

LA EVALUACIÓN DEL RIESGO DE CRÉDITO EN LAS INSTITUCIONES DE MICROFINANZAS: ESTADO DEL ARTE

María Nela Seijas-Giménez¹, Milagros Vivel-Búa², Rubén Lado-Sestayo³, Sara Fernández-López⁴

Resumen

Fecha de Recepción: 06 de Septiembre del 2017 - Fecha de Aprobación: 26 de Octubre del 2017

Este trabajo realiza una revisión de las investigaciones empíricas focalizadas en la evaluación del riesgo de crédito en las instituciones de microfinanzas (IMFs), identificando de forma particular aquellos relativos a América Latina. Desde el trabajo pionero de Viganò (1993), la literatura se ha extendido en las últimas dos décadas, abarcando un número relevante de países y con el objetivo principal de evaluar el riesgo de crédito. Así, en primer lugar, este trabajo se centra en identificar el uso de las técnicas de credit scoring en la literatura para evaluar el riesgo de que los microcréditos incurran en algún tipo de atraso costoso. De este modo, la IMF podría establecer medidas orientadas a mitigarlo y ser más eficiente. El análisis teórico de estas investigaciones muestra la utilización mayoritaria de técnicas paramétricas. Sin embargo, las investigaciones más recientes encuentran que las técnicas no paramétricas tienen un mayor poder predictivo del incumplimiento por parte de los clientes de microcréditos. En segundo lugar, este trabajo identifica los determinantes del riesgo de impago analizados en trabajos previos. La evidencia muestra la importancia de la información cualitativa sobre el prestatario, el negocio y el préstamo, y también el uso de datos no estructurados.

Palabras clave: Microcréditos, Credit Scoring, Instituciones de Microfinanzas, Morosidad.

JEL: G21, G29, G32

Autor por correspondencia

Email

¹ María Nela Seijas-Giménez, Universidad de La República, Montevideo, Uruguay, mseijas@ccea.com.uy.

² Milagros Vivel-Búa, Universidad de Santiago de Compostela, La Coruña, España, mila.vivel@usc.es.

³ Rubén Lado-Sestayo, Universidad de La Coruña, La Coruña, España, ruben.lado.sestayo@udc.es.

⁴ Sara Fernández-López, Universidad de Santiago de Compostela, La Coruña, España, sara.fernandez.lopez@usc.es.

THE EVALUATION OF CREDIT RISK IN MICROFINANCE INSTITUTIONS: A STATE OF ART

Abstract

This paper reviews the empirical research focused on credit risk assessment in microfinance institutions (MFIs), particularly identifying those related to Latin America. Since the pioneering work of Vigano (1993), literature has spread over the last two decades, covering a significant number of countries and with the main objective of assessing credit risk. First, this work focuses on identifying the use of credit scoring techniques in the literature to assess the risk of microcredit incurring some type of costly delay. In this way, the MFI could establish measures to mitigate and be more efficient. The theoretical analysis of these investigations shows the majority use of parametric techniques. However, more recent research finds that non-parametric techniques have a greater predictive power of non-compliance by microcredit clients. Second, this paper identifies the determinants of default risk analyzed in previous works. The evidence shows the importance of qualitative information about the borrower, the business and the loan, as well as the use of unstructured data.

Keywords: Microcredits, Credit Scoring, Microfinance Institutions, Default.

JEL: G21, G29, G32

1. Introducción

Las instituciones de microfinanzas (IMFs) otorgan microcréditos a los sectores más pobres de la población. Para ello, utilizan una metodología de concesión de créditos en la que el analista de crédito desempeña un rol fundamental, utilizando información subjetiva derivada de una vinculación más directa con el emprendimiento a financiar. Esta estrategia para la evaluación del crédito condiciona la eficiencia de las IMFs. De hecho, una de sus consecuencias más visibles es que el tipo de interés de los microcréditos suele superar de forma significativa el tipo de interés medio aplicado por el sector bancario tradicional.

La literatura ha demostrado que la aplicación de técnicas de *credit scoring* en la práctica bancaria para conceder financiamiento a familias y empresas permite mitigar el riesgo de crédito. En concreto, se mejora el porcentaje correcto de clasificación de clientes pagadores como no pagadores, prediciendo la probabilidad de impago asociada a una operación crediticia (Schreiner, 2000). Estas técnicas implican el uso intensivo de distintos modelos estadísticos que, en base a un conjunto de información cualitativa y cuantitativa, permiten estimar el riesgo de impago de un prestatario de créditos. En particular, el *credit scoring*, también conocido como calificación del riesgo de impago o morosidad, puede concebirse como un sistema que, mediante predicciones, califica un crédito y mide el riesgo inherente al mismo. La medición del riesgo de crédito implica la utilización de modelos estadísticos apropiados que permiten obtener un valor esperado y su correspondiente variabilidad o volatilidad. Estas técnicas estadísticas permiten conocer el comportamiento financiero de los prestatarios y su morosidad, la relación entre el riesgo y la rentabilidad, y la determinación del coste de la operación, tendiente a lograr su reducción futura en el marco del proceso de concesión de un crédito.

A partir de los trabajos pioneros de Vigano (1993) y Schreiner (1999), las técnicas de *credit scoring* se han analizado en el contexto de los microcréditos. Su diseño y aplicación es diferente respecto al sector bancario tradicional debido a las limitaciones existentes de los historiales de crédito. Por tanto, es relevante analizar la aplicabilidad de la utilización de las técnicas de *credit scoring* como herramienta de mitigación del riesgo de crédito en las IMFs. Ello contribuye a abordar el problema de sostenibilidad financiera que afecta a este tipo de instituciones proveedoras de fondos a los sectores más vulnerables de la sociedad. Debido a la creciente competencia, el sobreendeudamiento y las crisis económicas, las IMFs deben perseguir sus objetivos sociales y financieros en un entorno cada vez más restringido. En este sentido, desarrollar potentes herramientas de gestión de riesgos se vuelve más que nunca crucial para asegurar su sostenibilidad.

