

**DISEÑO DE UNA ESTRATEGIA PARA LA GESTIÓN DE COBRANZA, A TRAVÉS DE
BIG DATA ANALYTICS EN EMPRESAS DE VENTA POR CATÁLOGO**

Autora

Lina María Mira Orozco

Asesora Metodológica

Alejandra García Cardona, PhD (c)

Universidad de Medellín

Maestría en Administración-MBA

Medellín

2020

Tabla de Contenido

1. Resumen	4
2. Abstrac.....	5
3. Introducción.....	6
4. Problema de Investigación.....	9
Pregunta de investigación.....	9
5. Justificación.....	10
6. Objetivos.....	11
6.1 Objetivo General	11
6.2 Objetivos Específicos.....	11
7. Diseño Metodológico.....	12
7.1 Metodología	12
8. Estado del Arte.....	14
9. Marco Conceptual	21
9.1 Venta por Catálogo.....	21
9.2 Gestión de Cobranza	22
9.3 Herramientas de Analítica.....	22
9.4 Business Analytics	24
9.5 Big Data.....	25
9.6 Big Data Analytics	25
10. Diseño De La Estrategia De Gestión De Cobranza, A Través De Big Data Analytics En Empresas De Venta Por Catálogo	27
10.1 Categoría 1: <i>Otorgamiento Del Crédito</i>	27
10.2 Categoría 2: <i>Seguimiento Al Comportamiento Del Uso Del Crédito</i>	30
10.3 Categoría 3: <i>Recuperación Del Crédito</i>	32
10.4 <i>Modelo Estrategia Gestión De Cobranza A Través De Big Data Analytics</i>	34
11. Conclusiones y Recomendaciones	37
12. Bibliografía.....	39
13. Anexos.....	46
13.1 Análisis Bibliométrico.....	46

13.2	13.2 Análisis Sistemático de Literatura.....	47
------	--	----

1. Resumen

Este trabajo del MBA presenta un diseño de la estrategia de gestión de cobranza a través de Big Data Analytics, en empresas de Venta por Catálogo. La metodología empleada para lograr el objetivo del trabajo consiste en una revisión sistemática de literatura y un análisis cualitativo, con el fin de identificar, describir, profundizar y finalmente divulgar la estrategia. Es así como el método de investigación se empleó de la siguiente forma: (1) Planear el protocolo de revisión; (2) Identificación y clasificación de literatura orientada al objeto de estudio; (3) Descripción de literatura de la evolución del objeto de estudio, y (4) finalmente, la entrega de resultados. Como resultado se diseña la estrategia de gestión de cobranza a través de Big Data Analytics en empresas de Venta por Catálogo, en tres categorías enmarcadas en el ciclo de vigencia del crédito: (1) *Otorgamiento del crédito*, (2) *Seguimiento al Comportamiento del uso del crédito* y (3) *Recuperación del crédito*. Asimismo, el trabajo es un buen ejemplo de cómo emplear estas estrategias en empresas orientadas al desarrollo del canal comercial, lo cual asegura crecimiento, pero al mismo tiempo protege la estructura financiera de la empresa, pues permite segmentar los perfiles de los clientes, y genera estrategias customizadas de acuerdo con el riesgo, de tal forma que minimice la probabilidad de pérdida de la empresa. (la probabilidad de pérdidas que podría tener la empresa).

Palabras Clave

Gestión de Cobranza, Riesgo, Probabilidad de Incumplimiento, Probabilidad de Pago, Herramientas de Analítica, Big Data Analytics, Machine Learning, Venta por Catálogo.

2. Abstrac

The present study of MBA seeks to design a collection management strategy using Big Data Analytics implemented in Direct Selling Companies. The methodology used to achieve the main objective is based on a systematic literature review and a qualitative analysis, in order to identify, describe, deepen and communicate the final strategy. The research method was applied in four core activities: (1) Planning the review protocol ; (2) Identification and classification of literature approach to the object of study; (3) Literature description of the evolution of the study and finally (4) Results. As a result, the strategy design model applied in Collections management through Big Data Analytics in Direct Selling companies, the model design was divided into three categories focused on the credit cycle (1) *Credit Granting*, (2) *Credit Use Behavior* and (3) *Credit Recovery*. Likewise, this study is a good example of how to use these strategies in companies oriented to the development of the commercial channel, which ensure growth, but at the same time protect the financial structure of the company, by segmenting customer profiles, generating personalized strategies according to the risk, thus minimizing the possibility of loss of the company.

Key Words

Collection Management, Risk, Probability of Default, Probability of Payment, Analytical Tools, Big Data Analysis, Machine Learning, Direct Selling.

3. Introducción

En un mercado que cada vez es más competitivo para las compañías, las diferentes estrategias de otorgamiento de crédito se han convertido en una forma clave de incrementar e incentivar las ventas (Izar & Ynzunza, 2017). De acuerdo con estos autores esta situación genera un incremento en las cuentas por cobrar de la compañía, así como el riesgo de tener cuentas incobrables.

El incremento de cuentas por cobrar provoca que las compañías se queden sin los recursos necesarios para operar, incluso las lleva a tener problemas financieros (Antonio & Castro, 2014; Mili et al., 2018). Al respecto, Izar & Ynzunza (2017) mencionan que una compañía debe definir políticas de crédito y cobranza eficientes, con el fin de mitigar el crecimiento de cuentas por cobrar, pues de no hacerlo, no lograría convertirlas en dinero efectivo. Por esta razón, la *gestión de cobranza* desempeña un papel clave en el ámbito empresarial, puesto que permite que la compañía minimice el riesgo de pérdida, impactando la estabilidad financiera (Moradi & Mokhtab Rafiei, 2019; De Paula et al., 2019).

Adicional a lo anterior, el acuerdo de Basilea definió las condiciones para que las entidades financieras previnieran la pérdida asociada al otorgamiento del crédito (Gambetti, Gauthier, & Vrins, 2019). Esto a consecuencia de la crisis financiera del año 2008, los modelos de riesgo tomaron importancia, con el fin de reducir la probabilidad de insolvencia en entidades financieras (X. Chen, Wang, & Zhang, 2019), lo que llevó a desarrollar sistemas de administración de riesgo que permitieran tomar decisiones con respecto al crédito (Velásquez, 2013).

De acuerdo con Óskarsdóttir et al. (2019) la administración del riesgo condujo a desarrollar modelos de calificación crediticia, la cual es una de las aplicaciones de analítica más antiguas. La calificación crediticia permite a las entidades financieras evaluar los clientes de acuerdo con sus características para decidir si otorgan un crédito y en qué condiciones.

Los modelos de administración del riesgo fueron construidos con limitaciones en los datos, observaciones y con técnicas simples de clasificación. Por esta razón, en los últimos años se han desarrollado técnicas estadísticas para mejorar el desempeño de los modelos de calificación crediticia (Óskarsdóttir et al., 2019).

En los últimos años aparecieron técnicas de clasificación crediticia sofisticadas, como por ejemplo redes neuronales, máquinas de vectores, árboles de decisión, todos orientados a la mejora del desempeño de la calificación crediticia. Sin embargo, de acuerdo con Óskarsdóttir et al. (2019) estas técnicas deben ser utilizadas a través de las nuevas fuentes de información, es el caso del *Big Data Analytics*, con el fin de crear calificaciones crediticias de alto desempeño.

De acuerdo con Davenport (2014), estas *herramientas analíticas* han evolucionado para soportar la toma de decisiones, el soporte gerencial, el procesamiento de información, pasando por el *Business Intelligence*, *Business Analytics*, *Big Data* y ahora, como evolución de las mismas, el *Big Data Analytics*. Por esta razón, han sido implementadas para definir modelos de gestión relacionados con la administración del riesgo para soportar la gestión de cobranza, especialmente en entidades financieras como los bancos.

Es así como Tsao (2017) afirma que el *Big Data Analytics* ayuda a las empresas que otorgan créditos por sus bienes y/o servicios a mitigar el riesgo de incumplimiento de pago de un cliente, pues es claro que el crédito con usos comerciales, donde el cliente puede adquirir productos o servicios sin un pago previo, incrementa el riesgo de pago tardío, o incluso del no pago.

En este contexto, Bumacov et al. (2017) afirman que el análisis de comportamiento de pago de los clientes y calificación crediticia a través de *Herramientas de Analítica* aplica para todas las empresas que utilicen el crédito como incentivo comercial. Debido a lo anterior, Ferrell & Ferrell (2012) aseguran que las empresas de *venta por catálogo* se enfocan en el desarrollo del canal de ventas, pues son consideradas como empresas de *Social Networking Business*. En este contexto, Bumacov et al. (2017) y Onay & Öztürk (2018) afirman que las empresas que utilizan el crédito como incentivo comercial, presentan flexibilidad en el esquema de otorgamiento de crédito.

A su vez, Ferrell & Ferrell (2012) mencionan que la *venta por catálogo*, al ser un negocio que representa más de USD\$ 114 billones en el mundo y por más de 150 años, ha incrementado significativamente el número de Vendedores Independientes, lo que de acuerdo con Mili et al. (2018) y Stanworth et al. (2004) genera un incremento en el otorgamiento de crédito, aumentando así el riesgo de no pago.

Así mismo, Antonio & Castro (2014) sugieren que las empresas que se enfocan en el desarrollo de la estrategia de venta tienden a descuidar la gestión de cobranza de las cuentas por cobrar. Por esta razón, Gitman et al. (2007) afirman que la *gestión de cobranza* se convierte en un punto crucial, pues de acuerdo con los autores Stanworth et al. (2004) y Ferrell & Ferrell (2012) al tener las empresas de *Venta por Catálogo* un claro enfoque en el desarrollo comercial de su canal de venta, ocasiona retos adicionales, debido a que su incremento de las ventas está dado por el incentivo del crédito comercial (Tsao, 2017; Izar & Ynzunza, 2017).

En este contexto, esta propuesta de proyecto de grado consiste en *diseñar la estrategia de la gestión de cobranza, a través de Big Data Analytics en empresas de Venta por Catálogo.*

4. Problema de Investigación

Dada la alta competitividad del mercado, las empresas han incrementado el uso del crédito con el fin de promover e incrementar sus ventas. Esto genera que los clientes administren su flujo de efectivo de corto plazo, retrasando el pago de algunas de sus obligaciones (Tsao, 2017). Sin embargo, debido al riesgo del incumplimiento en los pagos por parte de los clientes (Jiang, Wang, & Zhao, 2019) y a la creciente demanda por los créditos, las empresas se ven obligadas a implementar estrategias de gestión de cobranza a través de la calificación crediticia (Bumacov et al., 2017).

En consecuencia, con el fin de evitar impactos financieros, las empresas se enfocan en desarrollar sistemas de administración del riesgo (Velásquez, 2013), asegurando una gestión de cobranza adecuada, a través de la identificación, comprensión, medición y definición de estrategias para mitigar los riesgos (Moradi & Mokhatab Rafiei, 2019).

Por lo anterior, y debido a que las empresas de *Venta por Catálogo* tienen un claro enfoque en el desarrollo de la estrategia de ventas (Stanworth et al., 2004), este enfoque hace que las empresas descuiden la gestión de cobranza (Antonio & Castro, 2014), lo que ocasiona un alto riesgo para las empresas en su estructura financiera (Mili et al., 2018).

