



LOS LIBERTADORES
FUNDACIÓN UNIVERSITARIA

Modelo de scoring para crédito de consumo en una entidad del sector solidario

Arbey González Parga, agonzalezp03@libertadores.edu.co, Fundación Universitaria Los Libertadores

John González Veloza, jjgonzalezv02@libertadores.edu.co, Fundación Universitaria Los Libertadores

RESUMEN

En Colombia la Superintendencia de la Economía Solidaria a través de la Circular Básica Contable, Título IV, Capítulo II regula el SARC como el Sistema de Administración de Riesgo de Crédito que deben implementar y/o complementar las organizaciones solidarias vigiladas, con el propósito de, identificar, medir, controlar y monitorear el riesgo de crédito al cual se encuentran expuestas en el desarrollo de su proceso de otorgamiento. Dicho lo anterior, se hace necesario para las entidades del sector que colocan créditos, contar con modelos propios que obtengan las variables más relevantes y que permitan calcular la probabilidad de incumplimiento con base en la información de los créditos que tiene la entidad y calificar de manera periódica cada uno de los créditos vigentes. El objetivo principal de este artículo es explicar cómo se pueden obtener las variables más relevantes para el cálculo de la probabilidad de incumplimiento de pago de un cliente y crear un score interno para nuevos créditos con el fin de apoyar la decisión del otorgamiento a través de un modelo de machine learning. Este artículo se realizó utilizando una base de datos de una entidad del sector solidario que contiene un total de 5974 créditos de consumo y mediante aprendizaje automático se entrenaron diferentes modelos para determinar la probabilidad de incumplimiento de un cliente. El modelo de light gradient boosting machine obtuvo el mejor desempeño con un AUC de 0.7550, recall de 0.7111, precisión 0.1587. Además,

entre las variables disponibles, las que tienen mayor importancia para inferir la probabilidad de incumplimiento para un crédito de consumo son la antigüedad, total activos, total pasivos, ingresos mensuales, egresos mensuales, valor del crédito, plazo, nivel de estudio, estado civil, forma de pago y edad.

Palabras clave: Modelo scoring, regresión logística, riesgo de crédito, machine learning, sector solidario.

ABSTRACT

In Colombia, the Superintendence of the Solidarity Economy through the Basic Accounting Circular, Title IV, Chapter II regulates the SARC as the Credit Risk Management System that must be implemented and/or complemented by the supervised solidarity organizations, with the purpose of, identify, measure, control and monitor the credit risk to which they are exposed in the development of their granting process. Having said the above, it is necessary for the entities of the sector that place credits, to have their own models that obtain the most relevant variables and that allow the calculation of the probability of default based on the information of the credits that the entity has and to qualify accordingly. periodically each of the current credits. The main objective of this article is to explain how the most relevant variables can be obtained to calculate the probability of default of a client and create an internal score for new loans in order to support the granting decision through a machine learning model. This article was carried out using a database of a solidarity sector entity that contains a total of 5974 consumer loans and through automatic learning different models were trained to determine the probability of default of a client. The light gradient boosting machine model had the best performance with an AUC of 0.7550, recall of 0.7111, precision 0.1587. In addition, among the available variables, the ones that are most important to infer the probability of default for a consumer loan are age, total assets, total liabilities, monthly income, monthly expenses, credit value, term, level of study, status civil, form of payment and age.

Keywords: Scoring model, logistic regression, credit risk, machine learning, solidarity sector.

1. INTRODUCCIÓN

Según cifras de la superintendencia de economía solidaria en Colombia la cartera bruta de créditos del sector solidario a 31 de diciembre 2021 es de 14.67 billones de pesos, con un indicador de cartera por riesgo del 6% que equivale aproximadamente a 880 mil millones de pesos. Por otro lado, es conocido que en la actualidad las entidades que pertenecen al sector solidario cuentan con procedimientos y metodologías tradicionales para el otorgamiento de los créditos con demoras en tiempos de semanas y hasta meses, y que dejan la decisión de otorgamiento de manera subjetiva entre clientes con condiciones similares al carecer de modelos estadísticos.

Estas entidades tienen como referencia principal la información proporcionada por las centrales de riesgo que funcionan en Colombia (Datacrédito y/o Transunión), sin embargo, es importante que las entidades puedan tomar decisiones con modelos internos propios desarrollados a partir de la información de sus bases de datos.

Teniendo en cuenta lo anterior, se hace necesario para las entidades del sector solidario que colocan créditos, contar con modelos que obtengan las variables más relevantes y que permitan calcular la probabilidad de incumplimiento con base en la información de cada crédito y a su vez calificarlos mediante un score.

Como lo afirma Guevara Castro y Moreno Noriega (2020) "las Cooperativas dentro del marco financiero colombiano son fundamentales para el otorgamiento de créditos a la población de los estratos socioeconómicos 1, 2 y 3, que tienen acceso restringido a la banca tradicional por ser en su mayoría informales laboralmente, bajo nivel de ingresos o en ocasiones por desconocimiento del manejo financiero. Las Cooperativas brindan la posibilidad de adquirir experiencia crediticia, pero a su vez se genera alto riesgo en el otorgamiento de dichos créditos, por no existir un modelo para el análisis y aprobación de estos, que minimice el default de la cartera".

Este trabajo presenta diferentes modelos de clasificación, los cuales, son comparados con las métricas AUC, recall, precisión, accuracy y F1 Score con el fin de obtener el mejor modelo que permita calcular la probabilidad e incumplimiento de un cliente.

Para realizar la estimación y entrenamiento de los modelos se hace uso de los datos de una entidad del sector solidario que consta de 5974 créditos de consumo con variables cualitativas y cuantitativas que se describen en el desarrollo del artículo.

2. REFERENTES TEÓRICOS

Según el estado del arte realizado para este trabajo de investigación encontramos trabajos como el de Arroba Rimassa y Montalvo Lima (2020), que afirman “el Credit Scoring es una herramienta que puede ayudar a tomar una decisión fundamentada en el histórico de créditos pasados, y tener menor riesgo de pérdida de liquidez en la empresa. En la parte de construcción de los modelos de clasificación obtuvieron niveles de precisión para la regresión logística del 97%, para Random Forest del 98% y para máquinas de soporte vectorial del 98%”; también concluyen que los datos juegan un papel importante al momento de realizar el entramiento de estos modelos supervisados ya que podemos estar sesgando a una sola predicción en cada modelo y siempre clasificaría como socio estrella o mal pagador.