Según Bumacov et al. (2014), la metodología de *credit scoring* contribuye a un crecimiento más rápido en el alcance y eficiencia de las IMFs, dado que se ofrece una mejor inclusión financiera a más beneficiarios de bajos ingresos. El uso del *credit scoring* tiene un gran potencial para disminuir las ineficiencias relacionadas con los procedimientos de evaluación de microcréditos, que son gravosos debido a la alta asimetría de la información.

En el marco del crédito al consumo, Hand & Henley (1997) realizan una revisión de literatura en la que presentan los diferentes trabajos que abordan la aplicación de las técnicas de *credit scoring*, a efectos de clasificar a los clientes entre “buenos” y “malos”. Sin embargo, de acuerdo a nuestro conocimiento, hasta el momento no se cuenta con una revisión de literatura en relación a aquellos artículos que analizan la aplicación de estas metodologías en el negocio de los microcréditos. Consecuentemente, el objetivo principal de este artículo es revisar los trabajos académicos que analizan la aplicación de técnicas de *credit scoring* en el contexto de los microcréditos. En particular, se revisan tres aspectos característicos de este tipo de trabajos que son: i) la delimitación conceptual de la morosidad, que constituye el riesgo a predecir en

los trabajos; ii) la metodología utilizada; iii) las variables explicativas empleadas. Todo ello se realiza tanto bajo una perspectiva internacional como prestando una especial atención a la literatura previa focalizada en América Latina.

El trabajo se estructura en cuatro apartados. Tras esta introducción, el segundo apartado se focaliza en un análisis de las investigaciones precedentes enfocado, en primer lugar, en la metodología aplicada y definición de impago utilizada para evaluar el riesgo de insolvencia. En segundo lugar, esta sección identifica los principales determinantes de morosidad evaluados en el estudio de los microcréditos concedidos por IMFs. El tercer apartado realiza una exposición más detallada de las investigaciones relacionadas con IMFs de América Latina. El trabajo finaliza con un cuarto apartado de conclusiones.

2. Credit Scoring y Microcréditos: marco teórico en las instituciones de microfinanzas

La literatura académica sobre la aplicación de técnicas de *credit scoring* en la concesión de préstamos por parte de las instituciones bancarias y de microfinanzas se organiza a partir del trabajo pionero de Altman (1968). Este autor diseñó un modelo Z-score para predecir la quiebra de empresas en base a un modelo discriminante múltiple. En una primera etapa de su investigación se utilizan datos históricos combinados con una técnica estadística a efectos de identificar aquellas características del prestatario, del préstamo y del contexto económico-financiero que resultaran más significativas para distinguir entre préstamos regulares y aquellos que experimentaron dificultades financieras (incumplimiento). En una segunda etapa, el modelo se utiliza para calcular un nuevo “*score*” (o puntaje) para cada nuevo solicitante de préstamo. Este *score* debe ser comparado con un umbral, a efectos de determinar si la solicitud es aceptada, rechazada o bien necesita de una evaluación más profunda. Una medida de *score* alta se asocia con un mejor comportamiento de pago (devolución de la deuda) por parte del prestatario y, en consecuencia, una menor probabilidad de experimentar dificultades financieras.

Chakravarty & Jha (2012) analizan la viabilidad del *credit scoring* para IMFs en los países en desarrollo, sugiriendo que este enfoque puede no tener un impacto tan poderoso como en los países ricos y desarrollados. No obstante, sí confirman que tiene el potencial de complementar las tecnologías de microfinanzas existentes en los países en desarrollo. Por otro lado, Schreiner (2000) establece que, en el ámbito de las microfinanzas, el *credit scoring* no sustituye los juicios de los oficiales de créditos basados en información cualitativa. Sin embargo, Schreiner (2000) establece que, en el ámbito de las microfinanzas, el *credit scoring* tiene poder para predecir el riesgo de crédito y, en consecuencia, para reducir costes, aún después de que el oficial de crédito emita su juicio. En la misma línea, Van Gool et al. (2012) sostienen que el *credit scoring* no es capaz de reemplazar completamente el proceso tradicional de crédito para las microfinanzas. No obstante, estos autores también exponen que puede introducirse como una herramienta de refinamiento en el proceso de crédito, para combinar las mejores prácticas estadísticas y humanas.

A continuación, se enumeran y analizan los trabajos académicos previos que se refieren al estudio de las técnicas de *credit scoring* en la actividad de microcréditos a pequeñas y medianas empresas por parte de IMFS. En particular, se abordará la descripción de los trabajos académicos revisando el riesgo a predecir bajo la técnica de *credit scoring*, la metodología utilizada y las variables explicativas empleadas como determinantes.

2.1. Metodología y riesgo a predecir en los microcréditos

La Tabla 1 sintetiza la literatura previa centrándose en dos aspectos fundamentales: la metodología aplicada, considerando las técnicas de *credit scoring*, y la variable dependiente, o variable a predecir, esto es, el riesgo de impago en el ámbito de las microfinanzas.

Hay una gran variedad de técnicas estadísticas que se encuadran en la metodología de *credit scoring*. A efectos de clarificar las técnicas a utilizar, habitualmente se distingue entre modelos de *credit scoring* paramétricos y no paramétricos. Las técnicas paramétricas son aquellas que presentan una función de distribución o clasificación conocidas, al igual que estiman parámetros para explicar un determinado suceso de tal modo que estos se ajusten a las observaciones de una muestra. Dentro de este grupo, es posible distinguir técnicas paramétricas lineales (análisis discriminante y modelos de probabilidad lineal) así como no lineales (modelos *logit* y *probit*). Por otro lado, las técnicas no paramétricas no se encuentran ligadas a ninguna forma funcional ni distribución concreta de probabilidad. Estas técnicas no tienen por objetivo la búsqueda de parámetros de una función conocida, sino que tratan de obtener formas funcionales que aproximen a la función objetivo. El grupo de las técnicas no paramétricas comprende la programación lineal, las redes neuronales y los árboles de decisiones.

