

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ
FACULTAD DE CIENCIAS E INGENIERÍA



**APLICACIÓN DE HERRAMIENTAS DE ANALÍTICA Y
OPTIMIZACIÓN MATEMÁTICA PARA MEJORAR LA COBERTURA
DE LOS CANALES DIGITALES EN UNA ENTIDAD BANCARIA**

**Trabajo de investigación para la obtención del grado de BACHILLER EN
CIENCIAS CON MENCIÓN EN INGENIERÍA INDUSTRIAL**

AUTORES:

Brunnella Alejandra Gomez Fabian

Walter Leonardo Blas Corrales

ASESOR:

Jonatán Edward Rojas Polo

Lima, Agosto, 2021

Resumen

Actualmente, las organizaciones están adaptando nuevas herramientas y metodologías para poder optimizar sus procesos. Las entidades bancarias no son ajenas a la implementación de diversas herramientas debido a la naturaleza cambiante del negocio. Entre dichas herramientas, se encuentran la Optimización Matemática y Data Analytics.

El objetivo de la presente investigación es presentar los beneficios obtenidos para una entidad bancaria a partir de la aplicación de las metodologías propuestas. Por un lado, se tiene como finalidad que valide la hipótesis que indica que la aplicación de Optimización Matemática permite a las entidades bancarias reducir sus costos y optimizar el uso de recursos con el propósito de incrementar la productividad de sus procesos. Por otro lado, se busca evidenciar que, mediante la implementación de modelos de Data Analytics, se puede incrementar la capacidad de explicar el comportamiento de varios aspectos que están relacionados con el negocio.

En el presente trabajo, además del marco teórico, se están abarcado casos de aplicación de Optimización Matemática para determinar la asignación óptima de trabajadores, de límite de crédito y de ventas cruzadas, donde se evidencia que esta herramienta permite distribuir eficientemente los recursos de una entidad bancaria con la finalidad de maximizar o minimizar una función de interés dentro del negocio. Asimismo, se presenta un conjunto de casos de estudio de Data Analytics con los cuales se tiene como objetivo validar los beneficios de dichas herramientas mediante diversas aplicaciones de modelos predictivos e identificación de clústeres.

En síntesis, se puede evidenciar, en el presente trabajo, que la inclusión de metodologías como Optimización Matemática y Data Analytics dentro de los procesos de una entidad bancaria permite que se logre registrar mayores beneficios, tanto a nivel operativo como económico.

Tabla de Contenidos

CAPÍTULO 1. MARCO TEÓRICO.....	7
1.1. Transformación Digital	7
1.2. Canales Digitales	8
1.2.1. Principios de los Canales Digitales	9
1.2.2. Clasificación.....	10
1.2.2.1. Banca por Internet.....	10
1.2.2.2. Aplicativos móviles.....	11
1.2.3. Beneficios.....	11
1.2.3.1. Para la entidad bancaria	11
1.2.3.2. Para los consumidores.....	12
1.2.3.3. Para los negocios.....	13
1.2.3.4. Desafíos para las entidades bancarias	14
1.3. Analytics.....	15
1.3.1. Ciencia de Datos	16
1.3.1.1. Metodología	16
1.3.1.2. Herramientas	18
1.3.2. Machine Learning	21
1.3.2.1. Objetivo.....	21
1.3.2.2. Principales herramientas	22
1.3.2.3. Aplicaciones.....	24
1.3.2.4. Casos Prácticos	25
1.3.2.5. Campos asociados	26
1.3.2.6. Limitaciones.....	27
1.3.3. Big Data Analytics	28
1.3.3.1. ¿Qué es Big Data?.....	28
1.3.3.2. 4 V's	29
1.3.3.3. Tipos	29
1.3.3.4. Plataformas.....	31
1.3.3.5. Métodos.....	32
1.4. Optimización Matemática.....	34

1.4.1.	Beneficios.....	35
1.4.2.	Alcance	35
1.4.3.	Requisitos.....	37
1.4.3.1.	Variables de decisión	37
1.4.3.2.	Restricciones	37
1.4.3.3.	Función Objetivo.....	37
1.4.4.	Investigación de Operaciones.....	38
1.4.4.1.	Naturaleza de la Investigación de Operaciones	39
1.4.4.2.	Efecto de la Investigación de Operaciones.....	39
1.4.4.3.	Modelamiento Matemático	40
1.4.5.	Clasificación de problemas de optimización.....	42
1.4.5.1.	Programación Lineal.....	42
1.4.5.2.	Problemas sin restricciones	45
1.4.5.3.	Problemas restringidos.....	45
1.4.6.	Características de los problemas de optimización.....	46
1.4.7.	Aplicaciones.....	47
1.4.7.1.	Planeamiento de Producción	47
1.4.7.2.	Problemas de asignación	48
1.4.7.3.	Programación de horarios	49
1.4.7.4.	Producción dinámica - modelos de inventario	49
CAPÍTULO 2. ESTADO DEL ARTE.....		51
2.1.	Modelo predictivo de la tasa de abandono de los clientes jubilados aplicando herramientas de “ <i>Big Data Analytics</i> ”	51
2.3.	Retención de clientes en el sector bancario mediante técnica de minería de datos predictiva.....	60
2.4.	Identificación de clústeres de clientes que utilizan los servicios de la banca electrónica.....	63
2.5.	Enfoque de clasificación y redes neuronales para identificar el comportamiento del cliente en el sector bancario: un estudio de caso de un banco internacional	68
2.6.	Modelo matemático para la asignación de trabajadores en una entidad bancaria.....	72
2.7.	Desarrollo de un modelo de asignación de límite de crédito para bancos utilizando un Técnica para la preferencia de orden por semejanza con la solución ideal difuso integrado y programación lineal	77
2.8.	Un enfoque de programación matemática difusa para la optimización de ventas cruzadas en la banca minorista.....	80

CAPÍTULO 3 DIAGNÓSTICO 85

CONCLUSIONES 89

BIBLIOGRAFÍA 91



Índice de Figuras

Figura 1. Principios para la experiencia digital del consumidor.....	10
Figura 2. Fases para la resolución de proyectos de Ciencia de Datos.....	18
Figura 3. Redes neuronales.....	22
Figura 4. Ejemplos de aplicación de Big Data Analytics.	30
Figura 5. Paradigma MapReduce.....	31
Figura 6. Ciclo de la modelación matemática.....	42
Figura 7. Principio de proporcionalidad.	44
Figura 8. La tasa de deserción de los clientes masivos frente a los no masivos 2012-2015.....	52
Figura 9. Distribución de clientes jubilados 2012-2015.....	52
Figura 10. Correlación entre el ratio de abandono y los eventos de retiro.....	55
Figura 11. La infraestructura de ICARE de la solución del caso.....	58
Figura 12. La infraestructura de ICARE de la solución del caso.....	59
Figura 13. La infraestructura de ICARE de la solución del caso.....	60
Figura 14. Clústeres de tratamiento con clientes extremos.....	65
Figura 15. Clústeres de tratamiento sin clientes extremos.....	66
Figura 16. Redes neuronales.....	70
Figura 17. Asignación de colaboradores.....	76

Índice de Tablas

Tabla 1. Casos de éxito de aplicación de la Investigación de Operaciones.	40
Tabla 2 Tasa de éxito de los datos de entrenamiento.....	62
Tabla 3. Tasa de éxitos de los datos de la prueba.	62
Tabla 4. Categoría de los colaboradores.	75
Tabla 5. Asignación por cada tipo de colaborador por periodo.	76
Tabla 6. Notación de las variables y parámetros del modelo.....	78



CAPÍTULO 1. MARCO TEÓRICO

En el presente capítulo, se detallan los principales conceptos que abordan los Canales Digitales, tales como, la Banca por Internet y los aplicativos móviles. Asimismo, se describirán a continuación definiciones acerca de las herramientas de “Data Analytics” y “Optimización Matemática”.

1.1. Transformación Digital

Los primeros pasos de la era digital empezaron con cierto grado de lentitud con la primera computadora programable con código binario en 1941. Posteriormente, Gordon Moore, cofundador de Intel, predijo la evolución de la era digital en 1965. La digitalización se instauró con la finalidad de acelerar procesos y esto provocó un cambio en los trabajos de investigación y desarrollo (Neugebauer, 2019).