Cano Bedoya (2021), presenta un trabajo donde los árboles de decisión y los algoritmos de boosting permiten detectar puntos de corte en las divisiones binarias sucesivas que dan señales de una discriminación objetiva en variables cualitativas y cuantitativas; su mejora se da cuando se utilizan algoritmos de boosting y validación cruzada aunque se pierde la interpretación de los árboles, pero se gana en una mejora en cuanto a la estimación de la probabilidad de pertenecer a una clase. El modelo Probit mejora lo anterior y el modelo Logit permite obtener un ordenamiento de las variables. Los tres modelos permitieron indicar las variables con mayor poder de discriminación. EL algoritmo de k-vecinos más cercanos ayuda a indicar la pertenencia de un asociado a la clase de riesgoso o no riesgoso, en él se incluyeron un número considerable

de variables predictoras que previamente se seleccionaron, pero no estima las probabilidades de pertenecer a una clase, solo la mide de acuerdo con el número de vecinos más cercanos. Máquinas de soporte vectorial: Es útil en el escenario en el que el problema de credit scoring se analiza con un número amplio de variables, permitió estimar las probabilidades de pertenecer a una clase, y es útil en el caso en que separar las clases se hace cada vez más difícil por la alta dimensionalidad y el alto volumen de datos. Redes neuronales: El algoritmo basado en redes neuronales para clasificación mostró alto poder de predicción y bajo error de clasificación.

Otro trabajo reciente es el de Gómez Henao (2021), donde se plantearon modelos de machine learning con desempeños sobresalientes para el estudio de otorgamiento de créditos de personas naturales, incluyendo información macroeconómica del lugar de residencia de estas para evaluar su efecto dentro de estos estudios y abordar el problema de la asignación correcta de capital de las entidades crediticias. Se obtuvieron resultados positivos en los modelos cuando se implementó la información macroeconómica dentro de estos, resaltando que el mejor modelo de los estudiados obtuvo un AUROC de 0.933.

3. METODOLOGÍA

Este trabajo de investigación se realizó basado en la metodología SEMMA y haciendo uso del lenguaje de programación Python 3 en Google Colab. Como podemos ver la figura 1 ilustra las cinco fases de dicha metodología.

Figura 1

Etapas de la metodología SEMMA



La fase “muestra” consolida en detalle el insumo de datos utilizados para esta investigación; la fase de “exploración” mediante herramientas de visualización determina cuales

pueden ser las mejores variables explicativas que serán utilizadas como entradas del modelo; la fase de “manipulación” busca que los datos se definan y tengan el formato adecuado para ser introducidos en el modelo; la siguiente fase de “Modelado” consiste en determinar una relación entre las variables explicativas y la variable dependiente, y por último en la fase de “valoración” se evalúan los resultados del modelo mediante pruebas de desempeño o comparando con otros modelos.

3.1 Muestra

Se cuenta con una base de datos en Excel de 970 KB, que consta de un encabezado, 5974 filas y 28 columnas, donde cada fila representa un crédito y cada columna representa una variable. La base de datos fue proporcionada por una entidad del sector solidario de manera anónima y en su proceso de extracción se validó que no contara con valores nulos en ninguna de sus columnas, adicionalmente, se validó que los valores de las variables numéricas fueran mayores o iguales a cero y que la edad fuera mayor o igual a 18 años y menor a 100 años. Las columnas de la base de datos se describen a continuación en la tabla 1.

Tabla 1

Descripción de las Variables de la base de datos y su redefinición

Variable	Descripción y Unidades	Redefinición
Incumplimiento	Para nuestro caso utilizaremos como variable dependiente el incumplimiento de un cliente en el pago de un crédito, siendo cero (0) que cumpla con los pagos (menor a 30 días de mora) y uno (1) que incumpla con los pagos (mayor o igual a 30 día de mora)	
Edad	Hace referencia a la edad del cliente titular del crédito	
Género	Género del titular del crédito (Femenino o Masculino)	
Antigüedad	Cantidad de meses que lleva asociado el titular del crédito en la entidad	
Total activos	Total de los activos del cliente titular del crédito	Se toma el logaritmo en base 10

Total pasivos	Total de los pasivos del cliente titular del crédito	Se toma el logaritmo en base 10
Total patrimonio	Total del patrimonio del cliente titular del crédito o en su defecto activos – pasivos	
Ingresos mensuales	Total de los ingresos mensuales del cliente titular del crédito	Se toma el logaritmo en base 10
Egresos mensuales	Total de los egresos mensuales del cliente titular del crédito	Se toma el logaritmo en base 10
Valor del crédito	Corresponde al desembolso inicial del crédito	Se toma el logaritmo en base 10
Saldo del crédito	Corresponde al saldo actual del crédito al momento del análisis	
Tipo de vivienda	Corresponde al tipo de vivienda del titular del crédito	
Estado civil	Estado civil del titular del crédito	
Valor inmuebles	Total del valor de los inmuebles que hacen parte del patrimonio	
Valor vehículo	Total del valor de los inmuebles que hacen parte del patrimonio	
Días de mora	Cantidad de días de mora actuales del crédito. Esta variable se utilizó para calcular la variable objetivo	
Clasificación de la cartera	Corresponde a la calificación de la cartera de acuerdo a la Super Intendencia de Economía Solidaria (A, B, C, D, E)	
Nivel de estudios	Corresponde al nivel de estudios aprobados por el titular del crédito	Se transforma a ordinal
Forma de pago	Corresponde a la forma en que se realizan los pagos de las cuotas del crédito (ventanilla / Nómina)	
Plazo en meses	Cantidad de meses de plazo para el pago del crédito	
Estrato	Estrato socioeconómico del titular del crédito	Se transforma a ordinal
Saldo del vencido	Corresponde al saldo actual del crédito al momento del análisis	
Código de la Actividad económica	Actividad económica del titular del crédito de acuerdo al CIIU	
Descripción de la Actividad económica	Actividad económica del titular del crédito de acuerdo al CIIU	
Tipo de persona	Persona natural / Persona Jurídica	
Tipo de garantía del crédito	Corresponde a la descripción del tipo de garantía del crédito	
Libranza	Indica si el recaudo del crédito es mediante la modalidad de libranza (descuento por nómina)	