Durante la primera década de los trabajos académicos sobre *credit scoring* en el ámbito de los microcréditos, las técnicas estadísticas utilizadas estuvieron limitadas al análisis discriminante (Vigano, 1993), esquemas *tobit* (Sharma & Zeller, 1997; Zeller, 1998), análisis *probit* (Reinke, 1998; Vogelgesang, 2003) y regresiones logísticas (Schreiner, 2003, 2004; Dellien & Schreiner, 2005). La aplicación del análisis discriminante a los modelos de *credit scoring* adolecen de varios problemas estadísticos, como la distribución subyacente de las variables, el uso de funciones de discriminación lineal y el rol de las variables individuales, entre otros (Thomas et al., 2004). A partir del trabajo de Bensic et al. (2005), los trabajos de *credit scoring* en microfinanzas también incluyen técnicas no paramétricas, como redes neuronales y árboles de decisión CART. Las redes neuronales constituyen metodologías de inteligencia artificial, que consideran redes de nodos interconectados entre sí, donde los nodos de entrada son características de la operación de crédito y el nodo de salida es la clasificación del cliente (pagador o moroso). En relación a su performance, logra una buena predicción en muestras pequeñas, dispone de una gran flexibilidad y no requiere la especificación previa del modelo. Como desventajas, se puede indicar que requiere de la definición de muchos parámetros y no estima las probabilidades de impago en forma directa, lo que genera dificultad en la comprensión de la aplicación. Por otro lado, el Árbol de Regresión y Clasificación (CART) es una técnica de clasificación binaria que permite separar las observaciones de una muestra, asignándolas a grupos previamente establecidos. Tiene una gran flexibilidad y no requiere supuestos estadísticos referentes a distribuciones o formas funcionales. Al no estimar parámetros ni probabilidades de impago, a menudo se la considera como una técnica de difícil comprensión. Kim & Sohn (2010) introducen la aplicación de *Support Vector Machines*, también empleados por Cubiles de la Vega et al. (2013), Blanco et al. (2014) y De Cnudde et al. (2015). En esta técnica, las variables de entrada se transforman de forma no lineal a un espacio de características de alta dimensión, en el que posteriormente se construye un clasificador lineal. Las características más relevantes de la técnica radican en la utilización de un término de regularización para mejorar la precisión de la muestra y la definición implícita de la asignación no lineal en términos de una función de kernel.

Más recientemente, varios trabajos aplicaron el enfoque de *Multilayer Perceptron* para evaluar el riesgo de crédito de IMFs, entre otros, Blanco et al. (2013), Cubiles de la Vega et al. (2013), Kammoun & Triki (2016) y Ayouche et al. (2017). El enfoque de *Multilayer Perceptron* (o red neuronal multicapa) consta de varias capas de unidades computacionales interconectadas

entre sí, donde cada neurona en una capa se encuentra directamente conectada a las neuronas de la capa anterior. Esta característica le permite resolver problemas que no son linealmente separables, debido a lo cual es un tipo de red neuronal muy utilizada para la predicción de la quiebra y la puntuación crediticia en general.

En Bensic et al. (2005), se utilizan datos compilados aleatoriamente de una asociación de ahorros y préstamos de Croacia especializada en financiar pequeñas y medianas empresas, fundamentalmente *start-ups*, para clasificar adecuadamente entre créditos normales y con incumplimiento. Para ello, se compara la exactitud de los mejores modelos de regresión logística, redes neuronales y árboles de decisión CART. Los resultados muestran que la tasa de aciertos más alta y el error del tipo I más bajo se obtienen por el modelo de redes neuronales. Por otro lado, Kim y Sohn (2010) desarrollan un modelo para predecir el porcentaje de incumplimiento de las pequeñas y medianas empresas (PYME) con un alto potencial de crecimiento en tecnología en Corea, con el fin de gestionar eficazmente los fondos gubernamentales a destinar a las PYME seleccionadas. Se utiliza la herramienta de *Support Vector Machine* (SVM), en comparación con la regresión logística y las redes neuronales, comprobándose que la precisión del modelo SVM registra una mejor performance que el de las redes neuronales y la regresión logística.

Recientemente, un número significativo de trabajos consideran la aplicación conjunta de varias metodologías, a efectos de determinar aquélla con el mayor grado de precisión en la predicción del incumplimiento (Blanco et al., 2013; Cubiles de la Vega et al., 2013; Baklouti, 2014; Blanco et al., 2014; De Cnudde et al., 2015; Kammoun & Triki, 2016 y Ayouché et al., 2017), resultando en general que los modelos no paramétricos resultan los de mayor poder predictivo. La Tabla 1 sintetiza las metodologías aplicadas en la literatura previa.

Schreiner (2000) investiga los posibles usos de los modelos de *credit scoring* aplicados a las IMF, estableciendo seis objetivos principales:

1. Predecir la probabilidad de que un préstamo vigente tenga un evento de atrasos de un cierto número de días (“*pre-disbursement scoring*”).
2. Pronosticar la probabilidad de que un préstamo que registre un atraso de un cierto número de días pueda llegar a registrar una determinada cantidad mayor de días de demoras en el pago (“*collections scoring*”).
3. Predecir la probabilidad de que se registren abandonos, esto es, la probabilidad de que un prestatario con un préstamo vigente no solicite un nuevo préstamo una vez que devuelva la deuda actual (“*drop-out scoring*”).
4. Pronosticar el plazo esperado del siguiente préstamo de un prestatario vigente.
5. Predecir el tamaño esperado del siguiente préstamo que pudiera ser solicitado por el cliente.
6. Con la información de los cinco modelos anteriores, estimar el valor esperado de la relación prestamista-cliente, en base a la información sobre la ganancia esperada de un préstamo con un tamaño y un plazo de vencimiento dados y sobre los costes esperados de abandonos, impagos y controles de prestatarios con atrasos.

La utilización más difundida de estas técnicas pretende clasificar entre buenos y malos clientes de acuerdo a una definición de riesgo que sea costoso para la IMF y sobre el cual ésta tenga un cierto control (Chakravarty & Jha, 202; Schreiner, 2000). El número de días de atraso que configura un atraso costoso, es decir, que requiere de una gestión de cobranza

extraordinaria para motivar el pago, depende de cada IMF. Asimismo, a menudo, se utilizan los referidos modelos estadísticos para calcular la probabilidad de que el usuario de microcréditos sea pobre (“*poverty scoring*”), lo que permite medir el alcance de los programas de microcréditos (Bumacov, 2014).