En la actualidad, la transformación digital es un término que ha ganado popularidad y ha generado revolución en los negocios; sin embargo, este es un concepto que trasciende desde las décadas de los años 1990 y 2000 cuando se realizaban campañas publicitarias a través del uso de canales digitales (Auriga,2016). Desde esa época hasta principios del 2015, las plataformas digitales donde se comercializaban y ofrecían productos y servicios de las empresas adquirió un gran reconocimiento dado que se identificó una gran oportunidad. Se observó la calidad y facilidad de comunicación que se podía mantener con los clientes a través de las redes sociales, páginas web, entre otros. Esto provocó un gran impacto y un cambio brusco en los sistemas de las organizaciones que optaron por mudarse al mundo digital (Schalmo y Williams, 2018).

Para definir, en efecto, ¿qué es la transformación digital?, se establece que no existe una conceptualización única de este. No obstante, en las siguientes líneas, se presentará una de las definiciones más representativas de este término. Según Altimeter Group, la transformación

digital es “El realineamiento o nueva inversión en tecnologías y modelos comerciales para involucrar de manera más efectiva clientes en cada punto de contacto en el ciclo de vida de la experiencia del usuario” (2014).

1.2. Canales Digitales

De acuerdo a reportes estadísticos, existen más de 4 mil millones de personas, de un total de 7.4 mil millones en el mundo, que usan internet. Sin embargo, la cifra de usuarios activos alcanzó los 3,297 millones en el 2018. Es por este motivo que, actualmente, las organizaciones empiezan a implementar innovaciones tecnológicas con la finalidad de fortalecer el nivel de comunicación entre las empresas y clientes (Dwivedi y otros, 2020).

Hay una creciente tendencia por adoptar la relevancia de la transformación digital dentro de las organizaciones. En primer lugar, se debe determinar una cultura dentro de la organización donde la implementación de la tecnología sea una fuente de soluciones para el negocio. En segundo lugar, la empresa debe elaborar un sistema integrado con la conformación de diversos equipos para poder implementar la transformación digital con la capacidad requerida (Kotlarsky y otros, 2018).

En un contexto digital, como el que se vive en la actualidad, se requiere de esfuerzos que trasciendan las funciones operacionales centrales de las organizaciones tales como las transacciones de productos y/o servicios. En este sentido, el objetivo de las empresas se debe centrar en crear valor ofreciendo experiencias de usuario valiosas para lograr ganar y retener clientes. Google, Amazon y Alibaba son empresas consideradas como los principales actores digitales que se han adaptado a esta era. Estas demuestran el crecimiento y la revolución que determina la digitalidad en el giro de los negocios.

Gracias a los resultados exitosos obtenido por estas compañías, se identifica la necesidad de un cambio brusco en el sistema bancario que defina a las entidades bancarias como agentes que se encarguen de proveer soluciones a los clientes. Esta nueva funcionalidad se

implementará a través de canales digitales, tales como, banca móvil, aplicativos móviles, entre otros (Wewege y Thomsett, 2020).

1.2.1. Principios de los Canales Digitales

Según Shivakumar y Sethii, para poder mejorar el nivel de satisfacción de los clientes en el uso de los canales digitales se deberán seguir un conjunto de principios que se centran en el diseño digital de las plataformas (2019). Los principios son los siguientes:

- **Valor de la marca**

Las organizaciones deben fortalecer el valor de la marca mediante el uso de las plataformas digitales. Para ello, se debe tomar decisiones acerca de los factores que puedan ser utilizados para construir una relación entre el cliente y la organización para incrementar el nivel de satisfacción del cliente y mejorar la interacción con la marca.

- **Diseño de interacción**

La estructura y el comportamiento de las plataformas serán establecidas mediante el diseño de interacción. En este apartado se define la interfaz del usuario, la cual debe poder brindar la mejor experiencia al usuario. Del mismo modo, se debe garantizar la usabilidad y un correcto flujo de navegación.

- **Diseño Visual**

Este es un elemento clave de la experiencia digital que se le ofrece al usuario ya que, a través de técnicas más innovadoras de CSS, desarrolla una interface que sea atractiva para las personas que accedan a esta. Este es el principio encargado de garantizar el uso correcto de la tipografía, color, imagen y forma que brinde un mejor panorama visual para los usuarios.

- **Arquitectura de la información**

Este principio de los Canales Digitales se encarga de recopilar la información obtenida de los puntos de contacto e interacción con los clientes, por ejemplo, los aplicativos móviles, el Internet de las cosas, entre otros. Con la ayuda de estos datos adquiridos, se realizan predicciones, automatización y sistemas de recomendación implementando conceptos de Inteligencia Artificial y “*Machine Learning*”.

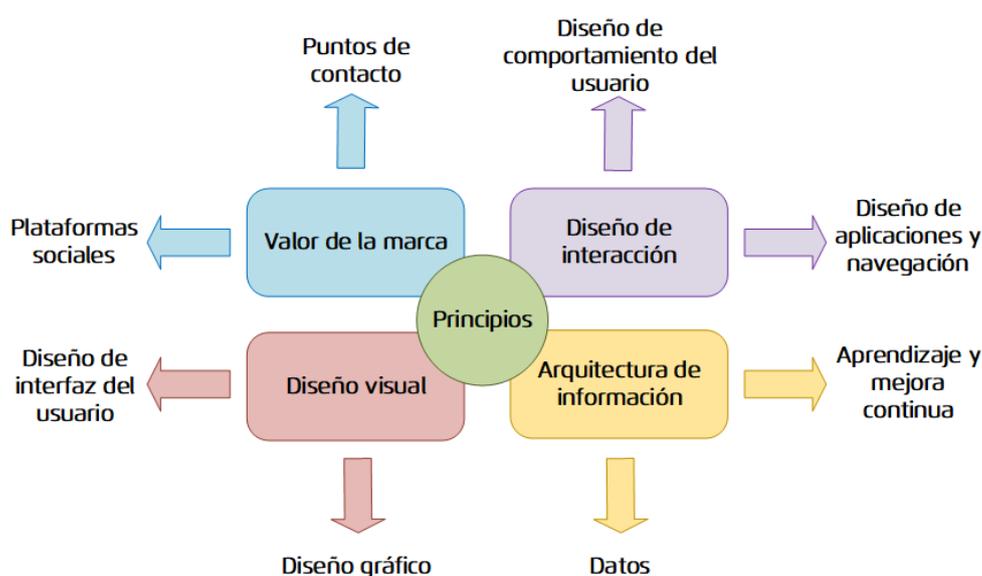


Figura 1. Principios para la experiencia digital del consumidor.

Tomado de “*Building Digital Experience Platforms*”, por Shivakumar y Sethii, 2019

1.2.2. Clasificación

En la actualidad, las entidades bancarias utilizan diversas plataformas digitales para ofrecer sus servicios financieros, entre las principales. se encuentran los aplicativos móviles como la Banca Móvil y la Banca por Internet.

1.2.2.1. Banca por Internet

Las páginas web se han convertido en una pieza fundamental en las organizaciones, y los bancos no son la excepción. Actualmente, la cantidad de entidades bancarias que son representadas por una página web incrementa cada vez más. Esto se debe a que sus servicios y

el acceso a sus productos e información es mucho más flexible. La presentación de una página web donde se oferten diversas líneas que posee el banco en su cartera como tarjetas de crédito y cuentas de ahorro, por ejemplo. La percepción global acerca de la banca por internet ha cambiado en los últimos años. Esta herramienta ha permitido a los usuarios elevar el nivel de experiencia a una siguiente fase. Cada vez, los bancos están implementando una mayor gama de ofertas para promocionar el uso de estos canales digitales (Lange, 1998).