Indicador de reestructuración	Indica si el crédito se encuentra reestructurado	
-------------------------------	--	--

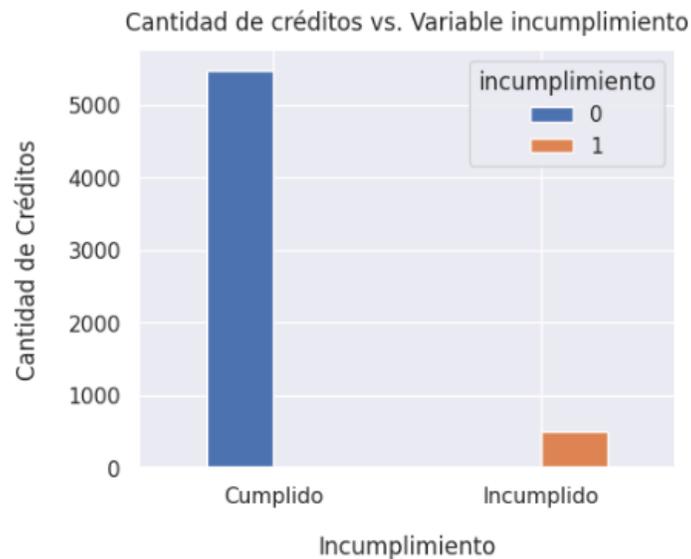
3.2 Exploración

Se realiza el cargue de la base de datos en google drive y se realiza el análisis exploratorio de la variable incumplimiento contra las 27 posibles variables explicativas del modelo. A continuación, se describen los hallazgos más relevantes:

Incumplimiento: 498 créditos presentan incumplimiento en el pago, mientras que 5476 no presentan incumplimiento, es decir, 8% y 92% respectivamente. Esto indica que existe un desbalanceo entre las dos clases como se observa en la figura 2.

Figura 2

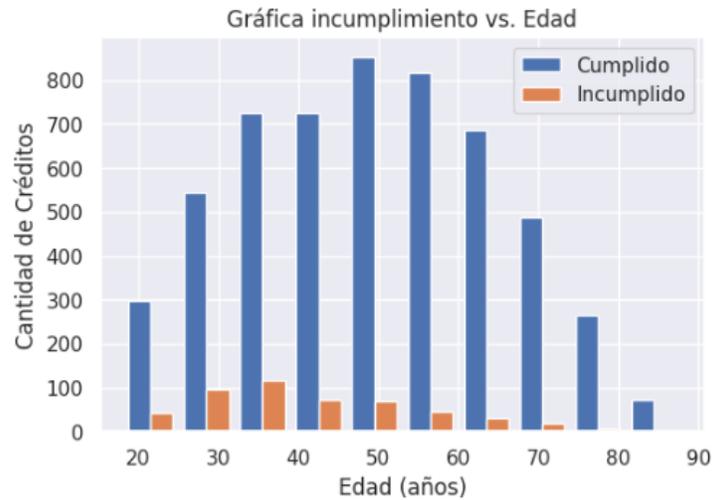
Cantidad de créditos vs. Variable incumplimiento



Edad: Presenta un valor mínimo de 18 años, un máximo de 88 años, desviación estándar aproximada de 15.50 años y una media de 48,45. Como se observa en la figura 3 los clientes mayores de 40 años presentan un mejor cumplimiento en el pago de los créditos, por lo tanto, la variable parece ser una buena predictora del modelo.

Figura 3

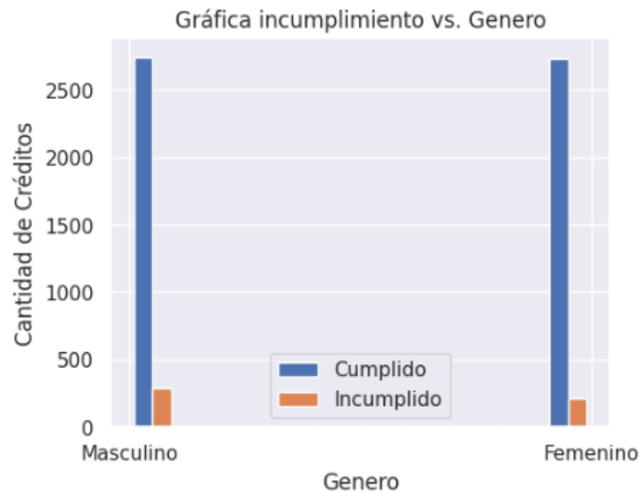
Variable incumplimiento vs. Edad (años)



Género: Como se observa en la figura 4 no existe mayor diferencia entre los créditos por género, por lo tanto, la variable no parece ser una buena predictora del modelo.

Figura 4

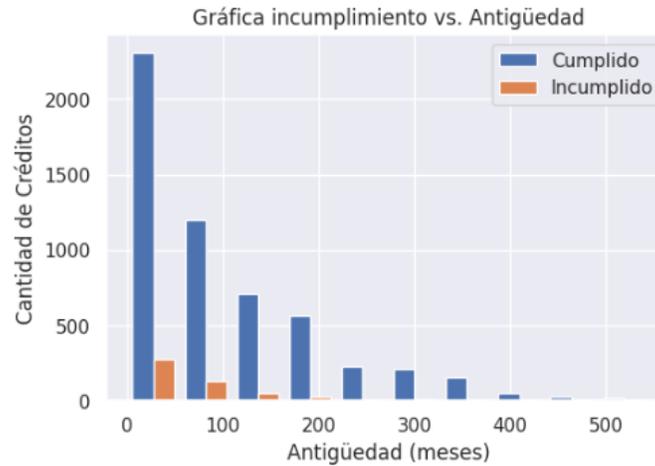
Variable incumplimiento vs. Género



Antigüedad: Como se observa en la figura 5 los créditos otorgados a clientes con más de 100 meses de antigüedad presentan menor incumplimiento, por lo tanto, la variable parece ser una buena predictora del modelo.