Con base en lo anterior se plantea lo siguiente:

Pregunta de investigación

¿Qué pueden hacer las empresas de *Venta por Catálogo* para gestionar su cartera de forma eficiente, con el fin de minimizar el riesgo financiero de la empresa?

5. Justificación

A consecuencia de la crisis financiera del año 2008, los modelos de riesgo tomaron importancia, con el fin de reducir la probabilidad de insolvencia en entidades financieras (X. Chen, Wang, & Zhang, 2019). Por lo anterior se desarrolló el acuerdo de Basilea, el cual definió las condiciones para que las entidades financieras previnieran la pérdida asociada al otorgamiento del crédito (Gambetti, Gauthier, & Vrins, 2019)

En las últimas décadas, las empresas han empleado el crédito como herramienta comercial, y han conseguido así incrementar sus ventas (Kanapickiene & Spicas, 2019; Tsao, 2017). Lo anterior genera que los clientes administren su flujo de caja a corto plazo, empleándolo como instrumento para estimular las ventas (Tsao, 2017); sin embargo, esta flexibilidad origina que los clientes no logren cumplir con sus obligaciones de forma oportuna (Kanapickiene & Spicas, 2019; Tsao, 2017), incrementando el riesgo financiero para la empresa (Mili et al., 2018).

En consecuencia, las empresas desarrollan estrategias orientadas a la administración del riesgo (Óskarsdóttir et al., 2019). Por esta razón, las empresas desarrollan sus estrategias de gestión de cobranza a través del uso de herramientas especializadas, como el *Big Data Analytics*, pues permite mejorar el desempeño de la administración del riesgo, a través de la identificación y segmentación de los clientes de acuerdo con el riesgo que generan por el incumplimiento del pago durante el ciclo completo del crédito (Hung, He, & Shen, 2020).

Las empresas de Venta por Catálogo poseen un enfoque claro en el desarrollo del canal de ventas (Ferrell & Ferrell, 2012), y además generan empleo informal a más de 20 millones de personas en el mundo, incrementando la cantidad de Vendedores Independientes año tras año (Harrison & Hair, 2017). Se convierte entonces en un factor relevante el uso de *Big Data Analytics*, con el fin de analizar y mejorar la toma de decisiones con respecto al riesgo financiero que generan sus clientes (J. L. Hung et al., 2020; Mili et al., 2018), a través de la estimación del comportamiento de pago, y asegurar de este modo un ofrecimiento del *Crédito* cuidadoso y eficiente (Ala'raj, Abbod, & Radi, 2018).

6. Objetivos

6.1 Objetivo General

Diseñar la estrategia de la gestión de cobranza a través de Big Data Analytics en empresas de venta por catálogo.

6.2 Objetivos Específicos

- Establecer el estado actual de la gestión de cobranza.
- Identificar el uso de las herramientas de analítica en la gestión de cobranza.
- Plantear la estrategia de la gestión de cobranza a través de Big Data Analytics en empresas de venta por catálogo.

7. Diseño Metodológico

Este estudio se llevó a cabo con base en el enfoque de análisis cualitativo y de revisión sistemática de literatura propuesta por Pérez Rave (2013). El cual consiste en identificar, describir, profundizar y finalmente divulgar. La metodología propuesta por Pérez Rave (2013) cuenta con un enfoque por procesos enmarcados en el ciclo PHVA.

El método de investigación se empleó de la siguiente forma: (1) Planear el protocolo de revisión; (2) Identificación y Clasificación de literatura orientada al objeto de estudio; (3) Descripción de literatura de la evolución del objeto de estudio y (4) finalmente la entrega de resultados.

7.1 Metodología

La ejecución del método de investigación se orientó a la búsqueda de artículos científicos relacionados con el objeto de estudio, sus características y el medio. Para esto, se definieron términos de búsqueda que relacionarán las empresas de *Venta por Catálogo* como Objeto de estudio, la *Gestión de Cobranza* como característica y el *Big Data Analytics* como medio de guía para la *gestión de cobranza*.

Los términos definidos se incorporaron para realizar inicialmente un análisis bibliométrico en *Web of Science*. El algoritmo definido para la búsqueda es el siguiente:

Bad debt OR credit scoring OR credit risk OR debt default OR credit default OR collections process OR collections scoring OR collections strategy AND social selling OR direct selling OR mail order industry AND analytics OR business analytics OR big data OR data mining OR business intelligence OR machine learning

Adicionalmente, se ejecutó la búsqueda con los siguientes filtros: Sólo título, 5 años, Sólo artículos, Categorías: *Business Finance*, *Business*, *Management*, *Economics*, lo que arrojó como resultado 630 artículos.

De los 630 artículos, se procedió a revisar los títulos y los resúmenes en aras de asegurar que el artículo respondiera al problema de investigación, resultando en 41 artículos que sirven de base para evidenciar la evolución de la *Gestión de Cobranza a través del Big Data Analytics*.

Para continuar con la revisión de los artículos resultantes, se realizó un análisis sistemático de literatura, con el fin identificar los artículos relevantes que soporten el objeto de estudio a través de la metodología IMRYD (introducción, materiales y métodos, resultados, y discusión)(Pérez Rave, 2013).

Con base en la revisión sistemática, se describe la importancia de la gestión de cobranza para las empresas que utilizan el ofrecimiento de créditos a los clientes. Así mismo, como la innovación financiera ha avanzado hasta llegar a herramientas como el *Big Data Analytics*, que permiten administrar el riesgo del crédito, con el fin de evitar el impacto financiero de las empresas.

Finalmente, fundamentados en los estudios realizados, se *diseña la estrategia de cobranza a través del Big Data Analytics, para emplearse en empresas de Venta por Catálogo*.

8. Estado del Arte

La gestión de cobranza de las cuentas por cobrar se convierte en un factor crítico para las empresas. Para Gitman et al. (2007) una cuenta por cobrar se refiere al dinero que representa las deudas de los clientes, provenientes de ventas a crédito. Estas cuentas por cobrar corresponden a una parte importante de los activos corrientes de las compañías, razón por la cual Izar & Ynzunza (2017) aseguran que dichos rubros se deben administrar de forma apropiada para que cumplan la función de incrementar las ventas sin que su costo financiero se eleve.

Para la recuperación rápida y efectiva de la cartera, sin afectar las ventas, Gitman et al. (2007) sugieren tres etapas para la gestión de dicha recuperación: selección y administración del riesgo crediticio, condiciones del crédito y supervisión del crédito. En efecto, (Chijoriga, 2011) argumenta que las fallas en las empresas se deben a una gestión ineficiente de las cuentas por cobrar, debido a una inadecuada evaluación y calificación de los clientes. En este sentido, Izar & Ynzunza (2017) mencionan que es fundamental definir políticas de crédito y cobranza eficientes, que le permitan seleccionar de forma adecuada los clientes, con el fin de convertir posteriormente las cuentas por cobrar en dinero efectivo; de lo contrario, puede conducir a la empresa a problemas financieros y, en algunos casos, a la quiebra (Antonio & Castro, 2014).

Antonio & Castro (2014) argumentan que para una correcta gestión de las cuentas por cobrar se deben tener en cuenta aspectos como: variables económicas, regulaciones del sector, comportamiento del mercado, herramientas de gestión y estrategias a utilizar; así mismo es fundamental el conocimiento de los clientes. De esta manera, las empresas deben reaccionar de forma rápida y alineada, a través del desarrollo de estrategias que le permitan administrar de forma eficiente la cobranza.

En esta dirección, Izar & Ynzunza (2017) proponen que la gestión de cobranza de las cuentas por cobrar debe estar asociada a la administración del riesgo, pues de no hacerlo las cuentas por cobrar se incrementarían, con impacto directo no solo en el uso del capital de trabajo, sino también en los costos de mantenimiento, de gestión y, en consecuencia, el deterioro en el valor de la compañía.

Para este propósito, Bülbül et al. (2019) evidencian cómo la evolución tecnológica ha propuesto innovaciones financieras para acceder en forma rápida a la información crediticia de los clientes.

Estas innovaciones también crean políticas para la administración del riesgo. Políticas que se implementan con mayor regularidad en el otorgamiento de crédito porque permiten a las empresas cuantificar y administrar el riesgo crediticio, de tal forma que puedan tomar decisiones de forma rápida y objetiva.

En consecuencia, surge la calificación de crédito, que como lo mencionan Carta et al. (2020), es el principal objetivo de la evaluación de nuevos clientes para el otorgamiento de un crédito, en términos de su potencial confiabilidad. Por su parte, Leonard (1995) argumenta que esta calificación permite segmentar y analizar las diferentes variables relacionadas con el comportamiento de los clientes. Además, afirma que para el desarrollo de la calificación se utilizan análisis estadísticos que reúnen información histórica de los clientes. Estos análisis determinan variables financieras, económicas y de desempeño que son importantes para el proceso de valoración. Más aún, Chijoriga (2011) arguye que esta calificación de crédito calcula la probabilidad de incumplimiento de pago (luego de otorgar el crédito) y clasifica a los clientes, lo que arroja una información confiable para determinar la importancia del riesgo crediticio.

Antoine & Abdallah (2006) mencionan que las calificaciones de riesgo crediticio son cada vez más comunes en las empresas, pues permiten identificar comportamientos asociados al uso del crédito otorgado y como resultado mitigar el riesgo de pérdidas debido al incumplimiento de los clientes. Adicionalmente, Carta et al. (2020) sostienen que la calificación de crédito ayuda a disminuir pérdidas debido al no pago de los créditos, por lo cual representa un instrumento crucial para las empresas. Por lo anterior, Antoine & Abdallah (2006) afirman que una de las mayores preocupaciones de las empresas es la gestión de cobranza, porque el cliente puede pagar, o no, en el tiempo límite.

De acuerdo con lo mencionado por Anderson (2007), la segmentación es utilizada por las empresas para agrupar sus clientes con orientación a la oferta de producto “marketing”; sin embargo, la segmentación es una estrategia que también es utilizada para la clasificación del crédito. De acuerdo con Bijak & Thomas (2012), la estrategia de segmentación es definida en la calificación crediticia como el proceso de identificar en una población características homogéneas, que permiten predecir su comportamiento. Con base en esto, Anderson (2007) define que la estrategia de segmentación sirve para mejorar la evaluación, ofertas de producto adecuadas en términos de crédito, plazo de pago, garantías y predecir el comportamiento de pago. Por esta razón, Bijak &

Thomas (2012) aseguran que la estrategia de segmentación es actualmente utilizada por las entidades crediticias debido a sus beneficios, pues les permite personalizar el trato y la toma de decisiones con respecto al crédito.

Por su parte, Higginson et al. (2019) aseguran que la segmentación es utilizada también para segmentar no sólo con base a los días de mora del cliente, sino también de acuerdo con el comportamiento de pago y a su riesgo, con el fin de definir la estrategia de cobranza.

En esta dirección, Liebman (1972) desarrolló un modelo básico que determina las políticas de cobranza basadas en el cliente y en función del tiempo de vencimiento del crédito, con una técnica de enfoque dinámico, la cual es utilizada actualmente. Sin embargo, Antonio & Castro (2014) sostienen que para determinar las estrategias de gestión de cobranza se deben tener en cuenta múltiples aspectos y variables relacionadas con las características de los clientes y sus deudas, y así determinar estrategias adecuadas para cada segmento de clientes.