1.2.2.2. Aplicativos móviles

El término Banca Móvil se refiere al concepto en el cual las entidades bancarias hacen uso de los dispositivos móviles para ofrecer servicios financieros de la compañía en una plataforma digital amigable para el usuario. Entre las operaciones que se encuentran disponibles en la aplicación se encuentran las transacciones interbancarias, consultas de cuentas, pagos de servicios, entre otros. Cabe mencionar que este concepto engloba tres definiciones principales: servicios móviles de contabilidad, información financiera y corretaje. Esta implementación digital ha permitido a los usuarios realizar operaciones desde lugares remotos y acceder a la información financiera en cualquier momento. (Nicoletti, 2014)

1.2.3. Beneficios

En el sector financiero, según la SCN Education, en su libro titulado “*Online Banking*”, el uso de los canales digitales implica una serie de beneficios para la entidad bancaria y los clientes como personas naturales y jurídicas (2001). Los beneficios son los siguientes:

1.2.3.1. Para la entidad bancaria

- **Impacto de la marca**

Las entidades bancarias que ofrecen sus servicios y/o productos a través de las plataformas digitales son pocas, por lo que utilizar estos elementos propios de

la transformación digital redefinen la marca de las empresas y las colocan como líderes en la implementación de la tecnología.

- **Reducción de costos de transacción**

En términos monetarios, los costos administrativos involucrados en las operaciones de transacción, tales como pagos, depósitos, entre otros, ya que no se utilizan recursos humanos y/o físicos; en lugar de ello, existe una gran inversión inicial para la digitalidad de los servicios.

- **Mejor capacidad de respuesta al mercado**

Gracias a los canales digitales, la interacción entre los clientes y los bancos ha incrementado su fluidez dado que el flujo de información se presenta en tiempo real con el uso de aplicativos móviles y banca móvil. Esto permite que las estrategias organizacionales respondan satisfactoriamente las necesidades de los clientes.

- **Mayores Ingresos**

Los canales digitales permiten ofertar diversos productos a varios clientes permitiendo la facilidad de que un mayor volumen de ellos sea adquirido y, en consecuencia, los ingresos de las entidades bancarias incrementen.

1.2.3.2. Para los consumidores

- **Reducción de costos**

Se reducen los costos por incurrir en los servicios que ofrece una entidad bancaria, puesto que no se incurrirán en gastos por comisión al realizar transacciones de manera presencial o asumir costos de transporte hacia una entidad bancaria.

- **Conveniencia**

Las operaciones y movimientos bancarios pueden ser realizados desde donde se encuentre el usuario. Los únicos requisitos que necesitaría el usuario son tener un dispositivo móvil con cobertura de internet.

- **Velocidad**

El nivel de respuesta de las operaciones es relativamente alto. Es punto mejora el nivel de experiencia, ya que proporciona una mayor flexibilidad al usuario para programar sus operaciones.

- **Mejor gestión de efectivo**

Los clientes pueden descargar el historial de los movimientos registrados en sus cuentas. Asimismo, pueden realizar un análisis de los saldos que poseen. Del modo, pueden gestionar su dinero entre las cuentas propias del usuario.

1.2.3.3. Para los negocios

- **Mejor gestión de efectivo**

La banca en línea permite a los negocios realizar transferencias por diferentes conceptos y realizar los pagos a las cuentas por pagar ganando interés. Además, se puede analizar los ingresos y egresos a las cuentas del negocio prácticamente en tiempo real.

- **Acceso a información**

Las corporaciones bancarias acceden rápidamente a la información de sus clientes ya que con un “*click*” de ellos pueden averiguar las plataformas a las que estos han entrado para adquirir algún producto o servicio.

1.2.3.4. Desafíos para las entidades bancarias

Las entidades bancarias tienen que afrontar una serie de desafíos al momento de querer implementar un cambio en la experiencia de los usuarios a través de los canales digitales. Según Nicoletti, estas organizaciones deben atravesar un conjunto de desafíos denominados las 6 C's. De acuerdo al autor, los desafíos son los siguientes:

A. Cultura

Las entidades bancarias deben enfocar sus esfuerzos en satisfacer las necesidades de los clientes. Del mismo modo, debe existir un nivel de balance entre los intereses de los accionistas y la misma organización. También, los bancos deben empezar a adoptar metodologías ágiles para la planificación de sus proyectos. Asimismo, se debe empezar a implementar mejoras automatizando procesos.

B. Clientes

Los bancos al implementar los canales digitales deben estar a la altura de las exigencias de los clientes. Del mismo modo, al implementar y promocionar el uso de los canales digitales, se deben asegurar que los clientes puedan entender el funcionamiento de la plataforma para asegurar un alto nivel de experiencia.

C. Competición

Los bancos, en la actualidad, han logrado alcanzar un mayor porcentaje de clientes gracias al uso de canales digitales para promocionar sus servicios. En este escenario, la competencia dentro de las plataformas digitales se ha vuelto más intensa y las entidades bancarias realizan grandes esfuerzos para atraer y retener a sus clientes.

D. Computadores

Para el empleo de las plataformas virtuales, se requiere de una buena conexión a los servidores, ya que los aplicativos móviles y la banca por internet se pueden utilizar mientras que el usuario se encuentre conectado a una red de Internet. Debido a ello, las entidades

bancarias deben poseer una tecnología de punta y personal capacitado que colaboren con la digitalización de los canales y la educación a los clientes en las plataformas.

E. Cumplimiento

El uso de canales digitales puede producir que algunos clientes sean víctimas de fraude cibernético. Es por ello que existe una necesidad de crear sistemas de seguridad. De este modo, las entidades bancarias deben someterse a un sistema de legislación y regulación para que pueda existir transparencia y seguridad en sus líneas de servicio implementando las medidas correspondientes.

F. Costos

Por parte de los accionistas, existe una constante presión para que la utilidad sobre el patrimonio sea cada vez mayor. Con este indicador, se puede medir si el uso de los canales digitales tuvo algún efecto en las finanzas de la entidad bancaria. Asimismo, el hecho de implementar estas nuevas plataformas supondría una reducción en los costos operacionales.

1.3. Analytics

Según Franks, el origen de la Analítica se remonta desde años atrás; sin embargo, a lo largo del recorrido, ha adquirido un posicionamiento importante en las personas debido a que ha revolucionado el comportamiento de las empresas y los negocios. En un inicio, las corporaciones que aplicaron Analítica se basaron principalmente en dos frentes: Estadística y Pronósticos. Esta visión ha cambiado a lo largo de los avances de las ciencias por lo que ahora no es suficiente para las empresas enfocarse en únicamente dos campos de la Analítica, sino que, en la actualidad, se ha convertido en una ventaja competitiva en diversas disciplinas, que serán descritas en las siguientes líneas (2014).

1.3.1. Ciencia de Datos

En la actualidad, la data es el recurso vital de las organizaciones. El tratamiento y análisis de dicha data adquiere una creciente relevancia para los distintos giros de negocios tales como salud, manufactura, entre otros (Mahmood, 2016). Los datos sin un procesamiento de análisis son, en efecto, datos que no generan valor para una certera toma de decisiones. Debido a esto, se presenta la necesidad de procesar la información aplicando “*Data Science*” con el objetivo de transformar datos de pequeños y grandes volúmenes para generar conocimientos que son aplicables, a través de diversas técnicas de muchos campos incluyendo Investigación de Operaciones, Estadística, Ciencias de la Información y Computación (Boehmke, Hazen, Boone y Robinson, 2020). Dichas técnicas utilizan diversos métodos que incluyen modelos predictivos, visualización, pronóstico, minería de datos, patrones de reconocimiento, inteligencia artificial y aprendizaje automático. Estos procedimientos incluyen datos estructurados y no estructurados con enfoque al mundo actual del “*Big Data*” (Wells y Chiang, 2017).

Big Data es aquella tecnología en crecimiento que es usualmente descrita como un conjunto de datos extremadamente grande que crece a una gran velocidad y se encuentra en diversos formatos. Esta data no se puede analizar aplicando métodos tradicionales por lo que esta herramienta se enfoca principalmente en la utilización de información y relaciones de comunicaciones a través del Internet de las cosas (Chinnaiyan, 2020).

