

# Design of a model based on neural networks in the cloud to determine the credit risk in microcredit applicants in the financial market of Peru

César Canelo, Magister<sup>1</sup>, Paul Tocto, Magister<sup>2</sup>

<sup>1</sup>Universidad Nacional de Ingeniería, Perú, [ccanelo@uni.edu.pe](mailto:ccanelo@uni.edu.pe)

<sup>2</sup>Universidad Nacional de Ingeniería, Perú, [ptocto@uni.edu.pe](mailto:ptocto@uni.edu.pe)

*Abstract— Credit institutions have always had the problem of controlling the credit risk they are exposed to when developing their credit operations, in that sense, they have always required to rely on predictive models that help them make the right decisions for the acceptance or rejection of a loan. credit application. They are the well-known classical models based on statistical techniques and models based on artificial intelligence techniques. These models differ in the number of factors they require, in the techniques they employ and in the accuracy of the prediction. In this study, it is proposed to apply a methodology based on neural networks, which will allow the model to learn and adjust according to the information provided by the client. Microsoft Azure Machine Learning Studio is used, new software available in the cloud, which evaluates various models based on neural networks to determine which model best fits the data and minimizes the prediction error.*

*Keywords- Microcredit, Credit score, Data mining, Cloud*

Digital Object Identifier (DOI):<http://dx.doi.org/10.18687/LACCEI2018.1.1.504>

ISBN: 978-0-9993443-1-6

ISSN: 2414-6390

# Diseño de un modelo basado en redes neuronales en la nube para determinar el riesgo de crédito en los solicitantes de microcrédito en el mercado financiero de Perú

César Canelo, Magister<sup>1</sup>, Paul Tocto, Magister<sup>2</sup>

<sup>1</sup>Universidad Nacional de Ingeniería, Perú, ccanelo@uni.edu.pe

<sup>2</sup>Universidad Nacional de Ingeniería, Perú, ptocto@uni.edu.pe

*Abstract– Las entidades crediticias siempre han tenido el problema de controlar el riesgo de crédito al que se exponen al desarrollar sus operaciones crediticias, en tal sentido, siempre han requerido apoyarse en modelos predictivos que les ayuden a tomar decisiones acertadas para la aceptación o el rechazo de una solicitud de crédito. Los modelos predictivos de microcrédito que emplean las instituciones financieras para calificar a los solicitantes de crédito, son los conocidos modelos clásicos basados en técnicas estadísticas y los modelos basados en técnicas de inteligencia artificial. Estos modelos difieren en la cantidad de factores que requieren, en las técnicas que emplean y en la precisión de la predicción. En este estudio, se utilizó redes neuronales supervisadas, implementándose tres redes neuronales, para decidir si se acepta o se rechaza la solicitud de crédito. Las redes neuronales se entrenaron con los datos de una entidad micro-financiera, que constaba de 15,569 casos, cada uno de ellos tenía 20 atributos. Para crear las redes neuronales se utilizó Microsoft Azure Machine Learning Studio, software disponible en la nube, mediante el cual se obtuvieron los ratios de eficiencia y error, que permitieron elegir el mejor modelo de predicción. El modelo elegido se puede utilizar en la automatización de la evaluación de la solicitud de crédito de los clientes de las financieras.*

*Keywords– Microcredit; Credit score; Credit risk; Data mining; Cloud*

## I. INTRODUCCIÓN

Los microcréditos son pequeños préstamos que se conceden a las microempresas o personas naturales con escasos recursos económicos, que generalmente están excluidos de la banca comercial tradicional, pero que tienen capacidad emprendedora. Las entidades que otorgan este tipo de crédito a nivel mundial son las micro-financieras, y la mayoría de los países del mundo tienen algún tipo de programa de microcrédito. Este sector ha tenido un crecimiento notable en los últimos años, convirtiéndose en una industria en auge. Así, según la Ref. [1], en el período 1998-2008 el número de instituciones de micro finanzas creció un 474% y el número de clientes aumentó un 1048%. En la Ref. [2] se menciona que en Perú, los préstamos para consumo y para las MYPE han tenido una rápida expansión en el período 2016-2017. Paralelamente al crecimiento de la industria del microcrédito, se han agudizado los problemas relacionados con el otorgamiento de este tipo de préstamo, tales como la

