales de la ciudad de Arequipa*. Universidad Nacional de San Agustín de Arequipa. Retrieved from <http://repositorio.unsa.edu.pe/bitstream/handle/UNSA/11067/FIjuatj.pdf?sequence=1&isAllowed=y>
- Benites, R. (2021). *La Educación Superior Universitaria en el Perú post-pandemia*. Lima, Perú. Retrieved from <https://escuela.pucp.edu.pe/gobierno/wp-content/uploads/2021/05/La-Educacion-Superior-Universitaria-en-el-Peru-post-pandemia-VF.pdf>
- Berkson, J. (1944). Application of the Logistic Function to Bio-Assay. *Journal of the American Statistical Association*, 39(227), 357–365. <https://doi.org/10.1080/01621459.1944.10500699>
- Bernal, C. A. (2006). *Metodología de la Investigación* (2da ed.). México: Pearson Education Limited. Retrieved from <http://www.cars59.com/wp-content/uploads/2015/08/Investigacion-de-Mercados-BENASSINI-2ED.pdf>
- Blanco, A., Pino-Mejías, R., Lara, J., & Rayo, S. (2013). Credit scoring models for the microfinance industry using neural networks: Evidence from Peru. *Expert Systems with Applications*, 40(1), 356–364. <https://doi.org/10.1016/j.eswa.2012.07.051>
- Cox, D. R. (1958). The Regression Analysis of Binary Sequences. *Journal of the Royal Statistical Society. Series B (Methodological)*, 20(2), 215–242. Retrieved from <http://www.jstor.org/stable/2983890>
- Cubiles-De-La-Vega, M.-D., Blanco-Oliver, A., Pino-Mejías, R., & Lara-Rubio, J. (2013). Improving the management of microfinance institutions by using credit scoring models based on Statistical Learning techniques. *Expert Systems with Applications*, 40(17), 6910–6917. <https://doi.org/10.1016/j.eswa.2013.06.031>
- Delgado Castillo, H. (2009). *Análisis de Estados Financieros: Finanzas para “no financieros.”* (Trillas, Ed.) (1ra ed.). México.
- Elizondo, A., & Altman, E. (2004). *Medición integral del riesgo de crédito* (1ra ed.). México: Editorial Limusa. Retrieved from https://books.google.com.pe/books?id=UsK-1Ajo44UC&source=gbs_navlinks_s
- Finlay, S. (2009). Are we modelling the right thing? The impact of incorrect problem specification in credit scoring. *Expert Systems with Applications*, 36(5), 9065–9071. <https://doi.org/10.1016/j.eswa.2008.12.016>
- Gordon, R. A. (2015). *Regression analysis for the social sciences: Second edition. Regression Analysis for the Social Sciences: Second Edition* (2ed.). New Yor: Taylor & Francis.
- Gunasekaran, A., Papadopoulos, T., Dubey, R., Fosso, S., Childe, S. J., Hazen, B., & Akter, S. (2017). Big data and predictive analytics for supply chain and organizational performance. *Journal of Business Research*, (70), 308–317. <https://doi.org/http://dx.doi.org/10.1016/j.jbusres.2016.08.004>
- Gurný, P., & Gurný, M. (2013). Comparison of Credit Scoring Models on Probability of Default Estimation for Us Banks. *Prague Economic Papers*, 22(2), 163–181. <https://doi.org/10.18267/j.pep.446>
- Horngren, C. T., Harrison Jr., W. T., & Smith Baber, L. (2003). *Contabilidad*. (P. E. de M. S. de CV, Ed.) (5ta ed.). México.
- Huang, S.-C., & Day, M.-Y. (2013). A comparative study of data mining techniques for credit scoring in banking. In *2013 IEEE 14th International Conference on Information Reuse & Integration (IRI)* (pp. 684–691). IEEE. <https://doi.org/10.1109/IRI.2013.6642534>

- Imtiaz, S., & J., A. (2017). A Better Comparison Summary of Credit Scoring Classification. *International Journal of Advanced Computer Science and Applications*, 8(7), 1–4. <https://doi.org/10.14569/IJACSA.2017.080701>
- Jagic, T., & Jagic, V. (2011). A Comparison of Growing Cell Structures Neural Networks and Linear Scoring Models in the Retail Credit Environment. *Eastern European Economics*, 49(6), 74–96. <https://doi.org/10.2753/EEE0012-8775490605>
- Jonker, J., & Pennink, B. (2010). *The Essence of Research Methodology: A Concise Guide for Masters and Phd Science* (1st ed.). London: Springer.