Figura 5

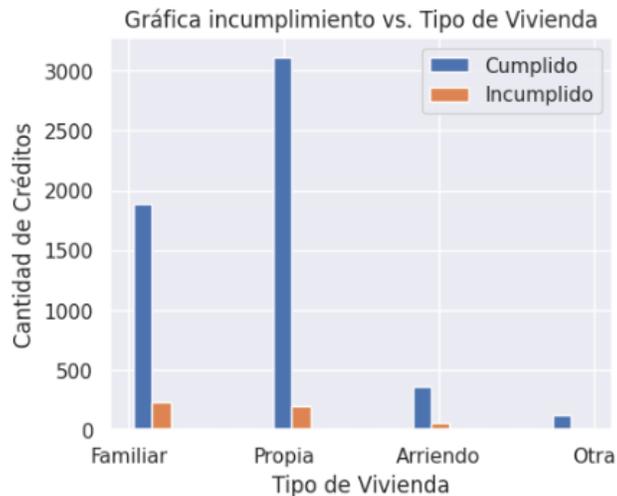
Variable incumplimiento vs. Antigüedad (meses)



Vivienda: Se observa en la figura 6 que los créditos de clientes con vivienda propia y familiar presentan mayor cantidad de créditos tanto cumplidos como incumplidos frente a los otros tipos de vivienda, por lo tanto, la variable parece ser una buena predictora del modelo.

Figura 6

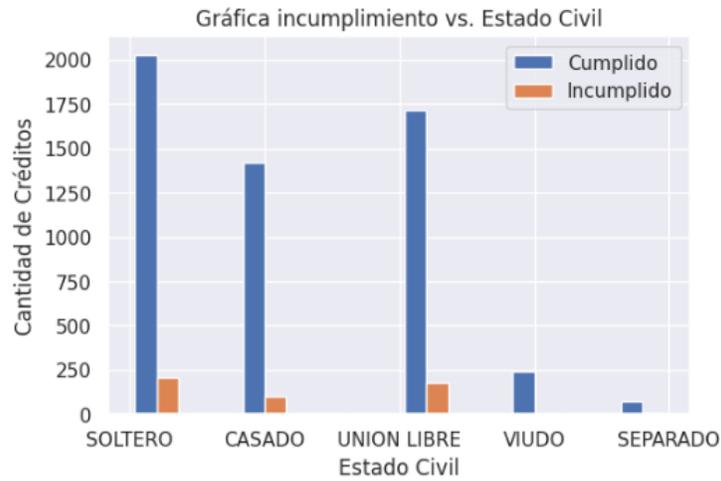
Variable incumplimiento vs. Tipo de Vivienda



Estado civil: Se observa en la figura 7 que los créditos otorgados a clientes con estado civil soltero y unión libre presentan mayor incumplimiento frente a los demás, por lo tanto, la variable parece ser una buen predictora del modelo.

Figura 7

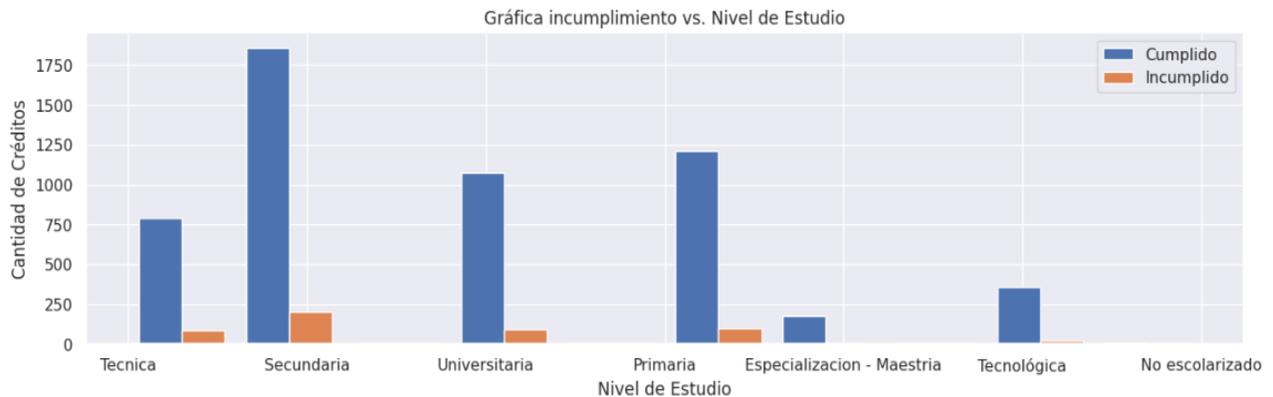
Variable incumplimiento vs. Estado Civil



Nivel de estudio: En la figura 8 se observa que los créditos otorgados a clientes con nivel de estudio secundaria presentan mayor cantidad de créditos con incumplimiento, por lo tanto, parece ser una buena predictora del modelo.

Figura 8

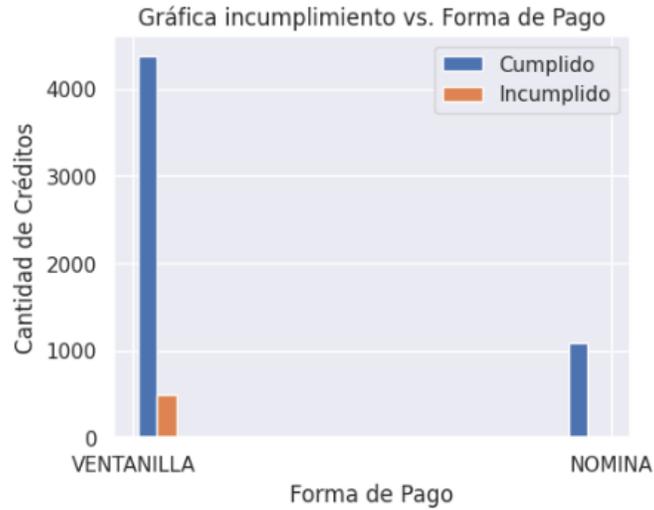
Variable incumplimiento vs. Nivel de Estudio



Forma de pago: Se observa en la figura 9 que los créditos que se pagan por nómina presentan incumplimiento muy bajo, con respecto a los que se pagan por ventanilla, por lo tanto, la variable parece ser una buena predictora del modelo.