alta morosidad, el desvío del préstamo para el consumo y no para una actividad productiva, las altas tasas de interés, los elevados gastos de administración del crédito, etc. Según la Ref. [11] el riesgo de crédito es un factor crítico de la gestión de los bancos, pues afecta a los préstamos aprobados y desaprobados. Como consecuencia de una mala gestión crediticia aumenta la tasa de morosidad, que a su vez atenta contra la estabilidad de las instituciones micro-financieras. A nivel mundial, la tasa de morosidad se mantiene en un nivel alto en los últimos años. En la Ref. [2] se indica que en Perú, la tasa de morosidad en los créditos de consumo y en los créditos a las MYPE tienen tendencia a subir, siguiendo la dinámica de los últimos doce meses. Según la Ref. [3] en la India, donde se encuentran el 30% de los clientes de microcrédito de todo el mundo, que representan el 7% de la cartera global de microcréditos, la tasa de morosidad también es un factor preocupante. Un estudio realizado en Nueva Delhi sobre una muestra de prestatarios de microcrédito reveló que el 22% de los clientes era moroso. A nivel mundial, la tasa de morosidad muestra cifras preocupantes para las entidades de micro finanzas.

Debido a la importancia del riesgo de crédito para las entidades financieras, se han desarrollado diversas investigaciones, según las Referencias [6], [7], [10], [11] tendientes a aumentar la exactitud de la predicción del riesgo crediticio. A partir del 2005 han tomado mayor importancia los modelos basados en técnicas de inteligencia artificial, porque han demostrado tener mayor precisión en la predicción del riesgo crediticio. Las redes neuronales artificiales utilizadas en los modelos han demostrado tener buen potencial para la predicción.

El artículo se organiza de la siguiente manera: en la sección 2 se revisa la literatura sobre modelos predictivos basados en redes neuronales. La sección 3 presenta los datos y se definen las variables. La sección 4 define la metodología. La sección 5 presenta el experimento y las pruebas. La sección 6 presenta el análisis de los resultados. Finalmente, la sección 7 presenta las conclusiones y recomendaciones para futuras investigaciones.

## II. REVISIÓN DE LA LITERATURA

En este documento se hace referencia a algunas investigaciones que respaldan el uso de las redes neuronales artificiales para la predicción del riesgo crediticio.

Según la Ref. [1], en un estudio hecho sobre un conjunto de datos de microcréditos de una institución de micro-finanzas de Perú para determinar el pago o no pago de micro-créditos, se evaluaron los modelos: análisis discriminante lineal y cuadrática, regresión logística, perceptron multicapa, máquina de soporte vectorial, árboles de clasificación y métodos ensamblados. Los resultados mostraron que con el uso de un perceptron multicapa entrenado en el sistema estadístico R con un algoritmo de segundo orden, se obtienen mejores resultados, lo cual conlleva a reducir los costos de clasificación errónea de las instituciones micro-financieras en un 13.7% con respecto a la aplicación de otros modelos clásicos. En otro estudio, Ref. [4], las redes neuronales fueron empleadas para determinar un modelo eficiente para el procesamiento automático de las solicitudes de crédito. La eficiencia del modelo se mide con la tasa de error obtenido y la tasa de precisión. Se entrenan tres modelos de redes neuronales utilizando nueve esquemas de aprendizaje. Los tres modelos neuronales difieren en la topología, y en particular en el número de neuronas de la capa oculta. Los nueve esquemas de aprendizaje difieren en las proporciones de casos para el entrenamiento de la red y la validación. Se determina el esquema de aprendizaje con el cual el modelo tiene la mejor performance. La Ref. [5] indica que las redes neuronales artificiales (RNA) conjuntamente con las redes neuronales emocionales (EmNNs) se emplearon para comparar su eficiencia en la evaluación del riesgo crediticio. Se ha investigado los efectos de los factores emocionales en los modelos EmNNs aplicados a la evaluación del crédito, y se ha comparado su rendimiento con respecto a una red neural supervisada convencional basado en el algoritmo de aprendizaje backpropagation (BP). El modelo EmNN se basa en el algoritmo de aprendizaje Emotional Backpropagation (EmBP), esta red neuronal emocional tiene dos respuestas emocionales (ansiedad y la confianza). Compara el rendimiento de 12 modelos de redes neuronales bajo los diferentes esquemas de aprendizaje y luego determina el modelo neural ideal y la actividad de aprendizaje. Los modelos emocionales superan a los modelos convencionales en velocidad y precisión, por lo que son ideales para el procesamiento automático de las solicitudes de crédito. La Ref. [6] señala que las redes neuronales artificiales diseñada bajo el enfoque perceptron multicapa, se han empleado para comparar su rendimiento frente a otros modelos que emplean el análisis discriminante lineal (LDA), análisis discriminante cuadrática (QDA) y las técnicas de regresión logística (LR). Se trabaja con un conjunto de datos de clientes de una institución micro-financiera de Perú, y se concluye que las redes neuronales artificiales (RNA) constituyen una de las herramientas más poderosas para la clasificación de patrones, debido a su no linealidad y propiedades de adaptación-aprendizaje no