1.3.1.1. Metodología

La mayoría de los proyectos que son resueltos por Ciencia de Datos siguen el proceso llamado “*Cross Industry Standard Process*”, el cual se divide en 7 fases:

1. Comprensión del negocio: Para comenzar con la resolución del problema, es necesario determinar los objetivos, los cuales se utilizarán para la formulación del problema que se resolverá con la aplicación de Ciencia de Datos.

2. Preparación: La data “cruda” es aquella que se encuentra en los repositorios de las bases de datos sin previa limpieza para su posterior análisis. En esta fase, se realiza la preparación de datos, el cual es uno de los procesos más complicados del proceso.
3. Exploración: Cuando los datos se encuentran limpios, se realiza una exploración previa con la aplicación de herramientas básicas, tales como, relaciones univariadas y multivariadas.
4. Configuración: En esta fase, se tiene que realizar el estudio de la validación-cruzada de las variables, aleatoriedad de los datos y establecer una base de rendimiento para calificar los modelos que serán aplicados posteriormente.
5. Modelado: La modelación es la parte fundamental para el análisis de los datos. En esta etapa, se seleccionan y aplican algoritmos que aseguren superar la base de modelos y ajuste los algoritmos para optimizar los resultados del análisis.
6. Evaluación: En esta parte del proceso, se realiza la evaluación de modelos comparándolos con el modelado de referencia, Asimismo, se contrastan los diversos modelos para encontrar aquel que cumpla con los objetivos y resuelva de mejor manera el problema. Asimismo, se realiza el análisis de costos intrínsecos en los datos analizados.
7. Despliegue: Esta es la última fase del proceso, en la cual se entregan los resultados que demuestran la resolución del problema y los indicadores que determinen las ganancias correspondientes (D. Larose y T. Larose, 2019).

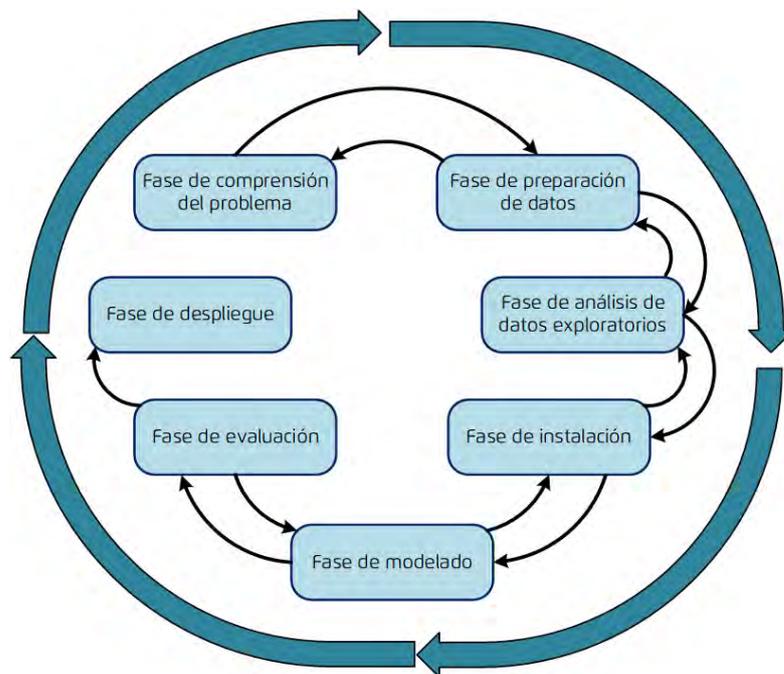


Figura 2. Fases para la resolución de proyectos de Ciencia de Datos.

Tomado de "Introduction to Data Science", por D. Larose y T. Larose, 2019

1.3.1.2. Herramientas

Según Wells y Chiang, la Ciencia de Datos ayuda en el proceso de transformación de la información a *"insights"*, los cuales son fundamentales para mejorar el análisis y se necesita el empleo de diferentes técnicas:

A. Métricas

Las métricas son las unidades de medida que permiten, al gerente o encargado del proyecto, procesar información y cuantificarla. Al momento de calcular las métricas, es importante definir las categorías de métricas que existen para su posterior utilización. A continuación, se definirán cada una de ellas:

- **KPI**

Los *"Key Performance Indicator"* son aquellos indicadores que se utilizan para determinar el progreso y la obtención de los objetivos organizacionales. En la práctica,

una empresa debe poseer un máximo de 7 indicadores de desempeño que se encuentren alineados con el giro del negocio (2017).

- **Métricas de Éxito**

Son aquellas métricas empleadas apoyar la toma de decisiones de los jefes de proyecto vinculadas con las estrategias económicas. Usualmente, estas métricas se discuten al finalizar el proceso de análisis (2017).

- **Métricas de Diagnóstico**

Son métricas específicas para cada área o departamento en particular. Son aquellas que favorecen el temprano descubrimiento de algún problema u oportunidad de mejora (2017).

- **Métricas Operacionales**

Estas son las métricas más empleadas para el diagnóstico del desempeño de los procesos del negocio. Estos forman la base para las métricas de diagnóstico y éxito (2017).

B. Umbrales

Al encontrarse definidas las métricas, se establecen umbrales o límites con el objetivo de encontrar aquellos puntos que se encuentren fuera del rango y tomar acción al respecto. Para encontrar el intervalo óptimo, se deberán recurrir a diversas fuentes que dependen del giro del negocio y de las funciones operacionales que la empresa (2017).

C. Tendencias y Pronósticos

Las tendencias son series de datos que son utilizadas para determinadas métricas con la finalidad de demostrar el rendimiento continuo de los procesos. En el diagnóstico de dichos procedimientos, los analistas desean saber si los puntos fuera de los límites son datos anómalos o sistemáticos que requieren un futuro estudio. El pronóstico es el estudio de la data histórica que tiene como fin determinar las proyecciones a futuro para disminuir la incertidumbre en la

toma de decisiones del negocio. Las tendencias y pronósticos son elementos claves para determinar si los datos siguen un patrón y aprovechar dicha ventaja competitiva para realizar una óptima planificación (2017).

D. Análisis de Correlación

Es otra técnica que se emplea para encontrar la relación que existe entre dos o más métricas, en las cuales exista alguna relación lineal o múltiple. En su mayoría, para una profunda investigación de un conjunto de datos, se aplica el coeficiente de correlación de Pearson (2017).

E. Segmentación

Es el agrupamiento de diversos mercados, canales u organizaciones, a través de la identificación de características o comportamientos similares de las variables estudiadas. La Segmentación tiene diferentes objetivos, tales como, encontrar el “*target*” de un mercado y segmentar a los consumidores de una compañía (2017).

F. Análisis de Clúster

“*Clustering*” es la agrupación de aquellos datos que poseen características similares y se diferencian significativamente de otro “*clúster*”. Esta técnica es similar a la Segmentación; sin embargo, el factor diferenciador es la aplicación de “*Machine Learning*” que posee este análisis (2017).

G. Velocidad

Es un indicador importante de la Ciencia de Datos ya que permite determinar la tasa de cambio de las métricas con el objetivo de identificar la dirección que siguen estas y, de esta manera, permitir una mejor toma de decisiones que beneficien al negocio (2017).

H. Modelos

Los modelos estadísticos son ampliamente utilizados para determinar el comportamiento de las variables y encontrar patrones con el propósito de ayudar a las empresas en la toma de decisiones (2017).

I. Machine Learning

El aprendizaje automático es el próximo paso en la Ciencia de Datos y, cada vez, adquiere una mayor relevancia ya que las empresas buscan incorporar modelos de autoaprendizaje que les permita abordar, con éxito, los problemas que se presenten (2017).

1.3.2. Machine Learning

Según Ghanbari y Najafzadeh, el término “*Learning*” se refiere a la adquisición de conocimientos a través del entrenamiento, la lectura y las experiencias. El Aprendizaje Automático es un nuevo campo perteneciente al área de Inteligencia Artificial, que se encuentra en un creciente crecimiento. Se define como la tecnología o técnica que utiliza la data histórica y programa un sistema que logre aprender de la experiencia con el objetivo de mejorar el rendimiento de análisis para la resolución de problemas (2020).