Figura 9

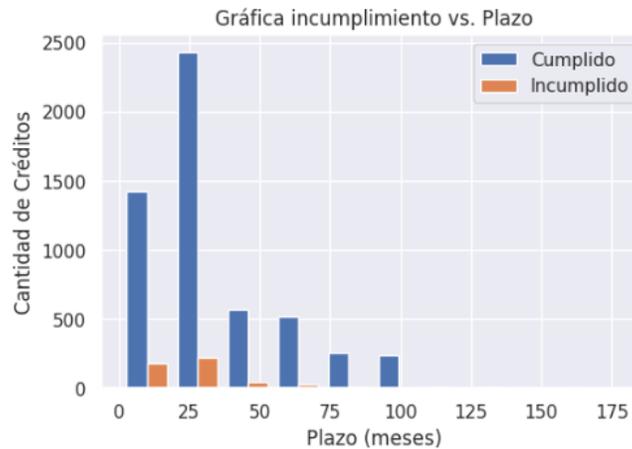
Variable incumplimiento vs. Forma de Pago



Plazo: Se observa en la figura 10 que los créditos con más de 40 meses de plazo presentan un menor incumplimiento, por lo tanto, parece ser una buena predictora del modelo.

Figura 10

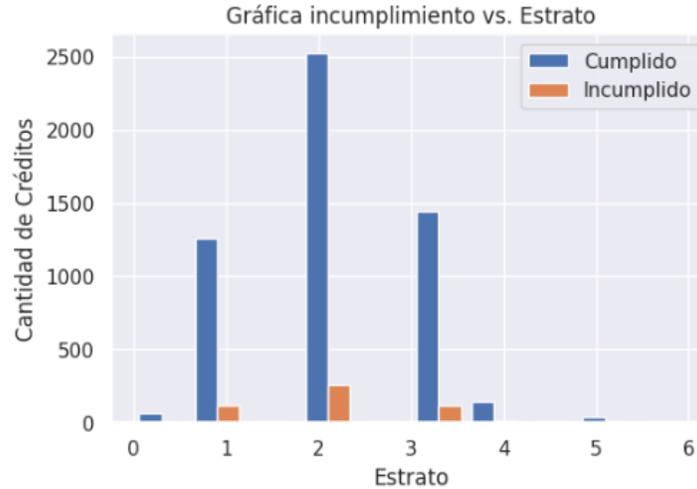
Variable incumplimiento vs. Plazo



Estrato: Se observa en la figura 11 que los créditos otorgados a clientes con estratos 1,2 y 3 presenta mayor incumplimiento, por lo tanto, la variable parece ser una buena predictora del modelo.

Figura 11

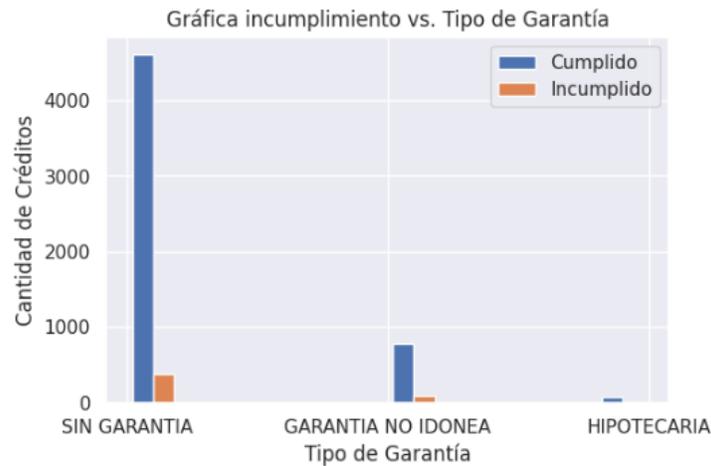
Variable incumplimiento vs. Estrato



Tipo de garantía: Se observa en la figura 12 que los créditos sin garantía presentan menor incumplimiento, mientras que los clientes con garantía no idónea e hipotecaria presentan mayor incumplimiento, lo cual, no tiene sentido y se decide no incluir la variable en el modelo.

Figura 12

Variable incumplimiento vs. Tipo de Garantía



Las siguientes variables se excluyen del modelo por ser calculadas en base a otras y pueden generar redundancia en el modelo:

- Total patrimonio corresponde a la diferencia entre los activos y pasivos
- Días de mora se utiliza para determinar si un cliente incumple con los pagos

- Clasificación de la cartera es una variable que se calcula con base en los días de mora del crédito
- LIBRANZA / SIN LIBRANZA es equivalente a pago por NOMINA / VENTANILLA de la variable forma de pago
- Saldo en mora está relacionado con la variable dependiente y con los días de mora
- La descripción de la actividad económica está relacionada con el código

Las siguientes variables se excluyen del modelo por no ser buenas predictoras del modelo según lo observado en el análisis exploratorio:

- Valor inmuebles solo cien (100) de los créditos otorgados a clientes tienen información en esta variable
- Valor vehículos todos tienen valor igual a cero (0)
- Tipo de persona presenta solo el valor "PERSONA NATURAL"
- Indicador de reestructuración presenta solo el valor de "NO"
- Código de la actividad económica presenta errores en la codificación del CIU y demasiadas categorías

3.3 Manipulación

Las variables total activos, total pasivos, ingresos mensuales, egresos mensuales y valor del crédito presentan outliers hacia la derecha, por lo tanto, se procede a realizar el análisis y la eliminación para aquellos que cuenten con 7 desviaciones o más por encima de la media.