paramétricas, pues superan a estas tres técnicas en términos del área bajo la curva (AUC) y costos de clasificación errónea. En la Ref. [7], se eligen redes neuronales artificiales y sistemas expertos para construir un sistema híbrido inteligente para la clasificación de crédito. Se desarrolla un sistema híbrido para combinar las capacidades de ambos sistemas. En lo que respecta a las redes neuronales, se destaca que por su naturaleza, son adecuados para el procesamiento de datos numéricos, además no requieren ninguna suposición de distribución para los datos de entrada, y siendo una técnica de minería de datos incremental, permite que se envíen nuevos datos a la red neuronal entrenada con el fin de actualizar el resultado de la información anterior. Se concluye que con el sistema híbrido se logra un modelo eficiente y efectivo para la clasificación del crédito. En la misma línea de investigación, la Ref. [8] hace un estudio comparativo de las aplicaciones de inteligencia artificial en las finanzas, comparando la precisión de las redes neuronales artificiales, los sistemas expertos y sistemas inteligentes híbridos y se concluye que la precisión de estos métodos de inteligencia artificial es superior a la de los métodos estadísticos tradicionales en el tratamiento de los problemas financieros, especialmente en lo relativo a patrones no lineales. Según la Ref. [9], la RNA con aprendizaje tipo Backpropagation, ha sido empleada para construir un modelo para detectar el riesgo crediticio. Este modelo presenta diferentes configuraciones de la red, variando el número de neuronas en la capa oculta así como también normalizando la data para reducir su dimensionalidad, para lo cual se utiliza el Análisis de Componentes Principales (PCA), hasta obtener la configuración del modelo de red de mayor precisión. En el entrenamiento del modelo se hace notar la conveniencia de disminuir la dimensionalidad de la data mediante la normalización, con lo cual, además se reduce el número de neuronas en la capa oculta. El estudio concluye que el modelo entrenado con los datos normalizados es más eficaz y eficiente para predecir el riesgo crediticio. En la Ref. [10], los autores proponen un método de descubrimiento del conocimiento utilizando redes neuronales basados en el enfoque del perceptrón multicapa (MLP), orientado al análisis del riesgo de crédito (CRA) de las pequeñas y medianas empresas (PYMES) en Turquía. El MLP toma una decisión para los clientes como "buenos" o "malos" y revela las reglas obtenidas en la decisión final. El enfoque propuesto valida la afirmación de que es una alternativa viable a otros métodos para el descubrimiento de conocimiento. En otra aplicación de las RNAs, la Ref [11], se propone un modelo utilizando la función de base radial para evaluar el riesgo crediticio en los bancos comerciales de Jordania, este método resultó ser superior a la regresión logística en términos de la identificación de los clientes que incumplen con la devolución del crédito. Los autores concluyen que no hay un mejor método para la evaluación de las solicitudes de crédito. Según la Ref. [12], en Perú, con la finalidad de que un banco estatal incursione en el servicio de microcrédito, se propone un modelo basado en