Al respecto, Antonio & Castro (2014) mencionan que las estrategias deben establecer la forma de cobrar, los criterios de la negociación, plazos de pago, descuentos, intereses o cargos por incumplimiento. No obstante, Thomas et al. (2012) sostienen que las estrategias utilizadas para la gestión de cobranza varían dependiendo del interés de la compañía. La razón estriba en que, si bien al inicio el interés va dirigido en mantener la relación con el cliente, una vez se identifica el riesgo potencial de incumplimiento de pago del cliente, el interés se concentra en la recuperación de la deuda.

En este sentido, Thomas et al. (2012) y Makuch et al. (1992) desarrollaron modelos para determinar el uso de los recursos destinados a la gestión de cobranza. Sin embargo, Antoine & Abdallah (2006) muestran cómo los estudios de la gestión de cobranza están orientados a la minimización de su costo y el tiempo máximo de tiempo en que se debe gestionar la deuda. Pero estos estudios evidencian que la gestión de cobranza tiene un enfoque simple direccionado al tipo de cliente y al tiempo de cumplimiento del pago de la obligación. Razones por las cuales Anderson (2007) argumenta que a medida que evolucionan las técnicas y aparecen nuevas necesidades para impulsar estrategias, es importante que se utilicen y desarrollen modelos de clasificación de los clientes; con esto se logra promover nuevos enfoques y eficiencias en los procesos.

Por lo anterior, Chen et al. (2019) mencionan que con la crisis financiera que se inició en el año 2008, los modelos de riesgo crediticio se volvieron importantes porque reducen la probabilidad de insolvencia en entidades financieras. Misma situación que sostienen Han & Jang (2013) porque manifiestan que históricamente la probabilidad de incumplimiento ha recibido más atención, que otros componentes de la gestión de cobranza, como por ejemplo la tasa de recuperación y la pérdida de dinero debido al incumplimiento. De hecho, Mili et al. (2018) aseguran que los modelos de calificación del riesgo crediticio se enfocan en la probabilidad de incumplimiento del crédito, más no en la probabilidad de recuperación de la cuenta por cobrar.

Chen et al. (2019) y Maldonado et al. (2018) afirman que para calcular el riesgo crediticio existen diversas herramientas predictivas, que sirven para modelar las tasas de recuperación de las cuentas por cobrar. De este modo se logra realizar una combinación de los diferentes modelos de calificación de riesgo, con lo cual se obtiene información relevante que apoye la toma de decisiones y la gestión de cobranza.

Al respecto de las técnicas clasificación, H. Chen et al. (2018) aseguran que existen oportunidades asociadas con la información y su análisis; por esto, las compañías han generado interés en herramientas de analítica como el *Business Analytics*. Esta herramienta incluye técnicas, tecnología, sistemas, prácticas y metodologías orientadas al análisis de información crítica dentro de una empresa con el fin de entender su comportamiento y tomar decisiones oportunamente. De hecho, Jalao (2015) argumenta que las empresas comenzaron a analizar su información histórica con el fin de diseñar estrategias que les permitan administrar de forma eficiente sus clientes, a través del uso de herramientas de analítica como el *Business Analytics*.

En este sentido, Jalao (2015) indica que el *Business Analytics* lo comprenden etapas como extracción y almacenamiento de información, modelos estadísticos y optimización. Este autor además afirma que con el uso de estos modelos las compañías no sólo pueden identificar el comportamiento de compra de sus clientes, sino que también pueden predecir el comportamiento de pago y la fidelización. En consecuencia, las investigaciones han evidenciado que el uso de *Business Analytics* mejora la toma de decisiones, pues los análisis entregados facilitan las decisiones y mejoran su desempeño (Griva et al., 2018).

El método de *Business Analytics* tiene un enfoque en el desarrollo de ideas, análisis del desempeño del negocio, a través del uso de modelos matemáticos y estadísticos que permiten entender, interpretar y predecir el comportamiento (Krishnamoorthi & Mathew, 2018).

Ahora bien, la evolución del *Business Analytics* es el *Big Data* (Davenport, 2014). Este último consiste en la recolección e interpretación de datos masivos, pero con la novedad de que incluye transmisiones digitales, como son, por ejemplo, las interacciones con sitios de compra e intercambio de información social, las cuales son analizadas por algoritmos inteligentes. Sin embargo, este método difiere de los métodos de analítica porque va más allá de entregar ideas y análisis que soporten la toma de decisiones (Davenport, 2014), y trabaja en descubrir nuevas oportunidades para personalizar productos y/o servicios orientados al perfil del cliente.

La evolución de las herramientas de análisis de información puede evidenciarse en la toma de decisiones, como base para el soporte gerencial (Davenport, 2014). Dicha evolución va desde la aparición del *Business Intelligence*, pasa por el *Business Analytics*, para transformarse en *Big Data* y ahora en *Big Data Analytics*. Por esta razón, han sido implementadas para definir modelos de gestión relacionados con la administración del riesgo a través de la calificación crediticia. Por ejemplo, Higginson et al. (2019) afirman que estas herramientas soportan la priorización y segmentación de acuerdo con el nivel de riesgo generado por la calificación de crédito. Este acercamiento a la calificación del riesgo está cambiando drásticamente la forma de gestión de cobranza, a través del desarrollo de estrategias hechas a la medida.

De su parte, Deloitte (2016) asegura que a través de las herramientas de analítica se pueden obtener beneficios para las empresas, debido a la integración de la analítica a la estrategia. Este autor asegura que la integración de las herramientas de análisis de información a la estrategia permite a la gestión de cobranza mejorar la tasa de recuperación de las deudas e identificar tendencias en el comportamiento de pago de los clientes que impacten la toma de decisiones.

Por estas razones, Crespo & Govindarajan (2018) mencionan que las innovaciones más relevantes en la gestión de cobranza están lideradas por las *herramientas de analítica* en combinación con *Machine Learning*. Estas innovaciones están transformando la gestión de cobranza hacia la era digital, mejores tasas de recuperación, menor costo de operación y mejores criterios de segmentación de clientes, cuyos resultados son las estrategias de cobranza más efectivas.

Adicionalmente, Hung et al. (2019) analizaron cómo entidades bancarias comerciales usan *Big Data Analytics* como herramienta para explorar el comportamiento de los clientes, con el fin de mejorar las finanzas de *Supply Chain* y la eficiencia de las campañas de marketing. Por otro lado, Davenport (2006) menciona que empresas como Amazon, Harrah's, Capital One y Boston Red Sox han implementado herramientas de *Analítica* en diferentes áreas, mejorando sus resultados.

Ahora bien, de acuerdo con Davenport (2006), diversas empresas han adoptado las herramientas analíticas, lo cual les ha permitido lograr un nivel de competitividad y liderazgo en varios sectores, como por ejemplo: finanzas, retail, viajes y entretenimiento, producción de productos, entre otros.

Al respecto, Óskarsdóttir et al. (2019) analizan cómo las entidades financieras utilizan herramientas de analítica para evaluar la solvencia económica de los posibles clientes, ayudándoles a definir el otorgamiento de los créditos. Además, los autores señalan cómo la evolución de las herramientas de analítica ha permitido combinar los análisis con la actividad digital de los clientes, generando mejoras significativas en el desempeño de las calificaciones crediticias. Por su parte, Hung et al. (2019) concluyen en su estudio que el *Big Data Analytics* es utilizado para mejorar el desempeño comercial de los bancos y la administración del riesgo de crédito.

En dicho sentido, Óskarsdóttir et al. (2019) analizan el comportamiento del *Big Data* en empresas de telecomunicaciones y entidades financieras, y llegan a la conclusión de cómo las herramientas de analítica mejoran el desempeño y generan un impacto positivo cuando se incluyen en las actividades financieras. Crespo & Govindarajan (2018) argumentan que, con el uso de herramientas de analítica, las entidades financieras pueden entender a un mayor nivel el comportamiento de sus clientes, a través de una segmentación especializada y, además, de unas estrategias de gestión de cobranza efectivas, diseñadas a la medida.

Hung et al. (2019), concluyen que el *Big Data Analytics* ha sido adoptado en la parte comercial de los bancos con el fin de segmentar los clientes de acuerdo con su perfil, buscando predecir su comportamiento.

Debido a lo anterior, Crespo & Govindarajan (2018) concluyen que empresas líderes en diversos sectores utilizan herramientas de analítica para desarrollar y optimizar los objetivos del negocio, pues les permiten mejorar el desempeño, a través de la implementación de estrategias de acuerdo con la realidad y necesidad de la empresa.

A pesar de los hallazgos, Hung et al. (2019) mencionan que el *Big Data Analytics* ha sido adoptado para el marketing en las entidades financieras enfocado en la segmentación y perfilamiento de clientes, con el objetivo de predecir la afinidad de productos y deserción de los clientes. Sin embargo, sugieren profundizar en otros análisis sofisticados como la detección del nivel de riesgo de los clientes.

Aunque Óskarsdóttir et al. (2019) evidencian que el *Big Data* y la *Analítica* presentan ventajas para las calificaciones de riesgo con el fin de predecir el comportamiento de pago de los clientes con las tarjetas de crédito; sin embargo, el estudio tiene limitaciones, pues se concentró en la información de clientes con tarjeta de crédito. Por esta razón, otro frente es analizar el comportamiento en otro tipo de crédito, como por ejemplo microcrédito e hipotecario.

Adicionalmente, Yadi et al. (2019) evidencian en sus estudios que el *Big Data* y la *Analítica* se han convertido en una dirección de referencia para el desarrollo de la gestión de cobranza, pues no solo reúne información relacionada con el crédito otorgado, sino que incorpora características del comportamiento de pago de los clientes. Aunque los autores aseguran que la evidencia no es suficiente, pues aún existen pocos estudios que analicen la gestión de cobranza en empresas no financieras.

9. Marco Conceptual

9.1 Venta por Catálogo

La venta por catálogo es un canal de ventas y distribución de productos, enfocado en productos cosméticos, aseo, hogar y salud (Stanworth et al., 2004). Este canal ha estado vigente por más de 150 años, el cual representa más de USD\$ 114 billones de ventas en el mundo. Por lo anterior, la venta por catálogo, al ser considerada un canal de distribución, no requiere tiendas físicas para ofrecer los productos a los consumidores. Esto genera que sea considerado un canal exitoso y de crecimiento para la empresas que utilizan los canales tradicionales, como el retail (Crittenden & Albaum, 2015).

La venta por catálogo funciona a través de vendedores independientes que trabajan desde su hogar, los cuales venden productos a través de sus conexiones sociales, pues este canal fue desarrollado sobre la premisa de aprovechar las redes sociales para crear oportunidades de ventas (Ferrell & Ferrel, 2012). De esta manera, las empresas de venta por catálogo ofrecen una oportunidad de trabajo a personas sin empleo formal, y generan más de 18.6 millones de empleos informales en el mundo (Peterson, Crittenden, & Albaum, 2019).

Las empresas de venta por catálogo se caracterizan por ser una oportunidad de trabajo para vendedores independientes, que trabajan exclusivamente por comisión de los productos vendidos (Stanworth et al., 2004), donde el perfil de su fuerza de ventas es un 80% mujeres, dedicadas a la venta por catálogo en el 50% de su tiempo (Crittenden & Albaum, 2015).