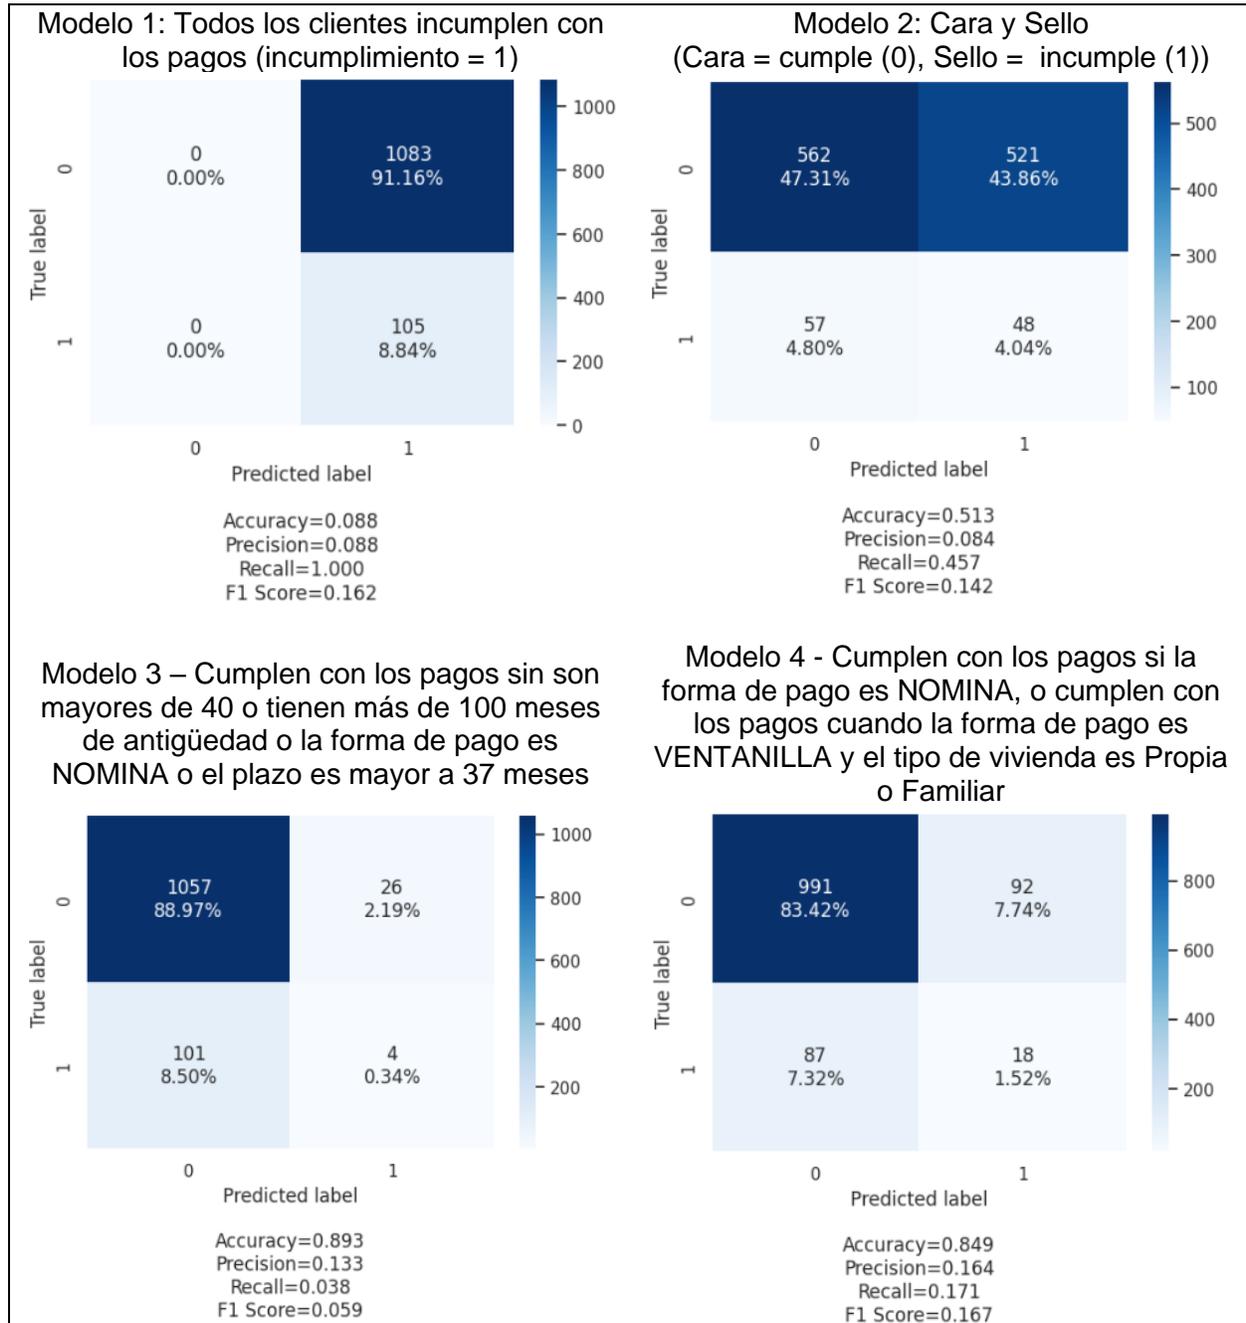
3.4 Modelado

3.4.1 Modelos basados en reglas

Se realizaron cuatro (4) modelos basados en reglas con una muestra de testeo del 20% del total de los registros. Los resultados se ilustran en la figura 13.

Figura 13

Resultados modelos basados en reglas



De acuerdo a la figura 13, el modelo basado en reglas No. 3 presenta el mejor desempeño con un accuracy de 0.893, precisión de 0.133, recall de 0.038 y F1 Score de 0.059, sin embargo, es un modelo que no es tan bueno identificando los verdaderos positivos.

3.4.2 Modelos Machine Learning

Teniendo en cuenta que la base de datos presenta desbalanceo de clases se realizaron diferentes modelos de clasificación con pycaret y aplicando el balanceo de clases con la librería imbalanced-learn versión 0.7.0 por temas de compatibilidad. Se definió para la base de datos de entrenamiento 80% y para la base de datos de testeo 20% y se obtuvo el mejor modelo teniendo en cuenta el AUC más alto ya que el accuracy es una métrica que no se comporta bien en clases desbalanceadas. Los modelos realizados fueron los siguientes:

- Modelo Machine Learning 1 sin balanceo de clases
- Modelo Machine Learning 2 balanceado con over sampling (sampling_strategy = "minority")
- Modelo Machine Learning 3 balanceado con under sampling (sampling_strategy = "majority")
- Modelo Machine Learning 4 balanceado con under sampling (NearMiss)
- Modelo Machine Learning 5 balanceado con estrategia combinada (resampling y smote-tomekunder sampling)
- Modelo Machine Learning 6 balanceado con ClusteringCentroids

3.5 Valoración

En la tabla 2 se presenta las métricas de los modelos que corresponden a estadísticos resumidos de validación cruzada.