redes neuronales para predecir la morosidad de los futuros clientes de micro-crédito. Se realiza experimentos comparando el Método de cómputo RNA versus el Convencional, y en las pruebas efectuadas obtiene entre el 97 y 99% de precisión, con lo cual demuestra que la RNA tipo perceptron multicapa es muy eficiente para predecir la morosidad en el micro-crédito. La preferencia para el uso de este modelo, también queda demostrado con el 95% de confianza estadística. Según la Ref. [13], en un estudio de los créditos de las Cooperativas de Ahorro y Crédito, se aplicó un modelo de redes neuronales para identificar los potenciales “buenos” o “malos” clientes. Esta investigación exploró el desempeño de tres diferentes modelos de redes neuronales: modelo de retro-propagación con aprendizaje adaptativo, modelo de retro-propagación con la aproximación de Levenberg-Marquardt, y el modelo de cuantificación del vector de aprendizaje para identificar préstamos problemáticos. Los modelos de redes neuronales superaron al modelo de regresión logística contra el cual fueron comparados, identificando posibles incumplimientos de préstamos y, por tanto, minimizando el error tipo II, el modelo de Backpropagation de doble capa con aprendizaje adaptativo mostró el mayor grado de precisión en la identificación de préstamos con problemas, el modelo de cuantificación del vector de aprendizaje proporcionó el grado más alto de exactitud global de la predicción en la identificación correcta de "buenos" y "malos" préstamos. Sin embargo, los resultados reportados en este estudio están lejos de ser suficientes para generar declaraciones concluyentes sobre la aplicabilidad de los modelos de redes neuronales en general, proporciona algunas ideas de sus potencialidades y limitaciones, pero si concluye que los modelos de redes neuronales son más robustos que el tradicional modelo de regresión logística.

### III. COLECCIÓN DE DATOS Y DEFINICIÓN DE VARIABLES

Para este estudio se tiene como base de datos la información de una entidad micro financiera, dedicada a otorgar crédito a micro empresarios y personas naturales. La base de datos está conformada por 15,569 registros de préstamos. La Tabla I muestra las variables que se usaron en el modelo, en total son 20 variables independientes y una variable dependiente FI-id.

TABLA I  
VARIABLES DEL MODELO

Nro	Atributo	Descripción
1	MON	Tipo de moneda.
2	MORG	Monto del préstamo.
3	SKCR	Saldo capital de la deuda.
4	TCR	Tipo de crédito según reporte crediticio de deudores.
5	CAL	Clasificación del deudor.
6	CALINT	Clasificación deudor sin considerar alineamiento con el sistema.
7	DAK	Días de atraso al cierre del mes.
8	DAKR	Días de atraso reales de la última cuota

9	DAPR	pagada.
10	KVI	Promedio días de atraso incurridos en pagos cuotas últimos 6 meses.
11	KRF	Saldo capital vigente de la operación.
12	KVE	Saldo capital refinanciado.
13	KJU	Saldo de capital en cobranza judicial.
14	ESAM	Esquema de amortización.
15	DGR	Número días de gracia para pago de capital según cronograma.
16	PCUO	Periodicidad de cuotas.
17	NCPR	Número de cuotas programadas.
18	NCPA	Número de cuotas pagadas.
19	TEA	Tasa efectiva anual.
20	NRPRG	Número de cambios contractuales en cronograma distinto a refinanciación.
21	FI-id	Flag de rechazo.

### IV. METODOLOGÍA

Se utiliza las redes neuronales supervisadas implementándose tres redes neuronales, para decidir la aceptación o el rechazo de una solicitud de crédito. La Fig. 1 muestra la arquitectura de la red neuronal que se utiliza.