Aún más, la venta por catálogo ha sido reconocida mundialmente como una oportunidad de crecimiento en las ventas, donde se deben integrar la innovación de productos, campañas de mercadeo, programas comerciales y nueva tecnología que permita maximizar el crecimiento y mejorar la lealtad de los clientes a todos los niveles (Duffy, 2005).

Asimismo, las empresas de venta por catálogo han visto el negocio como un marketing competitivo para el crecimiento de sus ventas (Duffy, 2005). Este tipo de empresas, las cuales no tienen contacto con el consumidor final, se han incrementado en los últimos años, lo que genera no sólo

un crecimiento en el mercado, sino también un incremento y deterioro del monto de las cuentas por cobrar (Takahashi, Azuma, & Tsuda, 2015).

Debido a que las empresas de *Venta por Catálogo* tienen un claro enfoque en el desarrollo de la estrategia de ventas (Stanworth et al., 2004), este tipo de empresas tienden a descuidar la gestión de cobranza (Antonio & Castro, 2014), lo que ocasiona un alto riesgo para las empresas en su estructura financiera (Mili et al., 2018).

9.2 Gestión de Cobranza

Las cuentas por cobrar corresponden a una parte importante de los activos corrientes de las compañías. Estas cuentas se refieren al dinero que representan las deudas de los clientes, provenientes de ventas a crédito (Gitman et al., 2007). Razón por la cual dichos rubros se deben administrar de forma apropiada, para que cumplan la función de incrementar las ventas sin que su costo financiero se eleve (Izar & Ynzunza, 2017).

Al respecto, las fallas en las empresas son ocasionadas por una gestión ineficiente de las cuentas por cobrar, debido a una inadecuada evaluación y calificación de los clientes (Chijoriga, 2011).

En este sentido, es fundamental definir políticas de crédito y cobranza eficientes, que permitan seleccionar y segmentar de forma adecuada los clientes (Izar & Ynzunza, 2017), con el fin de convertir posteriormente las cuentas por cobrar en dinero efectivo; de lo contrario, puede conducir a la empresa a problemas financieros y, en algunos casos, a la quiebra (Antonio & Castro, 2014).

Con el fin de evitar impactos financieros, las empresas se enfocan en desarrollar sistemas de administración de riesgo, que les permita tomar decisiones con respecto a los créditos (Velásquez, 2013).

9.3 Herramientas de Analítica

Las herramientas de analítica corresponden a técnicas de clasificación sofisticadas, que han sido desarrolladas para mejorar el desempeño de los modelos estadísticos (Óskarsdóttir et al., 2019). Por esta razón, las herramientas de analítica son utilizadas por las empresas que recurren al crédito como herramienta para incrementar el volumen de las ventas (Velásquez, 2013) para administrar el riesgo (Óskarsdóttir et al., 2019).

La administración del riesgo conduce a desarrollar modelos de calificación crediticia, y se convierten en una de las aplicaciones de analítica más antiguas, pues permite a las entidades financieras evaluar los clientes de acuerdo con sus características para decidir si otorgan un crédito y en qué condiciones (Óskarsdóttir et al., 2019).

Por lo anterior, debido a la importancia de los modelos de calificación del crédito, en los últimos años han aparecido técnicas de clasificación crediticia sofisticadas, como por ejemplo las redes neuronales, máquinas de vectores, árboles de decisión, todos orientados a la mejora del desempeño de la calificación crediticia. Sin embargo, estas herramientas fueron desarrolladas con limitación en los datos, además de incluir técnicas simples de clasificación, tales como: programación lineal, análisis discriminantes y regresión logística (Óskarsdóttir et al., 2019).

Es así como las herramientas de analítica han evolucionado para soportar la toma de decisiones, el soporte gerencial, el procesamiento de información, integrando el *Business Intelligence*, *Business Analytics*, *Big Data* y, ahora, *Big Data Analytics*. Por esta razón han sido implementadas para definir modelos de gestión relacionados con la administración del riesgo (Davenport, 2014).

Así mismo, estas herramientas fueron complementadas por las nuevas fuentes de información que genera el *Big Data* y *Business Analytics*, con el fin de crear calificaciones crediticias de alto desempeño (Óskarsdóttir et al., 2019). Las mayores ventajas de implementar y utilizar estas herramientas de analítica están asociadas a la administración de la información, la cual contempla: alto volumen de datos (a alta velocidad), variedad de información, almacenamiento, veracidad, calidad y análisis, los cuales generan insumos para la toma de decisiones (Onay & Öztürk, 2018; Rialti et al., 2019; Santoro et al., 2019).

Estas nuevas herramientas de analítica traen un cambio disruptivo, pues no sólo pueden conocer el comportamiento de sus clientes, sino también cómo se comportan frente a sus competidores, lo que da como resultado mayor aceptación y penetración en empresas donde el crédito es un

impulsor de sus ventas, pues permiten monitorear el desempeño interno de los procesos, con el fin de definir acciones en tiempo real (Onay & Öztürk, 2018; Rialti et al., 2019). Lo que arroja como resultado segmentaciones, de acuerdo con el riesgo de los clientes (Jiang et al., 2019), las cuales permiten otorgar, aprobar, determinar límites, extender y realizar acciones de cobranza a los créditos generados, a través de la definición y ejecución de estrategias de acuerdo con el perfil de riesgo del cliente, asegurando así mitigar el riesgo financiero a través de la *gestión de cobranza* (Moradi & Mokhatab Rafiei, 2019; De Paula et al., 2019).

9.4 Business Analytics

Debido a las oportunidades asociadas con la información y su análisis, las empresas han generado interés en herramientas de analítica. El *Business Analytics* es considerado una herramienta que incluye técnicas, tecnología, sistemas, prácticas y metodologías orientadas al análisis de información crítica dentro de una empresa, con el fin de entender su comportamiento y tomar decisiones oportunamente (H. Chen et al., 2018). De esta manera, las empresas comenzaron a analizar su información histórica, con el propósito de diseñar estrategias que les permitan administrar de forma eficiente sus clientes (Jalao, 2015).

El *Business Analytics* lo comprenden etapas como extracción y almacenamiento de información, modelos estadísticos y optimización. El uso de esta herramienta les permite a las empresas no sólo identificar el comportamiento de compra de sus clientes, sino también predecir el comportamiento de pago y la fidelización de éstos (Jalao, 2015). En consecuencia, las investigaciones han evidenciado que el uso de *Business Analytics* mejora la toma de decisiones, pues los análisis entregados facilitan las decisiones y mejoran su desempeño (Griva et al., 2018).

La herramienta de *Business Analytics* tiene un enfoque en el desarrollo de ideas, análisis del desempeño del negocio, a través del uso de modelos matemáticos y estadísticos que permiten entender, interpretar y predecir el comportamiento (Krishnamoorthi & Mathew, 2018; Davenport, 2006).

9.5 Big Data

El *Big Data* consiste en la recolección e interpretación de datos masivos, pero con la novedad de que incluye transmisiones digitales, por ejemplo, las interacciones con sitios de compra e intercambio de información social, interacciones que son analizadas por algoritmos inteligentes. Por esta razón, es considerado como la evolución del Business Analytics. Sin embargo, esta herramienta difiere de las demás herramientas de *Analítica*, porque va más allá de entregar ideas y análisis que soporten la toma de decisiones, pues trabaja en descubrir nuevas oportunidades para personalizar productos y/o servicios orientados al perfil del cliente (Davenport, 2014).

Así mismo, el *Big Data* mejora el desempeño y genera un impacto positivo cuando se incluyen en las actividades financieras (Óskarsdóttir et al., 2019), pues con el Big Data se puede entender a un mayor nivel el comportamiento de sus clientes, a través de una segmentación especializada del riesgo (Pérez-Martín, Pérez-Torregrosa, & Vaca, 2018) y también de unas estrategias de gestión de cobranza efectivas, diseñadas a la medida (Crespo & Govindarajan, 2018).

Además, el *Big Data* toma como referencia el perfil del cliente, a través del análisis del comportamiento e incluye información de *Social Network*, lo que genera una mejora en el desempeño de la toma de decisiones para la administración del riesgo en la *gestión de cobranza* (Óskarsdóttir et al., 2019).

9.6 Big Data Analytics

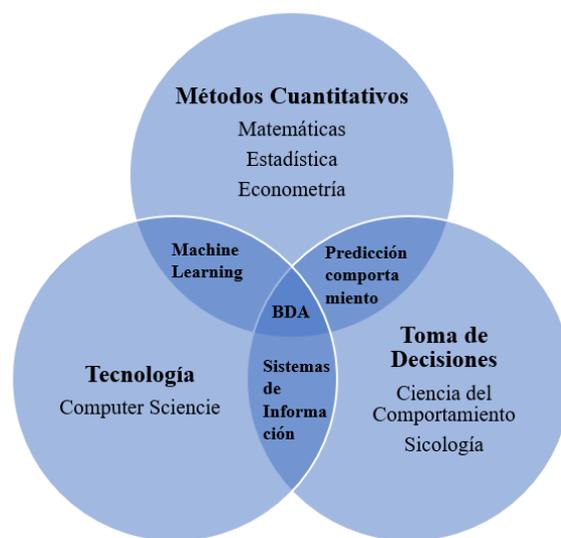
El *Big Data Analytics (BDA)* está orientado al uso de conjuntos de datos y a aplicaciones más complejas (Krishnamoorthi & Mathew, 2018), además del proceso de recolección, administración, procesamiento, análisis y visualización de información para la toma de decisiones. Es por esto que se considera una evolución del *Business Analytics* y del *Big Data*, agrupando su funcionalidad (Rehman et al., 2019). Esta herramienta permite el análisis de la información mediante modelos descriptivos, predictivos y prescriptivos, a través del uso de fuentes de información que agrupan variables tradicionales y no tradicionales. Por lo anterior, las empresas que lo utilizan toman

decisiones más rápidas, mejores y más inteligentes para crear valor comercial (Hindle, Kunc, Mortensen, Oztekin, & Vidgen, 2020).

Para las empresas, el *Big Data Analytics* se ha convertido en una herramienta importante para mejorar la lealtad de los clientes, especialmente en el sector financiero, debido al soporte que entrega, para la toma de decisiones orientada al desempeño de la administración del riesgo de los clientes (Hung et al., 2020).

El siguiente esquema gráfico muestra cómo el Big Data Analytics emplea intersecciones entre tres componentes de información, que arrojan como resultado la identificación y predicción del comportamiento de los clientes (Hung et al., 2020):

Gráfico 1. Procesos Analíticos



Fuente: Elaboración Propia. Información tomada de Hung et al. (2020)

De la misma manera, integra información proveniente de *Social Network*, *Telecomunicaciones*, *mediciones sicométricas* que facilitan el análisis y la identificación de comportamientos (Onay & Öztürk, 2018; Onay et al., 2019;) a través del uso de modelos inteligentes, como *Machine Learning* (De Paula et al., 2019).

Incluso se utiliza como herramienta para mitigar el riesgo de pérdida e incrementar las ventas de las empresas que ofrecen créditos comerciales (Onay et al., 2019).