Tabla 2

Comparativa de modelos con estadísticos de validación cruzada

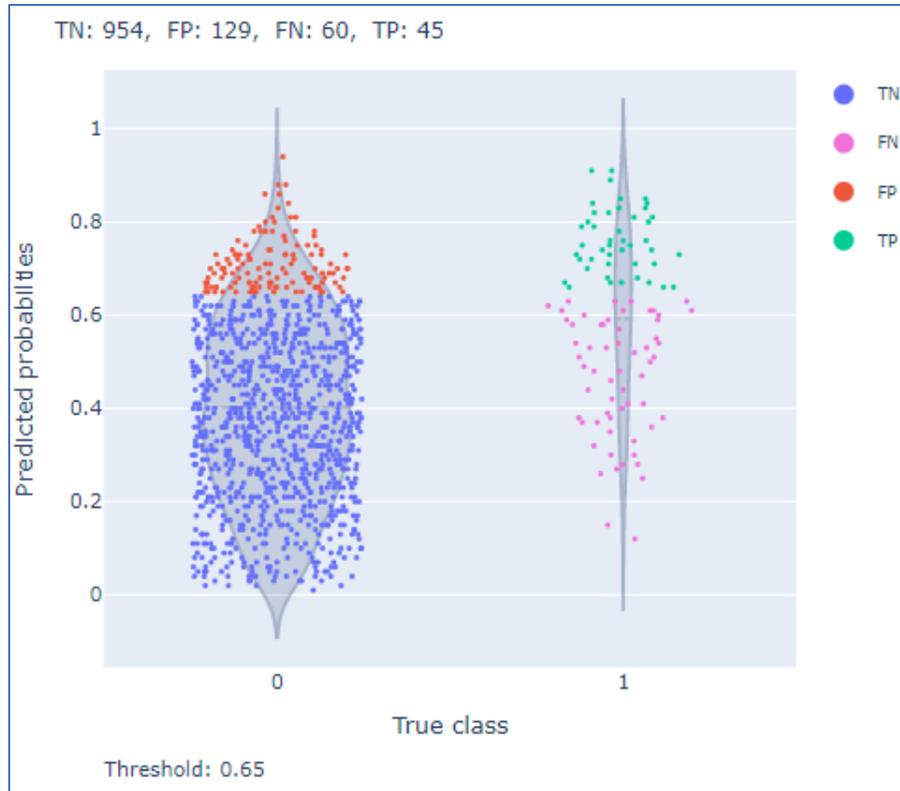
Descripción del Modelo	Accuracy	AUC	Recall	Precisión	F1 Score
Modelo 1: Todos los clientes incumplen con los pagos (incumplimiento = 1)	0.0880	---	1.0000	0.0880	0.1620
Modelo 2: Cara y Sello	0.5130	---	0.4570	0.0840	0.1420

(Cara = cumple (0), Sello = incumple (1))					
Modelo 3 – Cumplen con los pagos sin son mayores de 40 o tienen más de 100 meses de antigüedad o la forma de pago es NOMINA o el plazo es mayor a 37 meses	0.8930	---	0.0380	0.1330	0.0590
Modelo 4 - Cumplen con los pagos si la forma de pago es NOMINA, o cumplen con los pagos cuando la forma de pago es VENTANILLA y el tipo de vivienda es Propia o Familiar	0.8490	---	0.1710	0.1640	0.1670
Modelo Machine Learning 1 sin balanceo de clases - Light Gradient Boosting Machine	0.9252	0.8027	0.1248	0.5939	0.2026
Modelo Machine Learning 2 balanceado con over sampling - Light Gradient Boosting Machine	0.9011	0.7852	0.3103	0.3687	0.3353
Modelo Machine Learning 3 balanceado con under sampling – Light Gradient Boosting Machine	0.6785	0.7550	0.7111	0.1587	0.2592
Modelo Machine Learning 4 balanceado con under sampling NearMiss – Extra Trees Classifier	0.3766	0.6800	0.8677	0.1012	0.1813
Modelo Machine Learning 5 balanceado con estrategia combinada – Light Gradient Boosting Machine	0.9161	0.7935	0.1182	0.4077	0.1803
Modelo Machine Learning 6 balanceado con Cluster Centroids – Regresión Logística	0.5156	0.6931	0.8355	0.1236	0.2151

El modelo seleccionado fue el modelo 3 Light Gradient Boosting Machine balanceado con la estrategia under sampling debido a que presenta un AUC de 0.7550, recall de 0.7111 y una precisión de 0.1587.