Vigano (1993) es considerado el primer trabajo en el que se aplican metodologías de *credit scoring* a la industria de microfinanzas, en relación con la cartera de préstamos de micro y pequeñas empresas del sector rural. Este modelo se aplicó a la cartera de préstamos del *Caisse Nationale de Credit Agricole*, banco de desarrollo de Burkina Faso creado en 1979 para promover el desarrollo financiero de la zona rural. El trabajo se aplicó a una muestra de 100 préstamos, con 53 variables explicativas, obtenidas a partir de cuestionarios y entrevistas directas con oficiales de préstamos. En particular, se aplicó un análisis discriminante múltiple para clasificar los préstamos entre buenos y malos (préstamos que registraran algún tipo de atrasos), e identificar los determinantes del riesgo de crédito.

En otros casos, el riesgo a predecir consiste en que el cliente se atrase por un período de 15 o más días (Schreiner, 2004), que registre atrasos de por lo menos 30 días (Dellien & Schreiner, 2005), que se encuentre en incumplimiento de pagos (Reinke, 1998), o que registre algún tipo de atraso (Vigano, 1993). Por su parte, Vogelgesang (2003) analiza la probabilidad de que un préstamo registre atrasos (un día en promedio por lo menos) o que se encuentre en default (un promedio de 10 días de atrasos). Alternativamente, Schreiner (2003) utiliza un modelo logit para determinar la probabilidad de que un cliente no solicite un segundo préstamo luego de repagar el primero.

Atendiendo a la diversificación geográfica de las publicaciones revisadas, se constata que provienen principalmente de Latinoamérica (44%), con mercados de microfinanzas estables y maduros (especialmente, Bolivia y Perú), seguidos por África (33%) y la región Asia-Pacífico (23%). Al respecto, de acuerdo con Microfinance Gateway (2016), se prevé que esta última región experimente el porcentaje anual de crecimiento más relevante de su mercado de microfinanzas durante el año 2017.

Tabla 1: Credit scoring en microfinanzas: riesgo a predecir y metodología

Año	Autores	País	Variable dependiente	Metodología
1993	Vigano	Burkina Faso	Préstamo con atrasos	ADM
1997	Sharma & Zeller	Bangladesh	Proporción del monto total del préstamo con atrasos al vencimiento	Tobit
1998	Zeller Reinke	Madagascar Sudáfrica	Tasa de repago del préstamo al vencimiento Prestatario con atrasos	Tobit Probit
2003	Schreiner Vogelgesang	Bolivia Bolivia	Riesgo de salida de prestatarios Préstamo atrasado: un préstamo con un día de atraso en promedio Préstamo en default: un préstamo atrasado por lo menos 10 días en promedio	Logit Probit bivariado
2004	Schreiner	Bolivia	Préstamo con atraso de 15 días o más	Logit
2005	Dellien & Schreiner Bensic et al.	Colombia Croacia	Préstamo con al menos 30 días de atrasos o con 7 días de atraso promedio por cuota Préstamo con atrasos por lo menos una vez por 46 días o más	Logit Logit Redes neuronales Árboles de decisión CART
2006	Diallo	Mali	Préstamo que registró al menos una vez un retraso en el pago de 30 días o más	Logit ADM
2007	Beledo et al. Dinh & Kleimeier Luoto et al.	Uruguay Vietnam Guatemala	Préstamo con al menos 30 días de atrasos Microcréditos con más de 90 días de atrasos o con atrasos en tres pagos consecutivos Porcentaje de préstamos que registraron atrasos; porcentaje de préstamos que registraron algún tipo de atraso en un mes; número promedio de pagos atrasados por cada préstamo en un mes; número promedio de meses con atrasos para préstamos morosos emitidos en un mes	Logit Logit Regresión lineal de panel con efectos fijos
2009	Deininger & Liu	India	Porcentaje del monto adeudado de préstamos al vencimiento en relación con el total	Tobit
2010	Kim & Sohn Rayo et al.	Corea Perú	Default de PYME financiada Retraso en el pago de al menos 30 días	SVM Logit Redes Neuronales Logit
2011	Lara et al.	Perú	Retraso en el pago de al menos 30 días	Logit
2012	Van Gool et al. Kinda & Achonu	Bosnia-Herzegovina Senegal	Microcréditos con atrasos promedio por cuota de 2 o más días Préstamo con 15 días de atrasos	Logit Logit
2013	Blanco et al.	Perú	Retraso en el pago de al menos 15 días	Multilayer perceptrón approach ADM ADC

				Logit
	Cubiles-De-La-Vega et al.	Perú	Retraso en el pago de al menos 15 días	ADM ADC Logit Multilayer perceptron SVM Árboles de clasificación
2014	Blanco et al.	Perú	Retraso en el pago de al menos 15 días	Logit SVM
	Baklouti	Túnez	Préstamo que no ha sido repagado al vencimiento	Árboles de clasificación y regresión ADM Logit
2015	De Cnudde et al.	Filipinas	Tasa de repago del préstamo	Enfoque basado en redes SVM
2016	Serrano-Cinca et al.	Colombia	Solicitud de préstamo denegada	Evaluación multicriterio
	Kammoun & Triki	Túnez	Préstamo con un retraso en el pago de 30 días o más	Logit Multilayer perceptron Redes Neuronales
2017	Romer et al. Ayouché et al.	Magadascar Marruecos	Préstamo con atrasos de al menos 15 días Solicitud de préstamo denegada	Logit Multilayer perceptron Redes neuronales

Notas: ADM se refiere al análisis discriminante múltiple. SVM es support vector machines. ADC significa análisis discriminante cuadrático.

Fuente: Elaboración propia

2.2. Determinantes del riesgo de impago en microcréditos

La Tabla 2 ilustra los determinantes propuestos en la literatura previa focalizada en el uso del *credit scoring* por parte de IMFs. Así, en primer lugar, se advierte que los primeros trabajos referían fundamentalmente a los préstamos a grupos (Sharma & Zeller, 1997; Zeller, 1998; Reinke, 1998; entre otros), característica principalmente referida a las zonas rurales y semi rurales donde los microcréditos revistieron inicialmente un mayor arraigo (Armendáriz & Morduch, 2011). Posteriormente, la literatura se concentra exclusivamente en estudios de la morosidad en aquellos microcréditos concedidos para emprendimientos a nivel individual.