Actualmente, se ha logrado el desarrollo de múltiples algoritmos y teorías cuya base es el Aprendizaje Automático y han aparecido nuevos campos de estudio. Se percibe que el conocimiento de dichos algoritmos se encuentra en una etapa de madurez que, cada vez, adquiere un rol más importante en la Ciencia de la Información (2020).

1.3.2.1. Objetivo

El principal objetivo del Aprendizaje Automático es lograr encontrar la generalización de la experiencia, en otras palabras, la capacidad de precisar aquellas actividades nuevas y desconocidas con el uso de la experiencia adquirida de los datos introducidos al programa. Por lo general, los datos no siguen una distribución conocida, por lo cual el programador deberá

establecer un modelo con supuestos que permitan realizar el análisis con precisión. Debido a ello, los supuestos que se acoten para el modelo deberán ser complejos, es decir, evaluados y estudiados exhaustivamente a fin de reducir el error que se obtenga del modelo (2020).

1.3.2.2. Principales herramientas

Entre las principales herramientas del aprendizaje automático, se encuentran las redes neuronales artificiales y el análisis de componentes principales.

- Redes Neuronales Artificiales

La red neuronal artificial es aquella representación gráfica del procesamiento de información que se basa en el proceso neuronal del cerebro humano para interpretar la información percibida por las personas. Esta red consiste en nodos interconectados que se dividen en capas. La capa de entrada es aquella que recibe la información, las capas ocultas son las encargadas de procesar dichos datos y generar patrones que serán la salida de las capas de salida de la red. El principal uso de dicha herramienta es para clasificar los datos no lineales, en otras palabras, se utiliza para modelar las relaciones complejas que existen entre las entradas y salidas. A continuación, el gráfico muestra los principales componentes de la red.

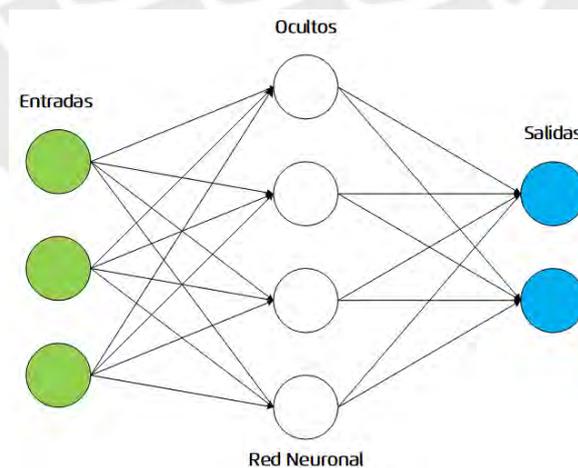


Figura 3. Redes neuronales.

Tomado de "Neural Network and Classification Approach in Identifying Customer Behaviour in the Banking Sector: A Case Study of an International Bank", por Ogwueleka, Misra, Colomo-Palacios y Fernandez, 2012

- Principal Component Analysis

Esta es una de las herramientas analíticas, más conocida por sus siglas en inglés como PCA, más utilizada para el pre procesamiento de la data y el análisis de esta que se ha aplicado ampliamente en diversos campos de investigación dada la gran capacidad que presenta para transformar los datos reducidos de un gran conjunto de estos y mantener la varianza original. A continuación, se explicarán los pasos para calcular las PC y se considerará a M como el conjunto de datos y vectores v_1, v_2, \dots, v_M , donde cada conexión tenga N características.

Paso 1: Se calcula el promedio del conjunto de datos

$$\mu = \frac{1}{M} \sum_{i=1}^M v_i \quad (1)$$

Paso 2: Se calcula la desviación del promedio

$$\theta_i = v_i - \mu \quad (2)$$

Paso 3: La covarianza de la matriz de la muestra del conjunto de datos se define como:

$$C_{n \times n} = \frac{1}{M} \sum_{i=1}^M \theta_i \theta_i^T = \frac{1}{M} AA^T \quad (3)$$

Paso 4: Se tiene a U_K que es el k -ésimo vector propio de C y λ_k es el factor asociado a cada vector de la matriz $U_{n \times n} = [U_1 U_2 \dots U_d]$. Se obtendrá:

$$CU_K = \lambda_k U_K \quad (4)$$

Paso 5: Ordenar los vectores propios en forma decreciente y seleccionar aquellos vectores que tienen los valores más grandes, es decir, los PC. La cantidad de vectores en la matriz depende de:

$$\tau = \frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^n \lambda_i} \quad (5)$$

Paso 6: Para la proyección de los datos en un tiempo t se emplea la siguiente ecuación:

$$Y_t = U_t^T \quad (6)$$

1.3.2.3. Aplicaciones

El Aprendizaje Automático tiene diversas aplicaciones que son utilizadas en la vida moderna. A continuación, se describirán alguna de ellas en los siguientes campos:

A. Servicios Financieros

Las entidades bancarias y firmas del sector financiero aplican el Aprendizaje Automático para obtener “*insights*” relevantes que mitiguen el riesgo e identifiquen oportunidades de inversión para incrementar el valor de las empresas (2020).

B. Cuidado de la Salud

El aprendizaje automático ayuda al sector salud con la implementación de sensores y dispositivos que entreguen información en tiempo real del diagnóstico de los pacientes, Asimismo, esta técnica permite identificar los síntomas a tiempo con el objetivo de que el personal de salud actúe y logre encontrar un tratamiento preciso para el paciente (2020).

C. Gas y Petróleo

En la industria petrolera existen diversas aplicaciones del “*Machine Learning*” tales como el análisis de los materiales del suelo y la predicción de las fallas de los sensores utilizados en las refinerías a fin de incrementar la productividad de la extracción de petróleo y reducir los costos operacionales (2020).

D. Marketing y Ventas

En el área de Marketing, se aplican técnicas de Aprendizaje Automático para ofrecer a sus consumidores propuestas de valor interesantes que están basadas en el estudio de las compras que los clientes han realizado previamente (2020).

E. Gobierno

Las organizaciones gubernamentales, al igual que las compañías, poseen información sensible, la cual debe estar protegida. Debido a ello, estas organizaciones utilizan las técnicas

de Aprendizaje Automático para garantizar la seguridad de los datos y evitar las transacciones fraudulentas que puedan ser registradas en la base del Estado (2020).

F. Transporte

En el área de transporte, el Aprendizaje Automático se ha utilizado para la determinación de las rutas óptimas y la asignación óptima de recursos tales como vehículos, conductores, entre otros (2020).

1.3.2.4. Casos Prácticos

A continuación, se describirán los casos en los cuáles se han aplicado las técnicas de Aprendizaje Automático:

A. Detección de Spam

El Aprendizaje Automático, desde sus inicios, comenzó con el uso de la detección de *Spam* de los mensajes en los correos electrónicos y dicho uso ha avanzado constantemente (2020).

B. Robótica

La robótica ha revolucionado con la utilización del Aprendizaje Automático ya que los robots, en la actualidad, aprenden las actividades por sí mismos o de la experiencia que adquieren al realizar los trabajos (2020).

C. Publicidad

Desde el año 1995, Internet otorga la oportunidad, a los minoristas, de ofrecer sus productos a través de las páginas web con el uso de “*Cookies*”, las cuales permiten identificar las necesidades de compra de los usuarios con el objetivo de ofrecer productos atractivos para los consumidores (2020).

D. Internet de las Cosas

El Internet de las Cosas es un sistema de dispositivos computacionales ubicuos que se extienden a lo largo del mundo de las redes. Este sistema tiene el objetivo de ayudar a facilitar

las actividades de los usuarios con una programación automática, en otras palabras, sin la necesidad de establecer relaciones humanas. Esto se logra a partir de una infraestructura aplicando la tecnología de la comunicación y la informática. Esta técnica abrirá paso a la simplificación de procesos y permitirá la reducción de costos en la realización de las funciones cotidianas (Chaouchi, 2010).

1.3.2.5. Campos asociados

“*Machine Learning*” es una ciencia multidisciplinaria, es decir, se relaciona con diversos campos, los cuales se especificarán en las siguientes líneas.