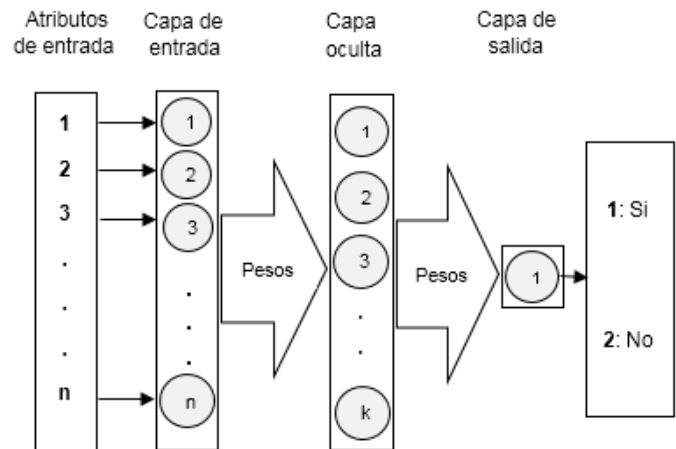


Fig. 1 Arquitectura de la red neuronal para la evaluación de crédito.

Para el experimento se evaluó a los líderes en el servicio de procesamiento analítico de datos en la nube: Amazon, IBM y Microsoft. Se eligió a Microsoft por tener mayor facilidad en el manejo de datos. El proceso seguido en el Portal Microsoft Azure Machine Learning Studio para nuestro experimento se resume en los siguientes pasos:

Paso 1. Subir los datos al entorno de Microsoft Azure Machine Learning Studio en la nube.

Paso 2. Seleccionar las variables a considerar en el modelo, utilizando para ello el módulo “Filter Based Feature Selection”, el cual permite identificar que variables tienen mayor correlación con la variable resultado de la evaluación: FI-id. Con este criterio se seleccionan las variables que tienen mayor coeficiente de correlación. La Fig. 2 muestra los coeficientes de correlación de las variables con la mayor

correlación, de acuerdo a esto se consideran las siguientes variables: DAKR, CALINT, CAL, DAK, KVE y DAPR.




Fig. 2 Coeficiente de correlación de las variables.

Paso 3. Se realiza la limpieza de los datos. Para los datos que no existen, se considera el promedio, mediante el módulo “Clean Missing Data”. La Fig. 3 muestra el histograma de la variable CAL, la cual es tomada como una de las variables representativas del modelo. La Fig. 4 muestra los estadísticos para esta variable. La Tabla II y la Tabla III muestran los estadísticos para las 6 variables que presenta el mayor coeficiente de correlación con la variable de salida FI-id.




Fig. 3 Histograma de la variable CAL

Statistics	
Mean	0.0399
Median	0
Min	0
Max	1
Standard Deviation	0.1957
Unique Values	2
Missing Values	0
Feature Type	Numeric Feature

Fig. 4 Estadísticos de la variable CAL

TABLA II  
ESTADÍSTICOS DE LAS VARIABLES

Estadístico	Variable		
	DAKR	CALINT	CAL
Mean	1.435	0.0421	0.0399
Median	0	0	0
Min	0	0	0
Max	16	1	1
Std Dev	2.7964	0.2009	0.1957
Unique Val	17	2	2
Missing Val	0	0	0
Feature type	Numeric	Numeric	Numeric

TABLA III  
ESTADÍSTICOS DE LAS VARIABLES

Estadístico	Variable		
	DAK	KVE	DAPR
Mean	-16.199	1.1301	0.1439
Median	-15	0	0
Min	-85	0	-10
Max	32	38.0468	16
Std Dev	18.131	6.4574	2.1119
Unique Val	118	3	27
Missing Val	0	0	0
Feature type	Numeric	Numeric	Numeric

Paso 4. Se separa el 80% de los datos para la fase de entrenamiento mediante el módulo “Split Data”, ver Fig. 5.

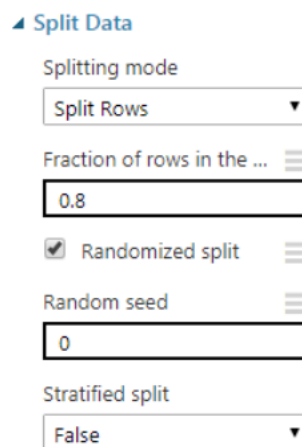


Fig. 5 Separación de datos para entrenamiento

Paso 5. Se configura el módulo de “Neural Network. Regression” como se muestra en la Fig. 6.