Figura 14

Diagrama de violín del modelo seleccionado con threshold = 0.65



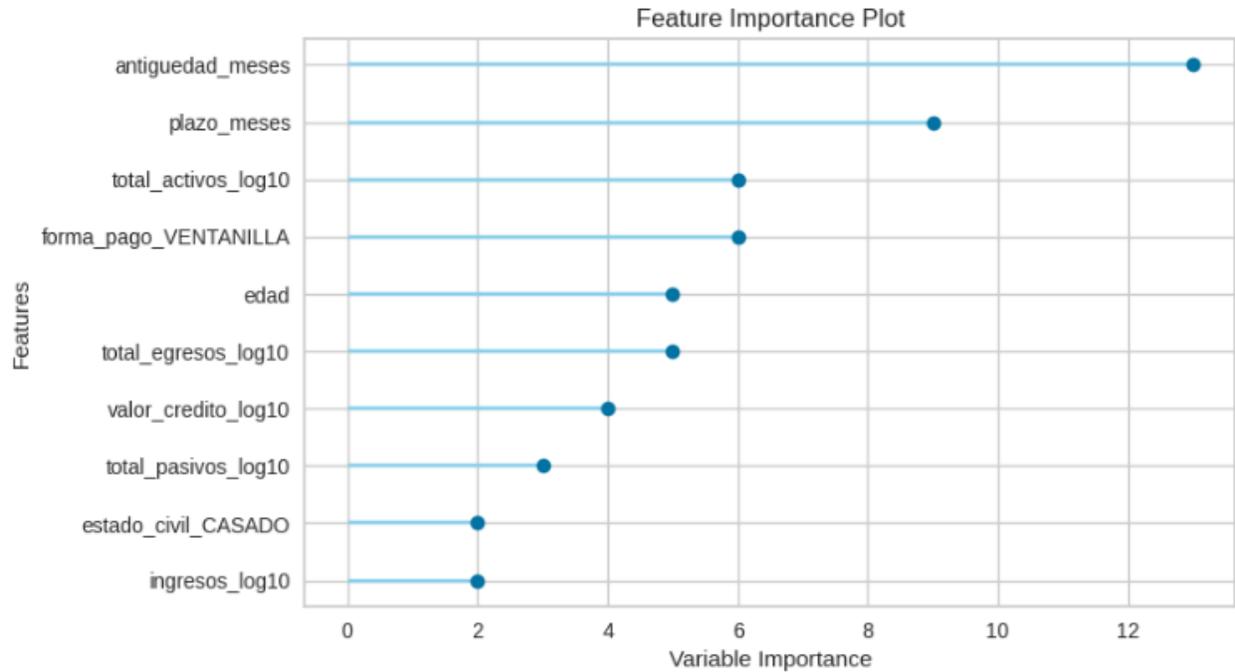
Como se observa en la figura 14 en la medida que se aumenta el threshold la tasa verdaderos positivos y falsos positivos disminuye mientras que la tasa de verdaderos negativos y falsos negativos aumenta.

4. CONCLUSIONES

De acuerdo a la figura 15 las variables más importantes que predicen la probabilidad de incumplimiento de un cliente son antigüedad, plazo, total activos, forma de pago, edad, egresos mensuales, valor del crédito, total pasivos, estado civil e ingresos mensuales.

Figura 15

Variables de mayor importancia para inferir el cálculo de la probabilidad de incumplimiento



El balanceo de clases mejora el recall de los modelos de manera notable debido a que equilibran las predicciones de la clase minoritaria, es decir, disminuye la tasa de verdaderos negativos.

Si tenemos en cuenta los créditos con más riesgo de pérdida, es decir, aquellos que se encuentran con calificación de cartera C, D y E (414 en total), la entidad dejaría de perder en promedio 5.64 millones de pesos por cada cliente bien identificado que tenga una probabilidad de incumplimiento mayor al 65% de acuerdo al umbral de la figura 14.

5. REFERENCIAS BIBLIOGRÁFICAS

- Moreno Valencia, S. (2013). El Modelo Logit Mixto para la construcción de un Scoring de Crédito. Repositorio Institucional Universidad Nacional de Colombia. Recuperado 10 de septiembre de 2022, de <https://repositorio.unal.edu.co/bitstream/handle/unal/74977/43596322.2014.pdf?sequence=1&isAllowed=y>
- Caicedo Carbonell, M. C. (2018). Scoring de crédito: herramienta para la evaluación de riesgo de crédito en entidades financieras. Repositorio Institucional - Pontificia Universidad Javeriana. Recuperado 10 de septiembre de 2022, de <https://repository.javeriana.edu.co/bitstream/handle/10554/35569/PROYECTO%20DE%20GRADO.pdf?sequence=4&isAllowed=y>
- Arriba Rimassa, J. L. & Montalvo Lima, O. D. (2020). Implementación de un Modelo de Credit Scoring para créditos de consumo aplicado para Entidades de la Economía Popular y Solidaria. Repositorio Digital - Universidad Central del Ecuador. Recuperado 10 de septiembre de 2022, de <http://www.dspace.uce.edu.ec/handle/25000/19348>
- Quiroz Calderón, M. B., Torres Guzmán, R. M., Montano Barbuda, J. J., Torres García, L. A., & Rubio Cabrera, W. F., (2022). Credit scoring como alternativa para minimizar riesgo de crédito en instituciones microfinancieras en COVID-19. Revista Universidad y Sociedad, 14(S3), 376-385. Recuperado 10 de septiembre de 2022, de <https://rus.ucf.edu.cu/index.php/rus/article/view/2967/2922>.
- Guevara Castro, V. M. & Moreno Noriega, M. J. (2020). Modelo de scoring para aprobación de créditos para la cartera de consumo, en una cooperativa de aporte y crédito colombiana. Repositorio Institucional - Pontificia Universidad Javeriana. Recuperado 10 de septiembre de 2022, de <https://repository.javeriana.edu.co/handle/10554/50785>
- Cano Bedoya, J. (2021). Aprendizaje supervisado en la construcción de un modelo de Credit Scoring para cooperativas de ahorro y crédito en Colombia. Repositorio Institucional - Universidad Nacional de Colombia. Recuperado 10 de septiembre de 2022, de <http://repositorio.unal.edu.co/handle/unal/81003>
- Cordero, B. (2021, noviembre). Working capital credit evaluation model using Python language applied to public banking: Case study in a shrimp project. Research Gate. Recuperado 10 de septiembre de 2022, de https://www.researchgate.net/publication/356568835_Working_capital_credit_evaluation_model_using_Python_language_applied_to_public_banking_Case_study_in_a_shrimp_project
- Gómez Henao, J. P. (2021). Modelo de scoring para el otorgamiento de crédito a personas naturales. Biblioteca Universidad EIA de <https://repository.eia.edu.co/handle/11190/3385>

Superintendencia de Economía Solidaria. (2021). Circular Básica Contable y Financiera - Título IV Sistema de Administración de Riesgos - Capítulo I Sistema Integrado de Administración de Riesgos – SIAR. Obtenido de https://www.supersolidaria.gov.co/sites/default/files/public/data/capitulo_i_sistema_integrado_de_administracion_de_riesgos_-_siar_0.pdf

Superintendencia de Economía Solidaria. (2021). Circular Básica Contable y Financiera - Título IV Sistema de Administración de Riesgos - Capítulo II Sistema de Administración de Riesgo de Crédito– SARC. Obtenido de https://www.supersolidaria.gov.co/sites/default/files/public/data/capitulo_ii_sistema_de_administracion_del_riesgo_de_credito_-_sarc_0.pdf