10. Diseño De La Estrategia De Gestión De Cobranza, A Través De Big Data Analytics En Empresas De Venta Por Catálogo

Hasta aquí se ha mencionado cómo las *Herramientas de Analítica* como el *Big Data Analytics* han revolucionado la *gestión de cobranza* en las empresas que utilizan el crédito a los clientes como incentivo comercial (Bumacov et al., 2017; Onay & Öztürk, 2018). En atención a lo que plantean Moradi & Mokhtab Rafiei (2019) y Velásquez (2013), las estrategias deben ser orientadas a mitigar el riesgo del incumplimiento de pago de los clientes, a través de la identificación, comprensión, medición y, finalmente, implementación de estrategias apropiadas para enfrentarlo.

En este apartado se desarrolla *la estrategia de gestión de cobranza a través de Big Data Analytics*, partiendo del análisis del perfil de riesgo de los clientes (Cai & Zhang, 2020), el cual está determinado por el comportamiento de pago de los créditos por parte de los clientes en un periodo de tiempo (Onay & Öztürk, 2018). El diseño consiste en tres diferentes categorías que se administran durante el ciclo de vigencia del crédito comercial (Velásquez, 2013): *El Otorgamiento, Seguimiento del uso y Recuperación del crédito*, las cuales estarán integradas a través de *herramientas de Analítica* como *Big Data Analytics*, debido sus múltiples ventajas, asociadas a la administración de la información. Esta herramienta está caracterizada por un alto volumen de datos, alta velocidad, variedad de información, almacenamiento, veracidad, calidad y análisis. Todas estas características generan insumos para la toma de decisiones (Onay & Öztürk, 2018; Rialti et al., 2019; Santoro et al., 2019).

10.1 Categoría 1: Otorgamiento Del Crédito

Debido al riesgo de no pago, el otorgamiento de crédito ha sido la principal preocupación de las empresas que promueven los créditos como incentivo comercial (Stanworth et al., 2004; Mili et

al., 2018;). En este sentido, los acuerdos internacionales de Basilea¹ estandarizan sistemas de evaluación del riesgo, para estimar el incumplimiento de los clientes (Moradi & Mokhatab Rafiei, 2019). Por esta razón, la identificación del perfil del cliente es un factor fundamental para este propósito: la segmentación del cliente con base en el riesgo sugerida por Shi et al. (2019). Esta es la primera etapa dentro de la categoría de *Otorgamiento del Crédito*, pues las empresas que otorgan crédito son conscientes de que algunos clientes tienen ciertos perfiles y características, que incrementan riesgo financiero (Bumacov et al., 2017). Para asegurar la supervivencia de las empresas, se deben administrar los riesgos necesarios de forma integral para mitigarlos (Moradi & Mokhatab Rafiei, 2019; Pardo Cariillo & Díaz Castro, 2020). La razón estriba en que el riesgo de los clientes y la administración del riesgo están estrechamente vinculados con el desempeño comercial de una empresa (Jiang et al., 2019).

Para lograr clasificar a los clientes de acuerdo con la probabilidad de pagar o no los créditos (Akkoc, 2012; Pérez-Martín et al., 2018; Moradi & Mokhatab Rafiei, 2019; Jiang et al., 2019;), se debe: (1) identificar la información relevante del perfil del prospecto de cliente (Bumacov et al., 2017); (2) recopilar variables propias del cliente, como por ejemplo edad, género, estado civil, estudios (Bumacov et al., 2017; Moradi & Mokhatab Rafiei, 2019; Jiang et al., 2019;; Grant & Deer, 2019); (3) información financiera relacionada con ingresos, comportamiento con otras entidades financieras, calificación del buró de crédito, e (4) índices macroeconómicos. Lo anterior con el fin de tener una mejor clasificación de los clientes (Onay & Öztürk, 2018; Moradi & Mokhatab Rafiei, 2019; De Paula et al., 2019; Grant & Deer, 2019).

Luego de conocer mayor información del cliente, se define el modelo estadístico que lo analice y clasifique. Esto se hace de acuerdo con el riesgo financiero que generan para la empresa (Panyagometh, 2019). Como ya se mencionó, los modelos estadísticos soportan la toma de decisiones y eliminan la subjetividad de los modelos de gestión de cobranza tradicionales (Lyn C. Thomas, Matuszyk, So, Mues, & Moore, 2016). Además, dichos modelos mejoran la eficiencia a través de la administración del riesgo (De Paula et al., 2019), con una mayor asertividad, menor sesgo y una mayor predicción de la solvencia de los clientes (Panyagometh, 2019).

¹ Como respuesta a la crisis global financiera, aparece una serie de acuerdos internacionales, recopilados en el acuerdo de Basilea. Estos acuerdos regulan el uso del crédito en instituciones financieras con el fin de evitar la bancarrota de estas entidades (BCBS, 2011).

Existen múltiples modelos estadísticos, como por ejemplo: *Regresión Logística y Lineal, Árboles de decisión, Análisis de supervivencia, Markov, Random Forest, Modelos Simples e Híbridos*, los cuales permiten evaluar el comportamiento del crédito del cliente en las diferentes etapas (Butaru et al., 2016; Lyn C. Thomas et al., 2016; Bumacov et al., 2017; Alzeaideen, 2019; Moradi & Mokhatab Rafiei, 2019; Jiang et al., 2019; De Paula et al., 2019; Grant & Deer, 2019; Pardo Cariillo & Díaz Castro, 2020).

Sin embargo, los modelos estadísticos en sí mismos presentan limitaciones en los resultados (Pérez-Martín et al., 2018; Onay & Öztürk, 2018), por lo cual se implementan herramientas de analítica especializadas, como el *Big Data Analytics*, pues a través de modelos de *Machine Learning*, mejoran su capacidad para estimar el comportamiento de los clientes, utilizando de forma integrada los modelos estadísticos para la predicción del comportamiento de los clientes, con una mayor confiabilidad en los resultados arrojados (Onay & Öztürk, 2018; Pérez-Martín et al., 2018; Rialti, Zollo, Ferraris, & Alon, 2019).

En esta etapa del otorgamiento del crédito, el *Big Data Analytics* permite determinar el incumplimiento de pago del cliente partiendo de las variables recopiladas inicialmente de él. En consecuencia, ayuda a estimar el comportamiento de los clientes, incrementando el *Otorgamiento del crédito* a un menor nivel de riesgo para la empresa, incluso para clientes sin información financiera externa o con bajos ingresos (Onay & Öztürk, 2018; Moradi & Mokhatab Rafiei, 2019). Característica de los clientes que presentan una alta participación en las empresas de *Venta por Catálogo* (Peterson et al., 2019).

Con el resultado que arroja el *Big Data Analytics*, se definen los segmentos de los clientes con base en la probabilidad de incumplir con el pago: *clientes riesgo alto, clientes riesgo medio y clientes riesgo bajo* (Pérez-Martín et al., 2018; Moradi & Mokhatab Rafiei, 2019). Esto permite customizar las estrategias para el *otorgamiento del crédito*, partiendo de la información sobre los segmentos de los clientes (Onay & Öztürk, 2018; Moradi & Mokhatab Rafiei, 2019). Para customizar la estrategia es necesario identificar y conocer el comportamiento del cliente, con el fin de determinar las estrategias acordes a sus características propias, es decir, desarrollar estrategias con base en el perfil del cliente, lo que permite un mejor desempeño, pues las estrategias están dirigidas q anticiparse a las intenciones del cliente y finalmente influenciar su comportamiento (Griva et al., 2018).

Las estrategias definidas tienen en cuenta los siguientes criterios: rechazo o aceptación del crédito (Bumacov et al., 2017), de acuerdo con la probabilidad de incumplir con el pago y el riesgo asociado (Grant & Deer, 2019; Moradi & Mokhatab Rafiei, 2019). En el caso en que el cliente se encuentre dentro del segmento de *clientes riesgo bajo o riesgo medio*, se determinan las condiciones para entregar el crédito. Lo anterior con el fin de mantener el riesgo controlado para la empresa, pero incentivando el crecimiento de las ventas. Por ejemplo: tasas de interés variables, monto del crédito ajustado al tipo de cliente, plazos de pago, garantías y renovación del crédito, entre otros (Shi et al., 2019; Moradi & Mokhatab Rafiei, 2019).

Es así como debido al incremento significativo en el número de *vendedores independientes* en las empresas de *venta por catálogo*, desde la crisis económica del 2008 (Harrison & Hair, 2017), la estimación del comportamiento de pago de los clientes se convierte en un factor relevante, con el fin de contar con un *otorgamiento de crédito* cuidadoso y eficiente (Ala'raj et al., 2018). Todo esto con el propósito de minimizar el riesgo de pérdida para la empresa (Mili et al., 2018) e incrementar el volumen de las ventas, a través de un otorgamiento de crédito consciente (Pérez-Martín et al., 2018).

10.2 Categoría 2: Seguimiento Al Comportamiento Del Uso Del Crédito

Pese a que las investigaciones se han enfocado principalmente en la categoría del *otorgamiento del crédito*, existe otra categoría con gran importancia en la administración del riesgo. La razón está en que el comportamiento del cliente puede modificarse en cualquier momento de la vigencia del crédito, debido a variables externas no identificadas en la categoría inicial, lo que puede resultar en una probabilidad de incumplimiento de pago, retraso de pago o incluso incapacidad de pagar el crédito (Moradi & Mokhatab Rafiei, 2019).

Las empresas que promueven el crédito son conscientes de que algunas características de los clientes a los cuales otorgaron el crédito pueden considerarse de alto riesgo en una etapa avanzada, pues comienzan a aparecer variables como la intención y la capacidad de realizar el pago (Bumacov et al., 2017). Por esta razón, es crucial monitorear y controlar el comportamiento de pago del cliente durante el uso del crédito. Esto se realiza a través de inclusión de variables

asociadas al comportamiento de pago, con el fin de mitigar el riesgo de no pago por parte del cliente (Lyn C. Thomas et al., 2016).

Para complementar las variables definidas para el *otorgamiento del crédito* (Bumacov et al., 2017; Ala'raj et al., 2018; Shi et al., 2019; Grant & Deer, 2019), se incluyen otras variables que agregan información acerca del comportamiento de pago del cliente, durante la vigencia del crédito (Pérez-Martín et al., 2018; Onay & Öztürk, 2018), de tal forma que permitan predecir la habilidad y la capacidad de pagar en un momento específico (Bumacov et al., 2017). Estas variables adicionales son las relacionadas con el uso del crédito, los días y plazos de pago, periodos de pagos, fechas de pagos, montos de pago, tipo de pago (parcial o total) y, además, con variables macroeconómicas (Moradi & Mokhatab Rafiei, 2019; Jiang et al., 2019; Tang, Cai, & Ouyang, 2019; Cai & Zhang, 2020). Teniendo en cuenta estas variables, se puede administrar el riesgo proveniente de los clientes con créditos aprobados para identificar, controlar y finalmente definir las estrategias que permitan abordar cada tipo de cliente, orientadas a la minimización del riesgo (Moradi & Mokhatab Rafiei, 2019), permitiendo que la segmentación de los clientes se determine con mayor precisión y eficiencia (Cai & Zhang, 2020).

Una vez identificadas las variables más significativas, se emplea *Big Data Analytics*, con el fin de incluir variables no tradicionales, como las relacionadas con *Social Networking*, *Digital footprints*, telecomunicaciones, entre otras (Onay & Öztürk, 2018; Yadi et al., 2019), buscando fortalecer el análisis. Esto es lo que permite segmentar y clasificar a los clientes de acuerdo con su comportamiento de pago durante la vigencia del crédito (Zanin et al., 2016; Chi & Meng, 2019; Pardo Cariillo & Díaz Castro, 2020), obteniendo una mayor asertividad en los análisis (Addo et al., 2018; Pérez-Martín et al., 2018).