A. Minería de Datos

Según Mehmed Kantardzic, “*Data Mining*” es un sistema iterativo, el cual se concentra en la exploración de la información, aplicando métodos manuales y automáticos, con el objetivo de encontrar datos relevantes en un escenario donde la data sea incierta. Este es un sistema coordinado entre personas y computadoras. Por un lado, el factor humano define el problema y los objetivos del proyecto. Por otro lado, los dispositivos computacionales poseen altas capacidades de búsqueda inmersas en su infraestructura de datos. De esta manera, se logra un resultado exitoso que determine con precisión las nuevas variables y los valores del análisis. Asimismo, este método tiene dos objetivos primordiales: predicción y descripción (2020).

B. Inteligencia Artificial

La Inteligencia Artificial es aquella ciencia que se encuentra definida en la teoría del desarrollo de características propias de los humanos relacionados con la inteligencia, tales como, el procesamiento de información, resolución de problemas, el lenguaje y la adaptación. La meta principal de esta disciplina es lograr comprender las bases de la inteligencia en los humanos y utilizarlos para que las computadoras desarrollen un razonamiento automatizado. Esta ciencia es un campo interdisciplinario, en otras palabras, se relaciona con diferentes campos que pertenecen a diferentes áreas de estudio. Por ejemplo, esta técnica vincula los

conceptos económicos, estadísticos, psicológicos, neurociencia, filosofía, matemática, computación, entre otros (Tecuci, 2011).

C. Estadísticas Computacionales

El Aprendizaje Automático se encuentra vinculado, estrechamente, con la Estadística Computacional, es decir, las técnicas y métodos estadísticos son procesados con el uso de ordenadores. Dicha ciencia se enfoca en el análisis de las variables para predecir comportamientos y se relaciona con la Optimización Matemática (2020).

D. Probabilidad

La probabilidad es un término que se evoca en la estadística. El Aprendizaje Automático es una ciencia que, desde sus inicios, se encuentra vinculada con la Estadística. Según Jordan, los orígenes del “*Machine Learning*” provienen de las técnicas y métodos de esta ciencia pura (2015).

1.3.2.6. Limitaciones

El Aprendizaje Automático no es una ciencia exenta de limitaciones, las cuales se deben a lo mencionado en los párrafos anteriores, se necesita la introducción de información extensamente cuantiosa para lograr que los ordenadores realicen los análisis con precisión. Por ejemplo, el caso del *Spam* en la mensajería, los mensajes son filtrados en las computadoras dado que existen algoritmos que utilizan la información que se les ha brindado para analizar los mensajes; sin embargo, existen mensajes personales que son filtrados por poseer algunas de los datos introducidos al servidor que deberían ser manejados como *Spam*. En estos casos, el algoritmo aplicado en los ordenadores no logra diferenciar la mensajería y ocasiona problemas en los usuarios (2020).

1.3.3. Big Data Analytics

Según Prabhu y otros autores, “*Big Data Analytics*” es un paradigma computacional paralelo comercial de alto rendimiento a escala de Internet para el análisis de datos. Este concepto globaliza las técnicas y métodos utilizados para el análisis de grandes volúmenes de data, conocido comúnmente como “*Big Data*”. Esta disciplina se apoya en el procesamiento automatizado en los ordenadores debido a que la cantidad de datos extraída es inmensa. Para comenzar con la explicación de las herramientas de dicha ciencia, se presentará la definición del término “*Big Data*” (2019).

1.3.3.1. ¿Qué es Big Data?

Las tecnologías innovadoras, como es el caso de, el procesamiento computacional, análisis de *clustering*, entre otros, son las responsables de la transformación de las relaciones entre el “*Big Data*” y la Ciencia de Datos. Previamente se ha definido el término Ciencia de Datos, por lo cual en esta sección se determinará, únicamente, el significado de “*Big Data*”. Para explicar este concepto, es posible señalar a las redes sociales y tener conocimiento de que en estas circula un extenso flujo de datos a escala de Internet. Esta extensa cantidad de datos es denominada “*Big Data*”, la cual puede extraerse de diversas fuentes, tales como, empresas, páginas web, entre otros (Prabhu, 2019).

Asimismo, el “*Big Data*” representa las proyecciones y pronósticos de las situaciones cotidianas que se viven, tales como, el pensamiento humano y procesamiento en ordenadores. Esta información se almacena en una base de datos y es codificada para el próximo procesamiento. La infraestructura para administrar este amplio tráfico de datos son los sistemas informáticos y sus orígenes teóricos se enfocan en las ciencias de la computación y las tecnologías de la información (García, 2017).

1.3.3.2. 4 V's

Según Finlay, las características primordiales, que diferencian al “*Big Data*” son las siguientes:

A. Volumen

Como se mencionó anteriormente, el término “*Big Data*” hace referencia al gran volumen de datos que serán analizados. Esta cantidad de data se expresa en Terabytes y Petabytes.

B. Variedad

Las fuentes de extracción de data son diversas, ya que la información se encuentra en múltiples sistemas de información como, por ejemplo, las redes sociales. Para la clasificación de dicha información, se identifica la data estructurada, la cual se puede representar a través de categorías y números, y la data no estructurada, la cual se refiere a los datos encontrados en páginas web, blogs y llamadas.

C. Velocidad

En la actualidad, los datos crecen a una gran velocidad dada la interacción de las personas a través de las páginas web y redes sociales. Esto implica la necesidad de recopilación, análisis y extracción de los datos en tiempo real para facilitar la toma de decisiones de las empresas.

D. Veracidad

Los datos de una empresa son el recurso más importante, por lo que validar la veracidad de ellos es un trabajo significativo para el posterior tratamiento de ellos. Esta es una de las características más difíciles de corroborar; sin embargo, se tienen que realizar exhaustivos esfuerzos para lograr la obtención de una data clara y limpia (2014).

1.3.3.3. Tipos

La Ciencia de “*Big Data Analytics*” se clasifica en las siguientes categorías analíticas:

A. Analítica Descriptiva

Para comenzar el análisis de datos, el primer paso es la utilización de la Analítica Descriptiva, la cual se encarga de la extracción y la exploración de la data histórica con el objetivo de determinar patrones de comportamiento de variables influyentes en la toma de decisiones de los negocios. Asimismo, en esta categoría, se visualizan los datos con el uso de “dashboards”.

B. Analítica Predictiva

La Analítica Predictiva tiene la función de utilizar la información y patrones encontrados de la Analítica Descriptiva para lograr la comprensión de la data histórica y, con dicha información, predecir las tendencias futuras mediante el uso de pronósticos y modelos predictivos.

C. Analítica Prescriptiva

Esta clase de Analítica utiliza los “outputs” de la Analítica Descriptiva y Predictiva, tales como, la clasificación, patrones de comportamiento y proyecciones. La Analítica Prescriptiva utiliza técnicas como Optimización, Simulación y Modelos Matemáticos con la finalidad de prever el impacto a futuro de la toma de decisiones presentes de las empresas (Pyne y Prakasa, 2016).



Figura 4. Ejemplos de aplicación de Big Data Analytics.

Tomado de “Big Data Analytics: Methods and Applications”, por Rao, Pyne y Prakasa, 2016

1.3.3.4. Plataformas

Debido a la alta necesidad de procesar grandes cantidades de datos, “*Big Data Analytics*” emplea diversas plataformas, las cuales serán explicadas a continuación:

A. Hadoop

Hace 9 años, Hadoop fue la primera plataforma de procesamiento de datos y fue utilizada por los gigantes de las redes sociales como Facebook y Yahoo. Este último utilizó esta plataforma para rastrear a los usuarios a través de los “*clicks*” en la página web, debido a que requería de un software que permita el tratamiento de un extenso flujo de datos. Asimismo, *Hadoop* lidera la transformación de datos y presenta un código abierto, el cual es utilizado por diferentes empresas minoristas y mayoristas para el estudio de su información (Prabhu, 2019).

B. MapReduce

La infraestructura del “*MapReduce*” faculta a los programadores el procesamiento de la data en paralelo y es considerado como un modelo de programación sencillo que posee una gran capacidad analítica de un amplio tráfico de datos. Para el proyecto de análisis, “*MapReduce*” utiliza dos elementos. Por un lado, emplea los “mapas” que son aquellos componentes que disgregan la data en grupos pequeños y los relacionan en conjuntos. Por otro lado, utiliza las funciones de reducir que son los encargados de agrupar los “*outputs*” de los “mapas” y los dividen en subgrupos más pequeños (Zomaya y Sakr, 2017).