Centrándonos en el tipo de determinante del riesgo de insolvencia en microcréditos, Viganò (1993) advierte la importancia de considerar información cualitativa en los modelos de *credit scoring* aplicados por parte de IMFs. Esta información se incluye en la forma de “variables sintomáticas”, ya que representan síntomas de la performance financiera del prestatario, incluyéndose en el modelo como variables *dummy*.

El análisis de los modelos de *credit scoring* permite advertir la significativa utilización de variables socioeconómicas del prestatario, así como variables representativas de la operación de préstamo y de las características del emprendimiento financiado. En algunos casos se utilizan asimismo variables macroeconómicas, en atención a que los prestatarios resultan afectados por los ciclos económicos locales imperantes durante la vigencia de sus préstamos. Por tanto, la gran mayoría de los trabajos analizados consideran información estructurada en los modelos de *credit scoring*. Sin embargo, en los últimos tiempos se advierte la consideración de información no estructurada, conocida genéricamente como *Big Data*, proveniente fundamentalmente de redes sociales, que es incorporada a los modelos de *credit scoring* para aumentar la precisión en las predicciones de impago (*European Commission, 2015*). Al respecto, De Cnudde et al. (2015) complementan la información sociodemográfica y del microcrédito con información sobre intereses y redes sociales del cliente, en base a Facebook, para una base de datos de microcréditos de Filipinas. Estos autores verifican la buena performance predictiva de los modelos planteados. En este sentido, Schreiner (2003) recomienda a las IMF's utilizar rasgos del carácter personal del cliente que son representativos del comportamiento de pago, mientras que la información proveniente de redes sociales se considera representativa del carácter del prestatario.

En otra perspectiva, dos Santos et al. (2015) reflexionan sobre las instituciones que operan con microcrédito en Brasil, abordando el *Behavioural Scoring*, o sistema de puntuación basado en el análisis de comportamiento, que ayudan a las IMF en la concesión de crédito y en el monitoreo del riesgo de recuperación de las operaciones con los clientes. En particular, el citado modelo incluye varias variables específicas vinculadas al comportamiento del individuo, tales como: (i) hábitos de consumo; (ii) hábitos de ocio; (iii) viajes; (iv) tipos de productos financieros; (v) compatibilidad con renta y patrimonio del individuo; y (vi) análisis de las obligaciones asumidas por el individuo. Entre las desventajas del *Behavioural Scoring* podemos indicar que, en general, se necesitan un par de años de historia para construir el *scorecard* y en consecuencia, la población sobre la que se aplica el modelo puede ser muy diferente de aquella sobre la que el mismo se construyó. Asimismo, las características de la población y el entorno económico pueden haber cambiado. Por otro lado, se asume generalmente que la relación entre las características de desempeño y el posterior estado de morosidad de un cliente se mantiene incambiada respecto al momento cuando se recolectó la información en la que se construyó el *scorecard*, no importando los cambios económicos que se hubieran producido en ese período. Recientemente, Baklouti (2014) propone incorporar al set de información sociodemográfica del prestatario, del negocio y del préstamo, una serie de variables representativas de características psicológicas del prestatario relacionadas con su carácter emprendedor que resultan predictores de relevancia de su probabilidad de pago.

Tabla 2: Determinantes de morosidad en microcréditos concedidos por IMFs.

Año	Autores	Tipo	Características relacionadas con:						
			A)	B)	C)	D)	E)	F)	G)
1993	Vigano	Individual	X			X	X		
1997	Sharma & Zeller	Grupo	X	X			X		X
1998	Zeller	Grupo	X				X	X	X
	Reinke	Grupo	X			X	X		
2003	Vogelgesang	Individual	X			X	X		X
	Schreiner	Individual	X	X	X	X	X		
2004	Schreiner	Individual	X	X	X	X	X		
2005	Dellien & Schreiner	Individual	X		X	X	X		
	Bensic et al.	Individual	X			X	X		
2006	Diallo, B.	Individual	X		X		X		
2007	Dinh & Kleimeier	Individual	X				X		
	Beledo et al.	Individual	X		X	X	X		
	Luoto et al.	Individual		X	X				
2009	Deininger & Liu	Grupo	X				X		
2010	Rayo et al.	Individual	X	X		X	X		X
	Kim & Sohn	Individual	X		X				
2011	Lara et al.	Individual	X	X		X	X		X
2012	Van Gool et al.	Individual	X	X	X	X	X		
	Kinda & Achonu	Individual	X		X		X		
2013	Blanco et al.	Individual	X	X		X	X		X
	Cubiles-De-La-Vega et al.	Individual	X			X	X		X
2014	Blanco et al.	Individual	X			X	X		X
	Baklouti	Individual	X				X		
2015	De Cnudde et al.	Individual	X						
2016	Serrano-Cinca et al.	Individual	X	X		X	X		X
	Kammoun & Triki	Individual	X			X	X		
2017	Römer et al.	Individual	X	X		X	X		X
	Ayouche et al.	Individual	X			X			

Notas: Características relacionadas con: A) Solicitante; B) IMF; C) Oficial de crédito; D) Negocio; E) Préstamo; F) Programa de microcréditos; G) Ambiente macroeconómico. “---”significa que la información no está disponible.

Fuente: Elaboración propia

3. Microcréditos e instituciones de microfinanzas: evidencia en América Latina

Este epígrafe se focaliza en ofrecer una descripción más detallada de los estudios sobre microcréditos en IMFs de América Latina. Así, en primer lugar, se citan los trabajos de Schreiner relativos a Bolivia. Schreiner (1999, 2003), con una muestra de 39,956 microcréditos, desarrolló un modelo en el que empleó la regresión logística binaria para modelar el riesgo de que los prestatarios no renueven sus préstamos en una IMF en Bolivia que realiza préstamos a pequeños emprendimientos, destinados a la inversión en actividades comerciales o industriales. El modelo utiliza aquellos préstamos pagados entre agosto de 1988 y diciembre de 1996, mientras que, para validar la predicción, se consideran aquellos préstamos desembolsados entre enero y septiembre de 1997. En el trabajo, se incluyeron nueve variables independientes, que se resumen en: 1) experiencia como prestatario; 2) historial de morosidad; 3) sexo del prestatario; 4) sector de actividad; 5) cantidad desembolsada; 6) tipo de garantía; 7) sucursales; 8) oficial de crédito; y, 9) la fecha del desembolso. Se concluye que el riesgo de salida es más grande para los nuevos prestatarios, las mujeres, los empresarios manufactureros y aquellos con mayor número de pagos atrasados. Este riesgo también depende del monto desembolsado, el oficial de préstamos y la sucursal, así como el tiempo transcurrido desde el primer préstamo.