Al utilizar *Big Data Analytics*, las empresas cuentan con acceso a estas nuevas fuentes de datos, por lo cual los clientes que no tienen un historial financiero o se consideran de alto riesgo, pueden ser considerados riesgo bajo a medida que su comportamiento se vuelve más predecible mediante un monitoreo constante, a través de esta herramienta (Onay & Öztürk, 2018).

El resultado de la etapa anterior permite establecer los segmentos a los que pertenecen los clientes de acuerdo con la probabilidad de incumplir con los pagos en un tiempo determinado durante la vigencia del crédito (Onay & Öztürk, 2018; Moradi & Mokhatab Rafiei, 2019). Estos segmentos determinan los clientes, al igual que en la Categoría de *Otorgamiento del Crédito*, en *clientes*

riesgo alto, clientes riesgo medio y clientes riesgo bajo (Pérez-Martín et al., 2018; Moradi & Mokhatab Rafiei, 2019); la diferencia radica en las variables y escenarios a evaluar, los objetivos definidos y resultados obtenidos (Onay & Öztürk, 2018).

Al igual que en la categoría 1, se tienen como base los segmentos de clientes, arrojados por el Big Data Analytics. Por lo anterior, las estrategias a implementar tienen el objetivo de monitorear y prevenir el incumplimiento, puesto que el cliente puede modificar su perfil de riesgo en el tiempo, lo que genera cambios en los perfiles de riesgo, pasando de un segmento de *clientes riesgo bajo* a uno de *clientes riesgo alto*, en cualquier momento de la vigencia del crédito (Onay & Öztürk, 2018; Moradi & Mokhatab Rafiei, 2019).

Por esta razón, el *Big Data Analytics* genera insumos para la toma de decisiones (Yadi et al., 2019), con respecto al canal de comunicación con el cliente, frecuencia en la comunicación, los productos que se ofrecerán, el incremento o disminución del cupo del crédito, el plazo de pago y formas de pago. Todo esto con el objetivo de minimizar el incumplimiento de pago del crédito (Chamasrour et al., 2012; Higginson et al., 2019).

Es así, como la implementación y el uso de la categoría de *Seguimiento al Comportamiento del uso del crédito*, durante la vigencia del crédito, es un punto de gran importancia para las empresas de *Venta por Catálogo*, pues están enfocadas en desarrollar su canal de ventas (Stanworth et al., 2004), a través del crédito comercial (Tsao, 2017; Izar & Ynzunza, 2017).

10.3 Categoría 3: Recuperación Del Crédito

Según lo expuesto en las categorías anteriores, es claro que el perfil del cliente puede modificarse en cualquier punto de la vigencia del crédito (Moradi & Mokhatab Rafiei, 2019). Por lo tanto, se requiere implementar la categoría *recuperación del crédito* en las empresas que ofrecen créditos comerciales, puesto que el incumplimiento de pago por parte del cliente puede mitigarse más no evitarse (Jiang et al., 2019). Esta categoría establece estrategias para recuperar los créditos de aquellos clientes que incumplen con los plazos de pagos pactados inicialmente (Onay & Öztürk, 2018).

Al igual que en las categorías anteriores, las estrategias definidas se precisan con base en la segmentación de los clientes, definida a través de *Big Data Analytics*, gracias al análisis de múltiples variables tradicionales y no tradicionales (Onay & Öztürk, 2018; Pérez-Martín et al., 2018; Yadi et al., 2019). En este punto, las variables no tradicionales, como por ejemplo: *Redes Sociales, Telecomunicaciones, E-Commerce, Psicometría*, en general todos los movimientos en internet que generen huellas digitales, se convierten en puntos cruciales para identificar patrones del comportamiento de pago de los clientes (Tsao, 2017; Onay & Öztürk, 2018, debido a que ya incumplieron con su obligación, lo cual genera un monitoreo de su comportamiento externo para tomar decisiones con respecto a las estrategias a accionar con cada segmento de cliente (Jiang et al., 2019).

Partiendo de las variables empleadas en las categorías anteriores, e integrando variables asociadas al comportamiento de pago, tipo de crédito, monto del crédito, tasa de interés, penalidades, periodos de gracia (Lyn C. Thomas et al., 2016; Derbali & Jamel, 2019; De Paula et al., 2019; Djeundje & Crook, 2019 Panyagometh, 2019), se determina la probabilidad de pago durante el periodo de mora (Lyn C. Thomas et al., 2016).

Esta segmentación se determina a través del *Big Data Analytics*, pues permite integrar la capacidad y habilidad de pago del cliente (Lyn C. Thomas et al., 2016; Cohen & Costanzino, 2017; Moradi & Mokhatab Rafiei, 2019), empleando modelos inteligentes de *Machine Learning*, segmentando los clientes con base en la probabilidad de recuperación de la deuda (Lyn C. Thomas et al., 2016), estimando los clientes de acuerdo con el éxito en su proceso de recuperación del crédito incumplido (Pérez-Martín et al., 2018).

El uso de *Big Data Analytics* permite estimar el comportamiento de los clientes con mayor asertividad (Alzeaideen, 2019). Asimismo, la herramienta se emplea para la detección en tiempo real de comportamientos fraudulentos y reducir el riesgo de castigar los créditos con incumplimiento de pago. Lo anterior, se logra a través del monitoreo constante de los segmentos identificados, por lo cual genera insumos para emprender acciones que permitan anticipar el riesgo (Tsao, 2017).

De esta forma, los segmentos resultantes del uso del *Big Data Analytics* son: *clientes con alta probabilidad de pago, media probabilidad de pago y baja probabilidad de pago* (Lyn C. Thomas et al., 2016). Con esta clasificación se determinan las estrategias (Crespo & Govindarajan, 2018),

empleando una mayor o menor intensidad de acuerdo con la probabilidad de pago del cliente (Lyn C. Thomas et al., 2016; Bumacov et al., 2017). Las estrategias definidas corresponden a penalidades e intereses, incluso descuentos, con el fin de recuperar el crédito antes de considerarlo como pérdida (Lyn C. Thomas et al., 2016; Bumacov et al., 2017).

Por otro lado, se determinan los canales de comunicación y la frecuencia de contacto, de acuerdo con el segmento al cual pertenece el cliente, buscando reactivar la intención de pago de la deuda (Crespo & Govindarajan, 2018; Danstun & Harun, 2020). Esto ayuda a disminuir la pérdida financiera para las empresas (Lyn C. Thomas et al., 2016). Además, de adaptar la estrategia de contacto de acuerdo con las preferencias de los clientes, dado que el *Big Data Analytics* monitorea en tiempo real el comportamiento de los clientes en fuentes de información no tradicionales como *Social Network*, *telecomunicaciones*, *GPS*, entre otras, lo que permite identificar los mejores canales para realizar la gestión de cobro (Tsao, 2017; Alzeaideen, 2019).

A pesar que durante los últimos años la *Recuperación del Crédito* no ha tenido tanta atención como las demás categorías, esta categoría es crucial para las empresas que ofrecen el crédito como incentivo comercial. Pues se debe minimizar la pérdida financiera de la empresa, recuperando los créditos al menor costo posible, antes de ser considerados irrecuperables (Lyn C. Thomas et al., 2016; Cohen & Costanzino, 2017), lo cual se realiza a través del *Big Data Analytics*, gracias a la segmentación asertada de los clientes (Danstun & Harun, 2020).

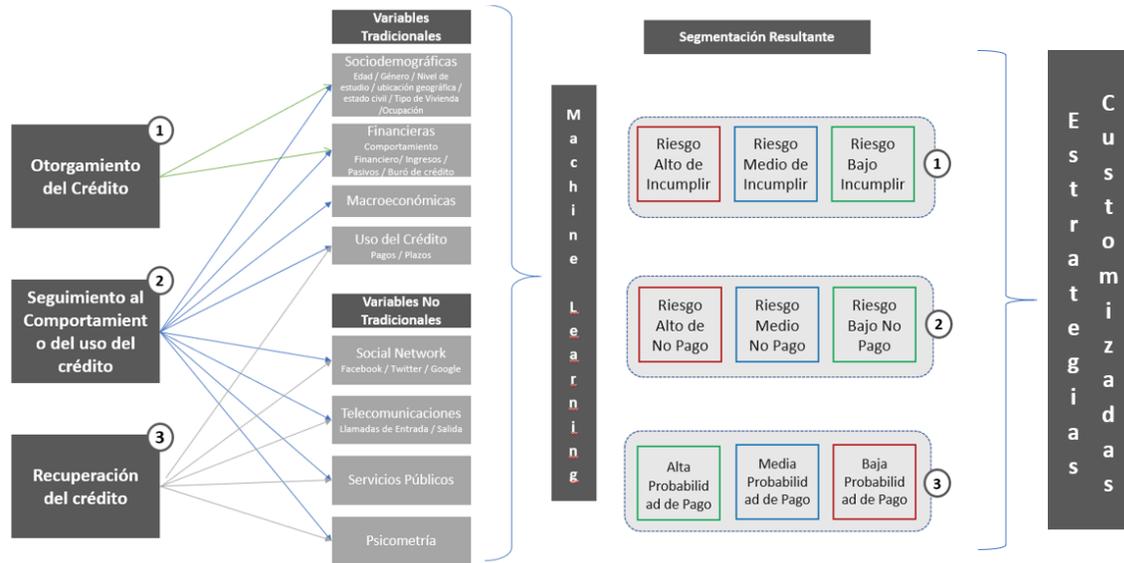
10.4 Modelo Estrategia Gestión De Cobranza A Través De Big Data Analytics

Como se menciona en los capítulos anteriores, *el diseño de la estrategia de gestión de cobranza a través de Big Data Analytics en empresas de Venta por Catálogo*, se desarrolla en tres categorías: (1) *Otorgamiento del crédito*, (2) *Seguimiento al Comportamiento del uso del crédito* y (3) *Recuperación del crédito*.

La siguiente figura resume las categorías sugeridas y su aplicación para la estrategia que se ha diseñado en este estudio. De acuerdo con la funcionalidad del *Big Data Analytics*, evidenciada en el *Gráfico 1*. Cada categoría describe el uso de las variables que se deben considerar, para generar insumos de valor en las empresas. De esta manera, se establece el perfil del cliente a través de

segmentos de riesgo, con el fin de determinar las estrategias en cada una de las categorías de la gestión de cobranza.

Gráfico 2. Modelo Estrategia Gestión de Cobranza a través Big Data Analytics



Fuente: Elaboración Propia.

Por lo anterior, la herramienta de Big Data Analytics se convierte en un punto de referencia importante para las empresas que utilizan el crédito como impulsor de sus ventas (Yadi et al., 2019). La razón se fundamenta en que las decisiones en las empresas ya no sólo dependen de las variables tradicionales del cliente, sino cómo el uso de esta herramienta permite emplear nuevas fuentes de información, que generan insumos de valor para la toma de decisiones, e incluso para personas sin información financiera (Óskarsdóttir et al., 2019; Yadi et al., 2019). Esta herramienta permite, además, monitorear el comportamiento de los clientes, a través del uso de modelos inteligentes como *Machine Learning*. Estos modelos segmentan los clientes de acuerdo con su comportamiento de pago, lo que significa brindar insumos para adaptar la estrategia de gestión de cobranza, con base en la identificación de los segmentos de los clientes. Esto al mismo tiempo permite implementar acciones especializadas y customizadas de acuerdo con el perfil de riesgo de los clientes (Tsao, 2017; Alzeaideen, 2019).