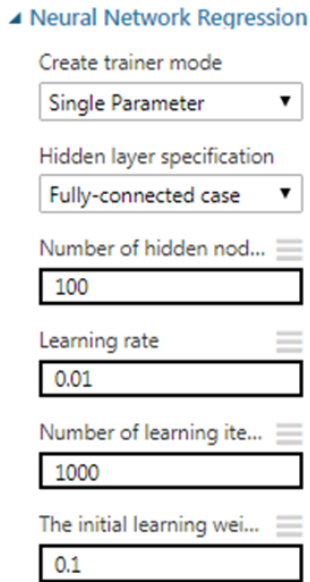


Fig. 6 Configuración del módulo “Neural Network Regression”.

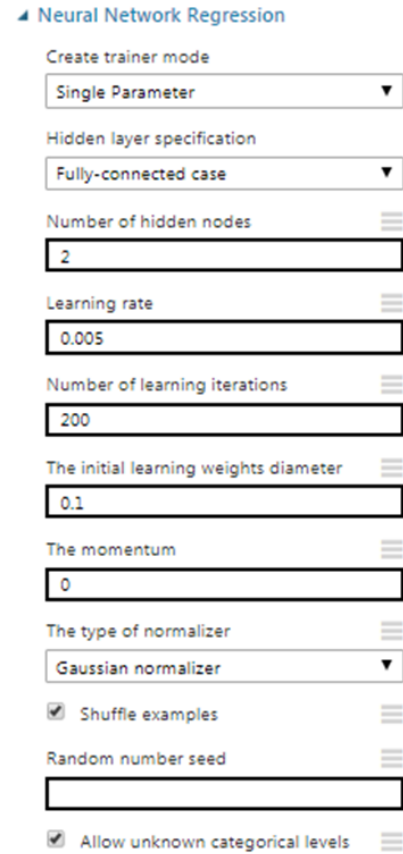


Fig. 7 Configuración del módulo para 2 nodos ocultos y 200 iteraciones.

Paso 6. Se realiza el entrenamiento utilizando el módulo “Train Model” que utiliza los datos de entrenamiento del paso 4 y el módulo configurado del paso 5.

Paso 7. Se valida el modelo con los datos de verificación, que son el 20% del total, utilizando el módulo “Score Model”.

Paso 8. Se evalúa el modelo con el módulo “Evaluate Model”.

## V. EXPERIMENTO

El experimento se realiza variando el número de nodos y el número de iteraciones en cada prueba. La Fig. 7 muestra la configuración del módulo para 2 nodos en la capa oculta y 200 iteraciones. La Fig. 8 muestra los resultados de la evaluación de la configuración anterior. Las Figs. 9 al 16 muestran los resultados de la evaluación variando aleatoriamente el número de nodos y la cantidad de iteraciones.

Metrics	
Mean Absolute Error	0.011861
Root Mean Squared Error	0.041766
Relative Absolute Error	0.29017
Relative Squared Error	0.085351
Coefficient of Determination	0.914649

Fig.8 Resultados de la evaluación para 2 nodos ocultos y 200 iteraciones.

Metrics	
Mean Absolute Error	0.011799
Root Mean Squared Error	0.042111
Relative Absolute Error	0.288655
Relative Squared Error	0.086768
Coefficient of Determination	0.913232

Fig. 9 Resultados de la evaluación para 5 nodos ocultos y 200 iteraciones.

#### Metrics

Mean Absolute Error	0.01125
Root Mean Squared Error	0.043465
Relative Absolute Error	0.275225
Relative Squared Error	0.092435
Coefficient of Determination	0.907565

Figura 10. Resultados de la evaluación para 10 nodos ocultos y 200 iteraciones.

#### Metrics

Mean Absolute Error	0.008487
Root Mean Squared Error	0.036108
Relative Absolute Error	0.20764
Relative Squared Error	0.063794
Coefficient of Determination	0.936206

Fig. 11 Resultados de la evaluación para 2 nodos ocultos y 500 iteraciones.

#### Metrics

Mean Absolute Error	0.006832
Root Mean Squared Error	0.032231
Relative Absolute Error	0.167146
Relative Squared Error	0.050829
Coefficient of Determination	0.949171

Fig. 12 Resultados de la evaluación para 2 nodos ocultos y 1000 iteraciones.