Utilizando la misma base de datos que en el trabajo citado anteriormente, Schreiner (2004) utiliza metodologías de *credit scoring* para predecir la probabilidad de que esta IMF boliviana experimente atrasos en sus préstamos de 15 días o más. El modelo *logit* empleado permitió clasificar los 10.555 préstamos amortizados en los primeros nueve meses de 1997, a partir de la información correspondiente al periodo 1988-1996, alcanzando una tasa de aciertos del 91,4%.

También referido a Bolivia, Vogelgesang (2003) analiza los determinantes de amortización de los préstamos a microempresarios de una IMF en este país, en base a información sobre 76.000 clientes y 28.000 solicitudes rechazadas de préstamos entre mayo de 1992 y junio de 2000. El análisis empírico se focaliza en la predicción de préstamos con atrasos y en default, en base a la aplicación de un modelo *probit*. Las variables que resultaron significativas en el modelo se refieren a características personales, información sobre los negocios de los clientes, condiciones de los préstamos e información sobre las condiciones de mercado. Los resultados mostraron que los préstamos con atrasos o en situación de incumplimiento son más probables de verificarse en emprendimientos con un alto ratio de deudas sobre activos totales. Por otro lado, una alta tasa de dependencia en préstamos de otras instituciones debería conducir a un mejor comportamiento de pago en un buen contexto económico mientras que éste se empeoraría en un contexto adverso. Asimismo, se obtuvo evidencia de que la existencia de una alta competencia y una gran oferta de microcréditos conducen a una alta probabilidad de préstamos con atrasos, empeorando el comportamiento de pago de la mayoría de los clientes emprendedores.

Dellien (2003) y Dellien y Schreiner (2005) argumentan sobre el proceso de introducir técnicas de *credit scoring* en una IMF a partir de la experiencia de un proyecto financiado por el Banco Interamericano de Desarrollo con afiliados de “*Women’s World Banking*” en Colombia y República Dominicana. En el caso de Colombia, se construyó una tarjeta de resultados (*scorecard*) con préstamos desembolsados hasta marzo de 2004, y luego éste se aplicó retroactivamente para desembolsos ocurridos entre abril de 2004 y julio de 2005. Se concluye que la aplicación del *credit scoring* habría reducido el número de desembolsos de la IMF en un 9% y el número de préstamos “malos” en un 20%.

Serrano et al. (2016) aplican las herramientas de *credit scoring* a efectos de realizar un análisis social y ambiental en una IMF colombiana. Estos autores proponen que las evaluaciones de solvencia incluyan la estimación del impacto social y ambiental del microcrédito, calculando el Valor Presente Neto Social. Al multiplicar la valoración obtenida por el peso dado por la IMF, se obtiene una puntuación, que categoriza el impacto social y ambiental de la IMF en cuatro categorías: impacto social y ambiental negativo (D); bajo impacto social y ambiental positivo (C); impacto medioambiental medio positivo (B); y alto impacto social y ambiental positivo (A). El trabajo realizado propone que la evaluación social y ambiental de cada microcrédito financiado se constituya en una variable independiente dentro del modelo de *credit scoring* de predicción de incumplimientos, no obstante, no se refiere a la vinculación del impago con esta evaluación. Este enfoque contribuye a crear una cultura de evaluación social y ambiental dentro de la institución, especialmente entre oficiales de crédito, traduciendo la misión social de la IMF en términos cuantitativos.

A partir del estudio de la cartera de microcréditos de dos IMFs en Perú, una serie de trabajos académicos analizan los efectos de la aplicación de las metodologías de *credit scoring*. En primer lugar, Rayo Cantón et al. (2010) utilizan la regresión logística binaria, sobre una base de datos correspondiente a 5.451 préstamos a microempresarios para el periodo 2003-2008, a efectos de determinar la probabilidad de impago de pequeños emprendimientos. Los resultados obtenidos indican un porcentaje global de aciertos del 77,7%, distinguiéndose entre los créditos

“buenos” (89,19% de aciertos) y los créditos “malos” (67%). A continuación, Lara et al. (2011) plantean un modelo de *credit scoring* para la cartera de microcréditos en la que, aplicando la regresión logística binaria, se diseñó un modelo de calificación estadística que resulta capaz de predecir correctamente un 78,3% de los créditos de la cartera de la entidad, corroborado por un porcentaje similar en el proceso de validación del modelo. A este respecto, las medidas de valoración del modelo globalmente indican un ajuste aceptable en regresión logística.

Blanco et al. (2013) desarrollan un modelo de *credit scoring* para la industria de microfinanzas peruana utilizando la técnica *Multilayer Perceptron*, y comparando la performance de este modelo con las tres técnicas paramétricas más utilizadas: el análisis discriminante lineal, el análisis discriminante cuadrático y la regresión logística. Los resultados obtenidos confirman que los modelos de *Multilayer Perceptron* tienen un mejor comportamiento y presentan costos por errores de clasificación más pequeños que los enfoques tradicionales de *credit scoring*. En una investigación complementaria, Blanco et al. (2014) utilizan una técnica no paramétrica de *credit scoring* denominado *Support Vector Machine* (SVM) para predecir la probabilidad de que el microempresario enfrente problemas financieros. A dichos efectos, se utilizan variables de tres tipos:

- a. ratios financieros correspondientes al negocio del microempresario;
- b. información no financiera relacionada con las características personales del microempresario así como las características del préstamo;
- c. variables relacionadas con el entorno macroeconómico en el que fue implementado el negocio.