De acuerdo con Stanworth et al. (2004), Ferrell & Ferrell (2012) y Harrison & Hair (2017), las empresas de Venta por catálogo han enfocado por años sus esfuerzos al desarrollo comercial de su canal de ventas, lo que genera un incremento en el ofrecimiento del crédito, incrementando el riesgo y, como tal, un alto riesgo en su estructura financiera (Mili et al., 2018). Es así como la tecnología desafía las formas tradicionales de administrar las empresas, buscando un crecimiento dinámico que permita sostenibilidad en el mercado (Harrison & Hair, 2017).

Asimismo, el Big Data Analytics permite implementar una estrategia de cobranza, que asegure un crecimiento sostenible del canal comercial, y al mismo tiempo proteja la estructura financiera de la empresa. Lo anterior establece cómo el Big Data Analytics puede implementarse de forma transversal durante toda la vigencia del crédito, desde su evaluación (Onay & Öztürk, 2018; Moradi & Mokhatab Rafiei, 2019), pasando del seguimiento a su utilización (Lyn C. Thomas et al., 2016) y, finalmente, para la recuperación de los créditos que ya cuentan con incumplimiento, pues el cliente puede modificar su comportamiento de pago en cualquier punto del ciclo de vigencia del crédito (Cohen & Costanzino, 2017; Moradi & Mokhatab Rafiei, 2019). Su impacto en la recuperación de los créditos con incumplimiento es fundamental, pues al emplear nuevas fuentes de información, permite predecir el comportamiento del cliente, determinar la intención de pago a través de la probabilidad de pago, lo que genera insumos para la implementación de estrategias orientadas a disminuir el riesgo de pérdida de las cuentas por cobros asociadas a los créditos, lo cual obtiene como resultado que los créditos no se conviertan en irrecuperables.

11. Conclusiones y Recomendaciones

Debido a la crisis financiera del año 2008, la gestión de la cobranza se convirtió en un punto crítico para las empresas que utilizan el crédito como impulsor de sus ventas. Con el Acuerdo de Basilea se definieron las condiciones para que las empresas financieras previeran el riesgo asociado a la pérdida del crédito. Asimismo, los modelos de administración del riesgo permitieron identificar y seleccionar los clientes de forma más adecuada, para minimizar la probabilidad de pérdida de la empresa. En este sentido, las herramientas de analítica apoyan a las empresas en el desarrollo de políticas de administración del riesgo, para tomar decisiones oportunas y acertadas.

El *Big Data Analytics* es una de las herramientas de analítica que utiliza modelos descriptivos, predictivos y prescriptivos que crean valor comercial y apoyan las decisiones concernientes a los riesgos con los deudores. Por esta razón, la implementación de dicho instrumento, como apoyo a la estrategia de gestión de cobranza, predeciría el comportamiento del cliente. En especial, las empresas de ventas por catálogo que utilizan el crédito como incentivo comercial eliminarían la subjetividad en la toma de decisiones.

La estrategia de gestión de cobranza, a través de Big Data Analytics, está dividida en el análisis, identificación, segmentación y gestión de los clientes, y se basa en el riesgo de no pago, durante todo el ciclo de vigencia del crédito comercial. De acuerdo con la literatura, la estrategia se focalizaba inicialmente en el proceso del otorgamiento del crédito, sin considerar las fases de seguimiento y recuperación de éste. Sin embargo, el crecimiento considerable de las empresas de venta por catálogo, con la consecuente generación de empleo, justifica la integración de la segmentación y posterior gestión de los clientes, como fases posteriores y parte integral de la estrategia de gestión de cobranza en estas empresas.

Este trabajo destaca el potencial de la aplicación del Big Data Analytics para la gestión de cobranza en empresas de venta por catálogo, debido a sus múltiples beneficios para la segmentación de clientes, lo cual arroja como resultado información relevante para la toma de decisiones.

Adicionalmente, a pesar de que el Big Data Analytics ha sido ampliamente adoptado en sectores financieros, se plantea para estudios futuros medir el impacto de su uso en empresas de Venta por Catálogo.

Por otro lado, se propone para estudios futuros la validación de la estrategia como modelo para la gestión de cobranza en empresas por catálogo, asimismo el desarrollo de nuevas variables de acuerdo con el perfil de sus clientes, que permitan tomar decisiones acertadas.

12. Bibliografía

- Addo, P. M., Guegan, D., & Hassani, B. (2018). Credit risk analysis using machine and deep learning models. *Risks*, 6(2), 1–20. <https://doi.org/10.3390/risks6020038>
- Ala'raj, M., Abbod, M., & Radi, M. (2018). The applicability of credit scoring models in emerging economies: an evidence from Jordan. *International Journal of Islamic and Middle Eastern Finance and Management*, 11(4), 608–630. <https://doi.org/10.1108/IMEFM-02-2017-0048>
- Alzeaideen, K. (2019). Credit risk management and business intelligence approach of the banking sector in Jordan. *Cogent Business and Management*, 6(1), 1–9. <https://doi.org/10.1080/23311975.2019.1675455>
- Anderson, R. (2007). *The {Credit} {Scoring} {Toolkit}: {Theory} and {Practice} for {Retail} {Credit} {Risk} {Management} and {Decision} {Automation}*.
- Antoine, D., & Abdallah, N. (2006). MODELLING OF THE DEBTS COLLECTION PROCESS FOR SERVICE COMPANIES DELOFFRE Antoine * NAIT ABDALLAH Rabie * *. *Context*, 349–354. <https://doi.org/10.3182/20060517-3-FR-2903.00188>
- Antonio, J., & Castro, M. (2014). *Crédito y Cobranza*. México D.F.
- BCBS. (2011). *Basel III: A global regulatory framework for more resilient banks and banking systems December 2010 (rev June 2011)*. *Bcbs 189* (Vol. 2010). Retrieved from <http://www.bis.org/publ/bcbs189.pdf>
- Bijak, K., & Thomas, L. C. (2012). Does segmentation always improve model performance in credit scoring? *Expert Systems with Applications*, 39(3), 2433–2442. <https://doi.org/10.1016/j.eswa.2011.08.093>
- Bülbul, D., Hakenes, H., & Lambert, C. (2019). What influences banks' choice of credit risk management practices? Theory and evidence. *Journal of Financial Stability*, 40, 1–14. <https://doi.org/10.1016/j.jfs.2018.11.002>
- Bumacov, V., Ashta, A., & Singh, P. (2017). Credit scoring: A historic recurrence in microfinance. *Strategic Change*, 26(6), 543–554. <https://doi.org/10.1002/jsc.2165>

- Butaru, F., Chen, Q., Clark, B., Das, S., Lo, A. W., & Siddique, A. (2016). Risk and risk management in the credit card industry. *Journal of Banking and Finance*, 72, 218–239. <https://doi.org/10.1016/j.jbankfin.2016.07.015>
- Cai, S., & Zhang, J. (2020). Exploration of credit risk of P2P platform based on data mining technology. *Journal of Computational and Applied Mathematics*, 372, 112718. <https://doi.org/10.1016/j.cam.2020.112718>
- Carta, S., Ferreira, A., Reforgiato Recupero, D., Saia, M., & Saia, R. (2020). A combined entropy-based approach for a proactive credit scoring. *Engineering Applications of Artificial Intelligence*, 87(October 2019), 103292. <https://doi.org/10.1016/j.engappai.2019.103292>
- Chamasrour, V., Fiorillo, C., & Goslin, D. (2012). *Tendencias de cobranza y recuperación de cartera en el sector financiero a partir de la crisis Punto de vista sobre las prácticas para eficientar la labor de cobranza de las instituciones financieras Contenido*.
- Chen, H., Chiang, R. H. L., & Storey, V. C. (2018a). Business Intelligence and Analytics: From Big Data to Big Impact, 36(4), 1165–1188.
- Chen, H., Chiang, R. H. L., & Storey, V. C. (2018b). Chen_Ch Chiang_Storey_Business Intelligence and Analytics_from big data to big impact.pdf, 36(4), 1165–1188.
- Chen, X., Wang, G., & Zhang, X. (2019). Modeling recovery rate for leveraged loans, (March). <https://doi.org/10.1016/j.econmod.2019.04.006>
- Chi, G., & Meng, B. (2019). Debt rating model based on default identification: Empirical evidence from Chinese small industrial enterprises. *Management Decision*, 57(9), 2239–2260. <https://doi.org/10.1108/MD-11-2017-1109>
- Chijoriga, M. M. (2011). assessment model Application of multiple discriminant analysis (MDA) as a credit scoring and risk assessment model. <https://doi.org/10.1108/17468801111119498>
- Cohen, A., & Costanzino, N. (2017). A General Framework for Incorporating Stochastic Recovery in Structural Models of Credit Risk. *Risks*, 5(4), 65. <https://doi.org/10.3390/risks5040065>
- Crespo, I., & Govindarajan, A. (2018). *The analytics-enabled collections model*.
- Crittenden, V. L., & Albaum, G. (2015). The misplaced controversy about internal consumption:

- Not just a direct selling phenomenon. *Business Horizons*, 58(4), 421–429. <https://doi.org/10.1016/j.bushor.2015.03.007>
- Danstun, N., & Harun, M. (2020). The effect of credit collection policy on portfolio at risk of microfinance institutions in Tanzania. *Studies in Business and Economics*, 14(3), 131–144. <https://doi.org/10.2478/sbe-2019-0049>
- Davenport, T. H. (2006). Competing on analytics. *Harvard Business Review*, 84(1).
- Davenport, T. H. (2014). How strategists use “big data” to support internal business decisions, discovery and production. *Strategy and Leadership*, 42(4), 45–50. <https://doi.org/10.1108/SL-05-2014-0034>
- De Paula, D. A. V., Artes, R., Ayres, F., & Minardi, A. M. A. F. (2019). Estimating credit and profit scoring of a Brazilian credit union with logistic regression and machine-learning techniques. *RAUSP Management Journal*, 54(3), 321–336. <https://doi.org/10.1108/RAUSP-03-2018-0003>
- Deloitte. (2016). *A fresh perspective Collections strategies for the digital age*. Retrieved from https://www2.deloitte.com/content/dam/Deloitte/za/Documents/financial-services/ZA_Digital-age_160916.pdf
- Derbali, A., & Jamel, L. (2019). Dependence of Default Probability and Recovery Rate in Structural Credit Risk Models: Case of Greek Banks. *Journal of the Knowledge Economy*. <https://doi.org/10.1007/s13132-017-0473-1>
- Djeundje, V. B., & Crook, J. (2019). Dynamic survival models with varying coefficients for credit risks. *European Journal of Operational Research*, 275(1), 319–333. <https://doi.org/10.1016/j.ejor.2018.11.029>
- Duffy, D. L. (2005). Direct selling as the next channel. *Journal of Consumer Marketing*, 22(1), 43–45. <https://doi.org/10.1108/07363760510576545>
- Ferrell, L., & Ferrell, O. C. (2012). Redirecting direct selling: High-touch embraces high-tech. *Business Horizons*, 55(3), 273–281. <https://doi.org/10.1016/j.bushor.2012.01.004>
- Gambetti, P., Gauthier, G., & Vrins, F. (2019). Recovery rates: Uncertainty certainly matters.