- Kambal, E., Osman, I., Taha, M., Mohammed, N., & Mohammed, S. (2013). Credit scoring using data mining techniques with particular reference to Sudanese banks. In *2013 INTERNATIONAL CONFERENCE ON COMPUTING, ELECTRICAL AND ELECTRONIC ENGINEERING (ICCEEE)* (pp. 378–383). IEEE. <https://doi.org/10.1109/ICCEEE.2013.6633966>
- Kocenda, E., & Vojtek, M. (2009). Default Predictors and Credit Scoring Models for Retail Banking. *CESifo Working Paper Series N° 2862*, (2862). Retrieved from <https://ssrn.com/abstract=1519792>
- Liberati, C., Camillo, F., & Saporta, G. (2015). Advances in credit scoring: combining performance and interpretation in kernel discriminant analysis. *Advances in Data Analysis and Classification*, 11(1), 121–138. <https://doi.org/10.1007/s11634-015-0213-y>
- Marginson, S. (2020). Global HE as we know it has forever changed. Retrieved from <https://www.timeshighereducation.com/blog/global-he-we-know-it-has-forever-changed>
- Marqués, A. I., García, V., & Sánchez, J. S. (2013). A literature review on the application of evolutionary computing to credit scoring. *Journal of the Operational Research Society*, 64(9), 1384–1399. <https://doi.org/10.1057/jors.2012.145>
- Minga Mendieta, B. T. (2019). *Gestión de riesgo de crédito a través de un modelo de Credit Scoring en las Cooperativas de Ahorro y Crédito del Segmento 2*. Universidad del Azuay. Retrieved from <http://dspace.uazuay.edu.ec/bitstream/datos/9000/1/14645.pdf>
- Morales, J., & Morales, A. (2015). *Crédito y cobranza* (1ra ed.). México: Grupo Editorial Patria S.A. de C.V. Retrieved from <https://elibro.net/es/lc/utnorte/titulos/39380>
- Nalić, J., & Martinovic, G. (2020). Building a Credit Scoring Model Based on Data Mining Approaches. *International Journal of Software Engineering and Knowledge Engineering*, 30(2), 147–169. <https://doi.org/10.1142/S0218194020500072>
- Nalić, J., Martinović, G., & Žagar, D. (2020). New hybrid data mining model for credit scoring based on feature selection algorithm and ensemble classifiers. *Advanced Engineering Informatics*, 45(March), 101130. <https://doi.org/10.1016/j.aei.2020.101130>
- Ortiz Anaya, H. (2011). *Análisis Financiero Aplicado*. (Universidad Externado de Colombia, Ed.) (!4 ava edi). Colombia.
- Perez Maldonado, A. E. (2017). *Análisis del riesgo de la cartera de microcrédito mediante la construcción de un modelo scoring para una cooperativa de ahorro y crédito del segmento 2 de Cuenca*. Universidad del Azuay. Retrieved from <http://201.159.222.99/bitstream/datos/6427/1/12566.pdf%0Ahttp://dspace.uazuay.edu.ec/handle/datos/7507>
- Ping, Y., & Yongheng, L. (2011). Neighborhood rough set and SVM based hybrid credit scoring classifier. *Expert Systems with Applications*, 38(9), 11300–11304. <https://doi.org/10.1016/j.eswa.2011.02.179>
- Puertas, R., & Marti, M. L. (2012). Análisis Del Credit Scoring. *Revista Administración de Empresas*, 53(3), 303–315.
- Quiroz Calderón, M. B. (2020). Credit Scoring Una Herramienta Para Minimizar El

- Riesgo De Crédito De Las Instituciones Microfinancieras-Perú. *Quipukamayoc*, 28(56), 69–75. <https://doi.org/10.15381/quipu.v28i56.17697>
- Quispe Gala, M. Do. (2013). *Administración del riesgo crediticio y la morosidad de la Cooperativa de Ahorro y Crédito Huancavelica Ltda. 582, periodo 2013*. Universidad Nacional de Huancavelica. Retrieved from <http://repositorio.unh.edu.pe/bitstream/handle/UNH/299/TP - UNH. CONT. 0016.pdf?sequence=1&isAllowed=y>
- Rodríguez Bauza, R. (n.d.). *Sistema de Evaluación del Riesgo en el Otorgamiento de Créditos Agropecuarios dentro del Sistema bancario Venezolano*. Universidad Católica Andres Bello. Retrieved from <http://biblioteca2.ucab.edu.ve/anexos/biblioteca/marc/texto/AAR7651.pdf>
- Ross, S. A., Westerfield, R. W., & Jaffe, J. F. (2010). *Finanzas corporativas* (9th editio). México.
- Ruiz, S., Gomes, P., Rodrigues, L., & Gama, J. (2019). Credit scoring for microfinance using behavioral data in emerging markets. *Intelligent Data Analysis*, 23(6), 1355–1378. <https://doi.org/10.3233/IDA-184239>
- Srinivasan, V., & Kim, Y. H. (1987). Credit Granting: A Comparative Analysis of Classification Procedures. *Journal of Finance*, 42(3), 665–681. Retrieved from <https://econpapers.repec.org/RePEc:bla:jfinan:v:42:y:1987:i:3:p:665-81>
- SUNEDU. (2020). *II Informe bienal sobre la realidad unversitaria en el Perú*. Lima, Perú. Retrieved from <https://cdn.www.gob.pe/uploads/document/file/1230044/Informe Bienal.pdf>
- Teles, G., Rodrigues, J. J. P. C., Kozlov, S. A., Rabêlo, R. A. L., & Albuquerque, V. H. C. (2020). Decision support system on credit operation using linear and logistic regression. *Expert Systems*, (April), 1–19. <https://doi.org/10.1111/exsy.12578>
- Tercera, L. (2020). Morosidad: deudas en las universidades alcanzan hasta al 29% de sus estudiantes. Retrieved from <https://www.latercera.com/nacional/noticia/morosidad-deudas-en-las-universidades-alcanzan-hasta-al-29-de-sus-estudiantes/5U7IZMWTXZERXIXIECJVT4SXHM/>
- Wang, G., Ma, J., Huang, L., & Xu, K. (2012). Two credit scoring models based on dual strategy ensemble trees. *Knowledge-Based Systems*, 26, 61–68. <https://doi.org/10.1016/j.knosys.2011.06.020>
- Welc, J., & Esquerdo, P. J. R. (2018). *Applied Regression Analysis for Business*. *Applied Regression Analysis for Business* (1th ed.). Switzerland: Springer International Publishing AG. <https://doi.org/10.1007/978-3-319-71156-0>
- Yao, J.-R., & Chen, J.-R. (2019). A New Hybrid Support Vector Machine Ensemble Classification Model for Credit Scoring. *Journal of Information Technology Research*, 12(1), 77–88. <https://doi.org/10.4018/JITR.2019010106>
- 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*, 08(04), 677–696. <https://doi.org/10.1142/S0219622009003582>