Los resultados obtenidos confirman que el método no paramétrico SVM tiene una mejor performance que el modelo de regresión logística tradicional. Por otro lado, se confirma que el uso de información no financiera y macroeconómica aumenta la precisión de los modelos.

Siguiendo con la evidencia para Perú, Cubiles-De-La-Vega et al. (2013) distinguen entre préstamos con y sin incumplimiento en las IMF peruanas, a partir de la utilización de variadas técnicas de *credit scoring* (análisis discriminante lineal y cuadrático, regresión logística y técnicas de aprendizaje estadístico (*statistical learning techniques*)). La base de datos utilizada incluye características personales de los emprendedores, ratios financieros y económicos de la empresa, características de la operación de préstamo, contexto macroeconómico y demoras en el pago de las cuotas del microcrédito. Los resultados indican que el mejor modelo tiene la característica de un modelo no paramétrico, el *multilayer perceptron*. Concretamente, el estudio concluye que los enfoques no paramétricos otorgan una mejor precisión en la clasificación entre buenos y malos pagadores, frente a los métodos tradicionales para microcréditos (análisis discriminante lineal y cuadrático y regresión logística).

Contextualizado en Guatemala, existe el trabajo desarrollado por Luoto et al. (2007). Estos autores analizan el impacto en la morosidad derivado del acceso a sistemas de información crediticia por parte del oficial de crédito de una IMF en Guatemala. Ellos encuentran la significativa disminución de los créditos con atrasos, hacia una mejor performance de las IMF en un entorno competitivo, que asegura la disponibilidad de créditos a la población de empresarios de menores ingresos.

Finalmente, en relación con Uruguay, Beledo et al. (2007) analizan una base de datos de 2.072 préstamos a emprendimientos entre octubre de 1997 y mayo de 2006, a efectos de predecir la probabilidad de que un préstamo entre en una situación de atraso costoso. Se aplicó un modelo de regresión logística para clasificar a los prestatarios que cancelaron préstamos e incurrieron o no en atraso costoso. Los resultados obtenidos muestran un porcentaje de aciertos

del 75% para los microcréditos con atrasos costosos, mientras que la predicción de préstamos “buenos” respecto al total se ubicó en un 71,5%, mostrando una capacidad predictiva aceptable.

4. Conclusiones

El análisis de los modelos de *credit scoring* realizado en este trabajo permite advertir que éstos pueden ser utilizados en varias dimensiones. No obstante, en general, se observa una preferencia por predecir el riesgo de que los microcréditos incurran en algún tipo de atraso costoso y sobre el cual la IMF tenga control a efectos de mitigarlo. En esta línea, la literatura académica ha destacado la importancia de la información cualitativa dentro de las variables que se incorporan a los diferentes modelos estadísticos. De este modo, no solo se consideran como determinantes del impago en el microcrédito aquellos datos relacionados con el prestatario, el negocio y el préstamo, sino también que paulatinamente se está incorporando información sobre comportamiento, variables macroeconómicas y datos no estructurados. Asimismo, dentro del conjunto de técnicas denominadas *credit scoring*, la revisión de la literatura realizada en este trabajo permite afirmar que existe una preferencia por las técnicas paramétricas en el ámbito de los microcréditos. Así, destaca especialmente la regresión logística. Sin embargo, en los últimos años se registra un mayor número de trabajos que utilizan técnicas no paramétricas y que evalúan alternativamente la performance de varias de ellas respecto a una misma base de datos de préstamos o prestatarios. Los resultados muestran que las técnicas no paramétricas logran un mayor poder predictivo del incumplimiento de los clientes de microcréditos.

Finalmente, cabe agregar que conjuntamente con la mayor emisión de publicaciones académicas en relación a la aplicación de herramientas de *credit scoring* al ámbito de las microfinanzas, estas instituciones han incorporado paulatinamente estas prácticas de evaluación de riesgo de crédito y están rumbo a convertirse en una práctica estándar del mercado, como en las instituciones bancarias, donde estas herramientas se han utilizado en las últimas cinco décadas. En ese sentido, complementando la actividad del oficial de crédito, la IMF se beneficia de una mayor consistencia y transparencia en la evaluación y posterior seguimiento de los clientes, optimiza sus procesos y mejora el control de calidad dentro de la institución, mejorando en definitiva su performance general.

5. Referencias

- I. Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589-609.
- II. Armendáriz, B. y Morduch, J. (2011). *Economía de las microfinanzas*. Ciudad de México: Fondo de Cultura Económica y Centro de Investigación y Docencia Económicas.
- III. Ayouche, S., Aboulaich, R., & Ellaia, R. (2017). Partnership credit scoring classification problem: a neural network approach. *International Journal of Applied Engineering Research*, 12(5), 693-704.
- IV. Baklouti, I. (2014). A psychological approach to microfinance credit scoring via a classification and regression tree. *Intelligent Systems in Accounting, Finance and Management*, 21(4), 193-208.

- V. Beledo, M., Gaggero, M. & Lazarini, G. (2007). *Las microfinanzas: un modelo de calificación estadística para una institución especializada en microcréditos de Uruguay*. Trabajo de investigación monográfico. Universidad de la Republica, Facultad de Ciencias Económicas y de Administración.
- VI. Bensic, M., Sarlija, N., & Zekic- Susac, M. (2005). Modelling small- business credit scoring by using logistic regression, neural networks and decision trees. *Intelligent Systems in Accounting, Finance and Management*, 13(3), 133-150.
- VII. 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.
- VIII. Blanco, A., Pino, R., & Lara, J. (2014). Modeling the Financial Distress of Microenterprise Start-ups Using Support Vector Machines: a case study. *Innovar*, 24(SPE), 153-168.
- IX. Bumacov, V., Ashta, A., & Singh, P. (2014). The use of credit scoring in microfinance institutions and their outreach. *Strategic Change*, 23(7-8), 401-413.
- X. Chakravarty, S., & Jha, A. (2012). Viability of “Credit Scoring in Microfinance” for Developing Countries. *International Review of Social Sciences and Humanities*, 3(1), 104-107
- XI. 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.
- XII. De Cnudde, S., Moeyersoms, J., Stankova, M., Tobback, E., Javalý, V., & Martens, D. (2015). *Who cares about your Facebook friends? Credit scoring for microfinance* (No. 2015018).
- XIII. Deininger, K., & Liu, Y. (2009). *Determinants of repayment performance in Indian micro-credit groups*. World Bank Policy Research Working Paper 4885.
- XIV. Dellien, H. (2003). Credit Scoring in Microfinance: Guidelines Based on Experience with WWB Affiliates in Colombia and the Dominican Republic. *Women's World Banking*, 1(2), 1-15.
- XV. Dellien, H., & Schreiner, M. (2005). Credit scoring, banks, and microfinance: balancing high-tech with high-touch. *Microenterprise Development Review*, 8(2), 1-16.
- XVI. Diallo, B. (2006). *Un modele de “Credit scoring” pour une institution de micro-finance Africaine: Le cas de Nyesigiso au Mali*. Orleans: LEO - Laboratoire d'économie d'Orleans
- XVII. Dinh, T. H. T., & Kleimeier, S. (2007). A credit scoring model for Vietnam's retail banking market. *International Review of Financial Analysis*, 16(5), 471-495.