- Journal of Banking & Finance*, 106, 371–383. <https://doi.org/10.1016/j.jbankfin.2019.07.010>
- Gitman, L. J., Angel, M., Carrión, S., Castro, A. M., Antonio, J., Castro, M., & Contreras, S. (2007). *Administración financiera Decimoprimer edición*. Retrieved from <https://profesorjulioraya.files.wordpress.com/2014/12/12020033.pdf>
- Grant, A., & Deer, L. (2019). Consumer marketplace lending in Australia: Credit scores and loan funding success. *Australian Journal of Management*, (September). <https://doi.org/10.1177/0312896219883678>
- Griva, A., Bardaki, C., Pramataris, K., & Papakiriakopoulos, D. (2018). Retail business analytics: Customer visit segmentation using market basket data. *Expert Systems with Applications*, 100, 1–16. <https://doi.org/10.1016/j.eswa.2018.01.029>
- Han, C., & Jang, Y. (2013). Effects of debt collection practices on loss given default. *Journal of Banking and Finance*, 37(1), 21–31. <https://doi.org/10.1016/j.jbankfin.2012.08.009>
- Harrison, D. E., & Hair, J. F. (2017). The Use of Technology in Direct-Selling Marketing Channels: Digital Avenues for Dynamic Growth. *Journal of Marketing Channels*, 24(1–2), 39–50. <https://doi.org/10.1080/1046669X.2017.1346979>
- Higginson, M., Jacques, F., & Rudisuli, R. (2019). *Toward distinctive collections operations*. McKinseys Boston Office.
- Hindle, G., Kunc, M., Mortensen, M., Oztekin, A., & Vidgen, R. (2020). Business analytics: Defining the field and identifying a research agenda. *European Journal of Operational Research*, 281(3), 483–490. <https://doi.org/10.1016/j.ejor.2019.10.001>
- Hung, J.-L. L., He, W., & Shen, J. (2020). Big data analytics for supply chain relationship in banking. *Industrial Marketing Management*, 86(October), 144–153. <https://doi.org/10.1016/j.indmarman.2019.11.001>
- Izar, J. M., & Ynzunza, C. B. (2017). El impacto del crédito y la cobranza en las utilidades Credit and Collection Profits Impact, 13, 47–62.
- Jalao, E. R. L. (2015). Developing the Manpower Complement for Business Analytics Service Professionals: A Case Study on the Challenges Faced by the Philippines. *Procedia*

Manufacturing, 3(Ahfe), 3494–3497. <https://doi.org/10.1016/j.promfg.2015.07.661>

Jiang, C., Wang, Z., & Zhao, H. (2019). A prediction-driven mixture cure model and its application in credit scoring. *European Journal of Operational Research*, 277(1), 20–31. <https://doi.org/10.1016/j.ejor.2019.01.072>

Kanapickiene, R., & Spicas, R. (2019). Credit risk assessment model for small and micro-enterprises: The case of Lithuania. *Risks*, 7(2), 1–23. <https://doi.org/10.3390/risks7020067>

Krishnamoorthi, S., & Mathew, S. K. (2018). Business analytics and business value: A comparative case study. *Information and Management*, 55(5), 643–666. <https://doi.org/10.1016/j.im.2018.01.005>

Leonard, K. J. (1995). The development of credit scoring quality measures for consumer credit applications. *International Journal of Quality & Reliability Management*, 12(4), 79–85. <https://doi.org/10.1108/02656719510087346>

Liebman, L. H. (1972). A Markov Decision Model for Selecting Optimal Credit Control Policies. *Management Science*, 18(10), B-519-B-525. <https://doi.org/10.1287/mnsc.18.10.b519>

Makuch, W. M., Dodge, J. L., Ecker, J. G., Granfors, D. C., & Hahn, G. J. (1992). Managing Consumer Credit Delinquency in the US Economy: A Multi-Billion Dollar Management Science Application. *Interfaces*, 22(1), 90–109. <https://doi.org/10.1287/inte.22.1.90>

Maldonado, S., Peters, G., & Weber, R. (2018). Credit scoring using three-way decisions with probabilistic rough sets. *Information Sciences*, 507, 700–714. <https://doi.org/10.1016/j.ins.2018.08.001>

Mili, M., Sahut, J. M., & Teulon, F. (2018). Modeling recovery rates of corporate defaulted bonds in developed and developing countries. *Emerging Markets Review*, 36(November 2017), 28–44. <https://doi.org/10.1016/j.ememar.2018.03.001>

Moradi, S., & Mokhatab Rafiei, F. (2019). A dynamic credit risk assessment model with data mining techniques: evidence from Iranian banks. *Financial Innovation*, 5(1). <https://doi.org/10.1186/s40854-019-0121-9>

Onay, C., & Öztürk, E. (2018). A review of credit scoring research in the age of Big Data. *Journal*

of Financial Regulation and Compliance, 26(3), 382–405. <https://doi.org/10.1108/JFRC-06-2017-0054>

Onay, C., Öztürk, E., Jiang, C., Wang, Z., Zhao, H., Tsao, Y. C., ... Li, W. (2019). Modelling repayment patterns in the collections process for unsecured consumer debt: A case study. *European Journal of Operational Research*, 26(1), 1–29. <https://doi.org/10.1002/jsc.2165>

Óskarsdóttir, M., Bravo, C., Sarraute, C., Vanthienen, J., & Baesens, B. (2019). The value of big data for credit scoring: Enhancing financial inclusion using mobile phone data and social network analytics. *Applied Soft Computing Journal*, 74, 26–39. <https://doi.org/10.1016/j.asoc.2018.10.004>

Panyagometh, K. (2019). Impact of baseline population on credit score's predictive power. *Economics and Sociology*, 12(1), 262–269. <https://doi.org/10.14254/2071-789X.2019/12-1/15>

Pardo Cariillo, O. S., & Díaz Castro, J. (2020). Perfil de riesgo de crédito para una cooperativa en Villavicencio a partir de un modelo Logit. *Revista Universidad y Empresa*, 22(38), 237. <https://doi.org/10.12804/revistas.urosario.edu.co/empresa/a.8266>

Pérez-Martín, A., Pérez-Torregrosa, A., & Vaca, M. (2018). Big Data techniques to measure credit banking risk in home equity loans. *Journal of Business Research*, 89(February), 448–454. <https://doi.org/10.1016/j.jbusres.2018.02.008>

Pérez Rave, J. I. (2013). Revisión sistemática de literatura en Ingeniería como apoyo a la Consultoría basada en Investigación. *Universidad, Ciencia y Tecnología*, 17(66), 38–48.

Peterson, R. A., Crittenden, V. L., & Albaum, G. (2019). On the economic and social benefits of direct selling. *Business Horizons*, 62(3), 373–382. <https://doi.org/10.1016/j.bushor.2018.12.002>

Rehman, M. H., Yaqoob, I., Salah, K., Imran, M., Jayaraman, P. P., & Perera, C. (2019). The role of big data analytics in industrial Internet of Things. *Future Generation Computer Systems*, 99, 247–259. <https://doi.org/10.1016/j.future.2019.04.020>

Rialti, R., Zollo, L., Ferraris, A., & Alon, I. (2019). Big data analytics capabilities and performance: Evidence from a moderated multi-mediation model. *Technological Forecasting*

- and Social Change*, 149(October), 119781. <https://doi.org/10.1016/j.techfore.2019.119781>
- Santoro, G., Fiano, F., Bertoldi, B., & Ciampi, F. (2019). Big data for business management in the retail industry. *Management Decision*, 57(8), 1980–1992. <https://doi.org/10.1108/MD-07-2018-0829>
- Shi, B., Zhao, X., Wu, B., & Dong, Y. (2019). Credit rating and microfinance lending decisions based on loss given default (LGD). *Finance Research Letters*, 30(March), 124–129. <https://doi.org/10.1016/j.frl.2019.03.033>
- Stanworth, J., Brodie, S., Wotruba, T., & Purdy, D. (2004). Outsourcing salesforces via self-employment: The case of direct selling in the UK. *Journal of Small Business and Enterprise Development*, 11(1), 50–59. <https://doi.org/10.1108/14626000410519092>
- Takahashi, M., Azuma, H., & Tsuda, K. (2015). A study on deliberate presumptions of customer payments with reminder in the absence of face-to-face contact transactions. *Procedia Computer Science*, 60(1), 968–975. <https://doi.org/10.1016/j.procs.2015.08.136>
- Tang, L., Cai, F., & Ouyang, Y. (2019). Applying a nonparametric random forest algorithm to assess the credit risk of the energy industry in China. *Technological Forecasting and Social Change*, 144(March 2018), 563–572. <https://doi.org/10.1016/j.techfore.2018.03.007>
- Thomas, L. C., Matuszyk, A., & Moore, A. (2012). Comparing debt characteristics and LGD models for different collections policies. *International Journal of Forecasting*, 28(1), 196–203. <https://doi.org/10.1016/j.ijforecast.2010.11.004>
- Thomas, Lyn C., Matuszyk, A., So, M. C., Mues, C., & Moore, A. (2016). Modelling repayment patterns in the collections process for unsecured consumer debt: A case study. *European Journal of Operational Research*, 249(2), 476–486. <https://doi.org/10.1016/j.ejor.2015.09.013>
- Tsao, Y. C. (2017). Managing default risk under trade credit: Who should implement Big-Data analytics in supply chains? *Transportation Research Part E: Logistics and Transportation Review*, 106, 276–293. <https://doi.org/10.1016/j.tre.2017.08.013>
- Velásquez, A. B. (2013). *DISEÑO DE UN MODELO PREDICTIVO DE SEGUIMIENTO DE RIESGO DE CRÉDITO PARA LA CARTERA COMERCIAL, PARA UNA ENTIDAD*

FINANCIERA DEL VALLE DE ABURRÁ.

- Yadi, L. I. U., Yuning, S., Jiayue, Y. U., Yingfa, X. I. E., Yiyuan, W., & Xiaoping, Z. (2019). Big-data-driven Model Construction and Empirical Analysis of SMEs Credit Assessment in China. *Procedia Computer Science*, 147, 613–619. <https://doi.org/10.1016/j.procs.2019.01.205>
- Zanin, M., Papo, D., Sousa, P. A., Menasalvas, E., Nicchi, A., Kubik, E., & Boccaletti, S. (2016). Combining complex networks and data mining: Why and how. *Physics Reports*, 635, 1–44. <https://doi.org/10.1016/j.physrep.2016.04.005>

13. Anexos

13.1 Análisis Bibliométrico

Los términos definidos se incorporaron para realizar inicialmente un análisis bibliométrico en Web of Science. El algoritmo definido para la búsqueda es el siguiente:

Bad debt OR credit scoring OR credit risk OR debt default OR credit default OR collections process OR collections scoring OR collections strategy AND social selling OR direct selling OR mail order industry AND analytics OR business analytics OR big data OR data mining OR business intelligence OR machine learning

Adicionalmente, se ejecutó la búsqueda con los siguientes filtros:

Sólo título, 5 años, Sólo artículos, Categorías: Business Finance, Business, Management, Economics, lo que arrojó como resultado 630 artículos.