#### Metrics

Mean Absolute Error	0.00283
Root Mean Squared Error	0.019869
Relative Absolute Error	0.069227
Relative Squared Error	0.019317
Coefficient of Determination	0.980683

Fig. 13 Resultados de la evaluación para 2 nodos ocultos y 10,000 iteraciones.

#### Metrics

Mean Absolute Error	0.001972
Root Mean Squared Error	0.017212
Relative Absolute Error	0.048252
Relative Squared Error	0.014496
Coefficient of Determination	0.985504

Fig. 14 Resultados de la evaluación para 2 nodos ocultos y 20,000 iteraciones.

#### Metrics

Mean Absolute Error	0.000908
Root Mean Squared Error	0.010656
Relative Absolute Error	0.022208
Relative Squared Error	0.005556
Coefficient of Determination	0.994444

Fig. 15 Resultados de la evaluación para 2 nodos y 100,000 iteraciones.

#### Metrics

Mean Absolute Error	0.000315
Root Mean Squared Error	0.004038
Relative Absolute Error	0.007697
Relative Squared Error	0.000798
Coefficient of Determination	0.999202

Fig. 16 Resultados de la evaluación para 2 nodos y 1'000,000 iteraciones.

## VI. ANÁLISIS DE RESULTADOS

Los indicadores de evaluación del modelo de regresión son los siguientes: Error absoluto medio, raíz del error cuadrático medio, error absoluto relativo, error cuadrático relativo y coeficiente de determinación. El “error” representa la diferencia entre el valor predicho y el valor real obtenido. El coeficiente de determinación es un indicativo del nivel de variabilidad explicada en los datos, esta métrica evalúa qué tan bien un modelo explica y predice los resultados futuros, esta métrica nos indica el rendimiento predictivo del modelo, es decir, permite medir la exactitud del modelo.

Del experimento, en las Figuras 9 y 10, se hacen pruebas con 5 y 10 nodos respectivamente, manteniendo constante el número de iteraciones en 200, se observa que el coeficiente de determinación no mejora al aumentar el número de nodos. Sin embargo, el coeficiente de determinación si mejora a medida que aumenta el número de iteraciones de la prueba. Para un modelo con 2 nodos y 200 iteraciones se obtienen un coeficiente de determinación de 0.914649 y a medida que se aumenta el número de iteraciones en la prueba, este índice mejora. Así, para 2 nodos y 1'000,000 de iteraciones, el coeficiente de determinación es 0.999202. Teniendo en cuenta que un coeficiente de determinación igual a 1 indica un ajuste perfecto, se elige el modelo de 2 nodos y un millón de iteraciones, por tener un ajuste casi perfecto. El modelo creado en la nube es posible, según la Ref. [14], actualmente la computación en la nube es considerada como un servicio público más, gracias a ello podemos realizar el procesamiento

de grandes volúmenes de datos, con un número grande de iteraciones, lo que facilita la experimentación y ayuda en las investigaciones actuales, como también la distribución del modelo para su uso, de forma transparente, sin necesidad de tener conocimientos de programación web, ni tener equipos dedicados para tal fin, porque es posible adquirir el servicio de un equipo en la nube para ese fin.

## VII. CONCLUSIONES Y RECOMENDACIONES

### 7.1. Conclusiones

- Los resultados obtenidos de las pruebas, permiten afirmar que, al aumentar el número de nodos, manteniendo el mismo número de iteraciones, el coeficiente de determinación no mejora.
- Al aumentar el número de iteraciones, manteniendo constante el número de nodos, el coeficiente de determinación si mejora.
- El modelo propuesto lograría, de acuerdo a los resultados obtenidos por la red neuronal, explicar el comportamiento y emitir la calificación de un cliente que solicita un micro-crédito.
- Las redes neuronales artificiales son una herramienta poderosa para el procesamiento de información subjetiva, por tanto, podría incluirse en el modelo este tipo de información para mejorar la precisión de la predicción.
- El procesamiento en la nube es una realidad y se debe de aprovechar para el desarrollo de las investigaciones.