- XVIII. Dos Santos, J. O., de Godoi, A. F., Bertoncelo, V. R., & Sincerre, B. P. (2015). Essay about the micro-credit and credit analysis methods: issues related to its origin, development and the behavioural scoring. *Revista de Administração de Roraima*, 5(1), 134.
- XIX. European Commission (2015). *Credit Scoring in the European (Micro)finance sector*. European Microfinance Network aisbl. http://www.european-microfinance.org/docs/activities/think_tanks_idea_labs/SCORING_EMN2015_LINKS_2.pdf
- XX. Hand, D. J., & Henley, W. E. (1997). Statistical classification methods in consumer credit scoring: a review. *Journal of the Royal Statistical Society*, 160(3), 523-541.
- XXI. Kammoun, A. and Triki, I. (2016). Credit scoring models for a Tunisian microfinance institution: comparison between artificial neural network and logistic regression. *Review of Economics & Finance*, 6(1), 61-78.
- XXII. Kim, H. S., & Sohn, S. Y. (2010). Support vector machines for default prediction of SMEs based on technology credit. *European Journal of Operational Research*, 201(3), 838-846.
- XXIII. Kinda, O., & Achonu, A. (2012). Building a Credit Scoring Model for the Savings and Credit Mutual of the Potou Zone. *Consilience: The Journal of Sustainable Development*, 1(7), 17-32.
- XXIV. Lara Rubio, J., Bolívar, M. P. R., & Cantón, S. R. (2011). Un caso empírico en la evaluación del riesgo de crédito de una institución de microfinanzas peruana. *Contabilidad y Negocios: Revista del Departamento Académico de Ciencias Administrativas*, 6(11), 21-30.
- XXV. Lara Rubio, J., Rayo Cantón, S. & Camino Blasco, D. (2010). *La gestión del riesgo de crédito en las instituciones de microfinanzas*. Editorial de la Universidad de Granada.
- XXVI. Lara, J., Molina, V., Holgado, M.del M. (2014). *Manual de procedimientos para la gestión del riesgo de microcrédito*. Madrid: Godel.
- XXVII. Microfinance Gateway (2016). *Micro and SME Finance Market Outlook Report 2017*. Noviembre 2016. <https://www.microfinancegateway.org/library/micro-and-sme-finance-market-outlook-2017>
- XXVIII. Rayo Cantón, S., Lara Rubio, J., & Camino Blasco, D. (2010). Un modelo de Credit Scoring para instituciones de microfinanzas en el marco de Basilea II. *Journal of Economics, Finance and Administrative Science*, 15(28), 89-124.
- XXIX. Reinke, J. (1998). How to lend like mad and make a profit: A micro- credit paradigm versus the start- up fund in South Africa. *The Journal of Development Studies*, 34(3), 44-61.

- XXX. Römer, U., & Mußhoff, O. (2017). *Can agricultural credit scoring for microfinance institutions be implemented and improved by weather data?* (No. 1703). Diskussionspapiere, Department für Agrarökonomie und Rurale Entwicklung.
- XXXI. Schreiner, M. (1999). The risk of exit for borrowers from a microlender in Bolivia. *Center for Social Development, Washington University in St. Louis, gwweb. wustl.edu/users/schreiner.*
- XXXII. Schreiner, M. (2000). Credit scoring for microfinance: Can it work? *Journal of Microfinance/ESR Review*, 2(2), 105-118.
- XXXIII. Schreiner, M. (2003). Scoring Drop-out at a Microlender in Bolivia. *Savings and Development*, 27(2), 101-118.
- XXXIV. Schreiner, M. (2004). Scoring arrears at a microlender in Bolivia. *ESR Review*, 6(2), 65.
- XXXV. Serrano-Cinca, C., Gutiérrez-Nieto, B., & Reyes, N. M. (2016). A social and environmental approach to microfinance credit scoring. *Journal of Cleaner Production*, 112 (1), 3504-3513.
- XXXVI. Sharma, M., & Zeller, M. (1997). Repayment performance in group-based credit programs in Bangladesh: An empirical analysis. *World development*, 25(10), 1731-1742.
- XXXVII. Thomas, L. C., Edelman, D. B., & Crook, J. N. (2004). *Readings in credit scoring: foundations, developments, and aims.* Oxford: Oxford University Press.
- XXXVIII. Van Gool, J., Verbeke, W., Sercu, P., & Baesens, B. (2012). Credit scoring for microfinance: is it worth it? *International Journal of Finance & Economics*, 17(2), 103-123.
- XXXIX. Viganò, L. (1993). A credit scoring model for development banks: An African case study. *Savings and Development*, 17 (4), 441-482.
- XL. Vogelgesang, U. (2003). Microfinance in times of crisis: The effects of competition, rising indebtedness, and economic crisis on repayment behavior. *World Development*, 31(12), 2085-
- XLI. Zeller, M. (1998). Determinants of repayment performance in credit groups: The role of program design, intragroup risk pooling, and social cohesion. *Economic development and cultural change*, 46(3), 599-620.