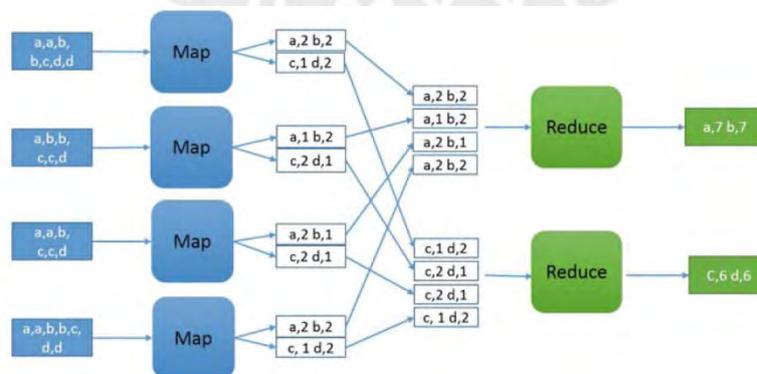


Figura 5. Paradigma MapReduce.

Tomado de “*Handbook of Big Data Technologies*”, por Zomaya y Sakr, 2017

C. Kafka

LinkedIn, la red social profesional, desarrolló una plataforma cuya función principal es el procesamiento de datos, llamada Kafka. Este es un programa cuya principal funcionalidad es el desarrollo del análisis de flujo de datos en diversos servidores. Asimismo, este software permite la obtención de la información en tiempo real (Bell, 2020).

D. Spark

Spark es una plataforma con un alto potencial para el procesamiento de datos. Este es un software que, con el pasar de los años y los avances que ha tenido, se ha vuelto más atractivo para los usuarios ya que tiene un procesamiento mucho más rápido que las tres herramientas previamente mencionadas. Este programa emplea el subconjunto de Ada y el lenguaje que utiliza para la codificación es un instrumento principal para las especificaciones contractuales de Spears (Boulanger, 2013).

1.3.3.5. Métodos

En un contexto, en el cual el tráfico de datos es masivo, se aplica una serie de métodos. Entre los principales se encuentran los siguientes:

A. Bloom Filter

Este método fue propuesto por Burton Bloom en el año 1970. Este término conceptualiza la infraestructura de datos probabilística que facilita la reducción del número de comprobaciones, es decir, la identificación de las entidades que pertenecen a un conjunto. Se inicia con un grupo de elementos binarios distribuidos en una matriz m , los cuales se transforman a través de una función “*Hash*”. Si estos últimos, en su totalidad, son 1, se concluye que el resultado es verdadero; sin embargo, si existe un elemento 0 resulta falso. Asimismo, este procedimiento permite la escalabilidad de los datos aplicando filtros que aumentan con el tamaño de la matriz (Sing y otros autores, 2018).

B. Hashing

Este es uno de los métodos que son utilizados por las herramientas de “*Big Data Analytics*” para sintetizar y consolidar el gran volumen de información que se extrae de diversas fuentes. Se encarga de acortar la longitud de los datos o convertirlos en elementos numéricos. Esta funcionalidad tiene el objetivo de facilitar la lectura de la data y realizar consultas a una alta velocidad de los datos analizados; no obstante, el desafío es encontrar la función “*Hash*” que transforme dichos elementos (Wells y Chiang, 2014).

C. Index

Index es uno de los procedimientos más efectivos para realizar la manipulación de la data perteneciente a bases de datos estructurados, semi- estructurados y no estructurados. Este método permite modificar, adicionar, eliminar y consultar datos con mayor eficiencia ya que consolida los datos para su posterior análisis. Sin embargo, para el uso de esta herramienta, se requiere de un espacio para el almacenamiento de los archivos Index y estos requieren las actualizaciones necesarias para su funcionamiento (Wells y Chiang, 2014).

D. Trier

Este método es más conocido como el “*Trie Tree*”. Se aplica a la información estadística que analiza la frecuencia de datos. Su función primordial es disminuir la contratación de diversas cadenas de caracteres con el empleo de prefijos que son añadidos a dichos caracteres para evaluarlos e identificarlos a una mayor velocidad (Wells y Chiang, 2014).

E. Parallel Computing

Este concepto se remonta a la década de los años 50 y 60 cuando comenzaron a aparecer las primeras supercomputadoras llamadas Illiac III y IV con la implementación de subprocesadores dentro de ellas. Posteriormente, se construyeron computadoras con algoritmos que trabajan en paralelo. Estas últimas aplicaron el término “*Parallel Computing*”,

el cual, en efecto, es la utilización de diversos procesadores para la realización de diversos cálculos en simultáneo (Kulperger y Yu, 2014).

1.4. Optimización Matemática

La optimización ha sido preservada a lo largo de la evolución del ser humano. A pesar de que la optimización ha sido aplicada desde la prehistoria de alguna manera u otra, el nivel de desarrollo a todos los niveles es realmente significativo, especialmente si se refiere a las últimas décadas. Actualmente, las sociedades conviven en un ambiente de competición; sin embargo, para ello, se requiere preservar los recursos de los que se disponen, puesto que estos son limitados. Es por ello que ahora se realizan un conjunto de actividades para poder alcanzar la optimización, tales como, diseño, aplicación y control (Diwekar, 2008).

En primer lugar, la principal aplicación de las matemáticas se ven reflejadas en problemas de optimización. Básicamente, lo que se busca conseguir es maximizar los bienes y, de la misma manera, se estaría buscando minimizar los costos o consecuencias. Para ello, se está buscando realizar un estudio exhaustivo de las variables a controlar con la finalidad de maximizar el beneficio de la entidad en asunto. Cabe resaltar que, debido a que las variables a modelar poseen un límite de capacidad, los análisis de maximización o minimización serán acotados dichas restricciones. Bajo dichos supuestos, los modelos de optimización se programan para poder obtener valores de las variables lo más próximo a un resultado óptimo (Meerschaert, 2013).

Según Pappalardo, Pardalos y Stracquadanio, “la optimización matemática es una rama interdisciplinaria de las matemáticas relacionada con los campos de la Investigación Operativa, Complejidad Computacional y teoría de algoritmos.” (2013). El objetivo de la Optimización Matemática es maximizar o minimizar variables que se relacionan con diversos procesos que finalmente desembocan en una toma de decisiones teniendo en consideración un conjunto de restricciones. El término “optimización” está fuertemente relacionado con la palabra “mejora”.

Es decir, la optimización matemática está relacionada con encontrar el mejor valor, ya sea a nivel local o global, en un sistema determinado (Kallrath, 2004).

1.4.1. Beneficios

Según Venkateswarlu y Jujjavarapu, especialistas en modelación matemática e investigación de operaciones, la aplicación de la optimización matemática implica diversos beneficios dentro de la ciencia e ingeniería, puesto que ha sido un gran impulsor para realizar diversas contribuciones a la evolución de la industria. La aplicación de la optimización matemática ofrece un incremento sustancial al rendimiento de las plantas, puesto que permite reducir significativamente el consumo de múltiples recursos valiosos, los cuales son escasos. (2020) Según los autores, se destacaron entre los principales beneficios de la aplicación de la optimización los siguientes:

- Permite la programación y eficiente construcción de las plantas.
- Conduce a incrementar la calidad de diseño mejorada.
- Permite reducir la incertidumbre de una manera rápida y confiable para la toma de decisiones.
- Minimiza los costos de inventario e incrementar la eficiencia para el proceso de asignación de recursos.
- Facilita la reducción por conceptos de transporte a través de la Planificación Estratégica.

1.4.2. Alcance

La optimización puede ser aplicada a lo largo de diversas líneas de una empresa, planta, proceso u operación. Si se sitúa dentro de una industria convencional, se puede alcanzar la optimización en los siguientes niveles: Gestión, Diseño de planta, Operaciones de planta

(Venkateswarlu y Jujjavarapu, 2020). A continuación, se describirán cada uno los niveles mencionados.