### 7.2. Recomendaciones

- En futuros estudios debe incluirse en el modelo la variable voluntad de pago. Aunque esta variable es muy subjetiva, porque su valor depende de la percepción que el oficial de crédito tenga acerca del solicitante, consideramos importante incluirla en un modelo de predicción del riesgo del crédito.
- Otra variable cuya inclusión en el modelo que consideramos muy importante es el destino del crédito. Se trata de una variable que influye en la generación de recursos para la devolución del crédito. Esta variable debe ser proporcionada por el solicitante del crédito y debe ser verificada por el oficial de crédito.

## REFERENCIAS

[1] María-Dolores Cubiles-De-La-Vega, Antonio Blanco-Oliver, Rafael Pino-Mejías & Juan Lara-Rubio, "Improving the management of microfinance institutions by using credit scoring models based on Statistical Learning techniques", *Expert Systems with Applications* 40, 2013, pp. 6910–6917.

[2] Reporte de Estabilidad Financiera. Banco Central de Reserva del Perú, noviembre 2017.

<http://www.bcrp.gob.pe/docs/Publicaciones/Reporte-Estabilidad-Financiera/ref-noviembre-2017.pdf>

[3] ¿Qué ocurre con los clientes que caen en mora? Estudio exploratorio de prácticas de microfinanzas. Febrero de 2015. [http://red-accion.org/wp-content/uploads/2015/03/what\\_happens\\_to\\_microfinance\\_clients\\_who\\_default\\_SP.pdf](http://red-accion.org/wp-content/uploads/2015/03/what_happens_to_microfinance_clients_who_default_SP.pdf)

[4] Adnan Khashman, "Neural networks for credit risk evaluation: Investigation of different neural models and learning schemes", *Expert Systems with Applications* 37, 2010, pp. 6233–6239.

[5] Adnan Khashman, "Credit risk evaluation using neural networks: Emotional versus conventional models", *Applied Soft Computing* 11, 2011, pp. 5477–5484.

[6] Antonio Blanco, Rafael Pino-Mejías, Juan Lara & Salvador Rayo, "Credit scoring models for the microfinance industry using neural networks: Evidence from Peru", *Expert Systems with Applications* 40, 2013, pp. 356–364.

[7] Arash Bahrammirzaee, Ali Rajabzadeh Ghatari, Parviz Ahmadi & Kurosh Madani, "Hybrid credit ranking intelligent system using expert system and artificial neural networks", *Appl Intell*, April 2009, pp. 28–46.

[8] Arash Bahrammirzaee, "A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems", *Neural Comput & Applic*, June 2010, 19, pp. 1165-1195.

[9] Cristian López Del Álamo & Juan Lazo Lazo, "Propuesta de un modelo basado en redes neuronales para la detección de riesgo crediticio", *Revista de Investigación ULASALLE*, Universidad La Salle, Arequipa, Perú, Número 1, 2012, pp. 55-64.

[10] Gülnur Derelioglu & Fikret Gürgen, "Knowledge discovery using neural approach for SME's credit risk analysis problem in Turkey", *Expert Systems with Applications* 38, 2011, pp. 9313–9318.

[11] Hussain Ali Bekhet & Shorouq Fathi Kamel Eletter, "Credit risk assessment model for Jordanian commercial banks: Neural scoring approach", *Review of Development Finance* 4, 2014, pp. 20–28.

[12] Palacios, L., Modelo de RNA para predecir la morosidad de microcredito en la Banca Estatal Peruana, Universidad Nacional Mayor de San Marcos, Lima, Perú, Master's Thesis, 2012.

[13] Rashmi Malhotra & D.K. Malhotra, "Identifying Potential Loan Defaulters in the Credit Union Environment: A Comparative Analysis of Statical and Neural Networks Models", *Journal of Information Technology Case and Application Research*, Sep 2014, pp. 20-48.

[14] Priyadarshinee P., Raut R., Kumar M., Gardas B., "Understanding and predicting the determinants of cloud computing adoption: A two staged hybrid SEM - Neural networks approach", *Computers in Human Behavior*, Nov 2017, pp. 341-362.