- **Nivel de Gestión**

La optimización matemática permite facilitar la toma de decisiones que están relacionadas con la selección de productos, evaluación de proyectos. Del mismo modo, permite realizar una distribución óptima de los presupuestos corporativos, la inversión en ventas. Además, permite contribuir con el desarrollo de la planta, ya que a través de esta herramienta se puede mejorar el rendimiento en investigación, desarrollo y construcción de nuevas plantas.

- **Nivel de Diseño de la Planta**

En este nivel, la optimización matemática ayuda con la selección del proceso, es decir, permite facilitar la elección entre un proceso continuo o por lotes. De la misma manera, se pueden definir las condiciones de funcionamiento nominales y la configuración más eficiente de la planta. En este nivel, es destacable que se también se permita gestionar el tamaño óptimo de unidades a procesar y la programación de la planta con ayuda de herramientas de simuladores de procesos.

- **Nivel de Operaciones de la Planta**

El alcance de este nivel es la toma de diversas decisiones que se encuentran relacionadas con las operaciones de un proceso concretamente. Por ejemplo, la optimización matemática a este nivel permite una óptima asignación de los recursos a cada nivel de procesamiento. También, permite minimizar los costos generados en las operaciones conceptos que se derivan indirectamente por el proceso productivo como transporte y distribución.

1.4.3. Requisitos

Como se ha descrito en los párrafos previos, el objetivo de la optimización es mejorar el desempeño de las empresas mediante el aumento de la eficiencia de los procesos mediante la formulación matemática en función de la naturaleza de la industria. Los componentes básicos de la optimización matemática son las variables, restricciones y función objetivo.

1.4.3.1. Variables de decisión

Son el conjunto de incógnitas que se encargan de definir la función objetivo. En varias ocasiones, las variables representan los recursos que involucran los diversos procesos. Es común que las variables sean recursos como tiempo dedicado a una actividad o la cantidad de materia prima utilizada.

1.4.3.2. Restricciones

Son aquellas que se encargan de limitar los posibles valores que pueden adoptar ciertos valores. Esto se debe a que debido a la naturaleza de los procesos y variables se deben restringir ciertos valores. Por ejemplo, los valores de tiempo no pueden ser negativos. El problema de la optimización radica en que dichas variables minimicen o maximicen el valor de la función objetivo a través de las variables.

1.4.3.3. Función Objetivo

Es una lógica matemática que, dependiendo del objetivo de la operación, debe ser minimizada o maximizada. Es decir, puede ser minimizada si se establece la función en términos de costos y puede ser maximizada si se define la función objetivo en términos de ganancia o utilidad. Esta se define comúnmente dependiendo de los objetivos de la organización.

1.4.4. Investigación de Operaciones

Formalmente, las primeras investigaciones de operaciones se originaron en Inglaterra durante el periodo de la Segunda Guerra Mundial. En ese entonces, el principal propósito era realizar un modelo que permita optimizar la utilización del armamento bélico que se emplearía. Una vez finalizó la guerra, las ideas y modelos que se aplicaron para el enfrentamiento armado se pudieron extrapolar al sector civil para poder incrementar su eficiencia y productividad. (Taha, 2012)

Para poder conocer con mayor profundidad la definición de Investigación de Operaciones, resulta oportuno remontarse a las definiciones que se promulgaron. Por un lado, según la Sociedad de Investigación de Operaciones de América, dentro de su material educativo, se define a la Investigación de Operaciones como un enfoque a nivel científico para poder realizar la toma de decisiones. Por otro lado, otra definición brindada por la misma organización es que la Investigación de Operaciones es aquella herramienta que brinda científicamente la mejor decisión acerca de cómo operar bajo un contexto en el cual se requiere la asignación de una cantidad limitada de recursos. Asimismo, en 1962, de acuerdo a The British Operational Research Society, se refiere a la Investigaciones de Operaciones como el uso de herramientas de modelos matemáticos con la finalidad de resolver problemas complejos para poder brindar diagnósticos y poder administrar diversos sistemas de recursos. (Pollock y Maltz: pp. 1-22, 1994)

Además, Ackoff y Sasieni, pioneros de la Investigación de Operaciones, definen a esta herramienta como "la aplicación del método científico por equipos interdisciplinarios a problemas que implican el control de sistemas organizados (hombre-máquina) para proporcionar soluciones que sirvan mejor a los propósitos de la organización en su conjunto". (2003)

1.4.4.1. Naturaleza de la Investigación de Operaciones

Según Hillier y Liberman, esta disciplina se relaciona con la coordinación de las operaciones de una organización. La investigación de operaciones ha podido ser aplicada en diversas ramas, tales como, transporte, manufactura, planificación financiera, cuidado de salud, fuerzas armadas, construcción, entre otras (2010).

Según los autores, a esta herramienta se le agrega el término de investigación, puesto que se realiza la misma orientación que las varias ramas científicas. En ciertas ocasiones, se hace uso de los términos “*Ciencia de la administración*” o “*Management Science*” como referencia a la Investigación de Operaciones. Estas nomenclaturas se refieren a el proceso de aplicación de los siguientes pasos:

A. Observación

Se realiza la recolección de datos para poder ser procesados en el modelo matemático propuesto.

B. Construcción de un modelo científico

Se construye una lógica, que generalmente es matemática, para que se logre abstraer la esencia de la casuística en cuestión.

C. Experimentación

Se llevan a cabo los experimentos en campo para poder analizar el comportamiento del modelo en la práctica.

D. Validación del modelo

Se verifica el correcto funcionamiento del modelo y se analiza si se rechaza la hipótesis propuesta.

1.4.4.2. Efecto de la Investigación de Operaciones

En los últimos años, diversas organizaciones se han beneficiado debido al efecto surgido de la Investigación de Operaciones, ya que hubo un incremento notorio en la eficiencia

de sus procesos. Actualmente, existen múltiples instituciones que se especializan en este campo. Entre las organizaciones más importantes, destaca la *International Federation of Operational Research Societies*, conocida por sus iniciales como IFORS, con más de 30 países miembros. Para poder ilustrar de manera concisa y específica los beneficios que conlleva la aplicación del método a varias entidades, se va a enunciar algunos casos de aplicaciones reales y su efecto dentro de la organización (Hillier y Liberman, 2010).

Tabla 1.

Casos de éxito de aplicación de la Investigación de Operaciones.

Organización	Aplicación	Ahorro anual
Samsung Electronics	Reducción de tiempos de manufactura y niveles de inventario	Ganancias adicionales de \$200 millones
Procter & Gamble	Rediseño del sistema de producción y distribución	\$200 millones
Taco Bell	Planeación de los programas de trabajo de los empleados de restaurantes	\$13 millones
Memorial Sloan-Kettering	Diseño de terapia de radiación	\$459 millones

Nota: Tomado de “Introducción a la investigación de operaciones”, por Hillier y Liberman, 2010.

Como se puede reflejar en la tabla anterior, la introducción de herramientas de Investigación de Operaciones tiene registro de casos donde ha significado un incremento en la eficiencia de las organizaciones, lo cual se ve reflejado finalmente en beneficios económicos para la organización.

1.4.4.3. Modelamiento Matemático

Según Hermann Schichl, el término “modelar” tiene origen a partir de la palabra *modellus*, proveniente del latín, la cual describe una manera en la cual el humano afronta la realidad. Varios investigadores expertos en antropología indican que la capacidad de formular diversos modelos matemáticos proviene desde los tiempos de homo neanderthalensis. Sin

embargo, los modelos desarrollados por los homo sapiens son los más destacados debido al nivel de complejidad que aplicaban. Aunque los orígenes del modelamiento matemático se remontan a los tiempos de la Edad de Piedra, los primeros grandes avances de la modelación vinieron con la Antigua Grecia y con el Antiguo Cercano Oriente con el surgimiento de los números y funciones matemáticas. En los siglos siguientes, el entendimiento acerca de los modelos matemáticos se extendió hasta que se empezaron a establecer principios para poder estandarizar su naturaleza. Posteriormente, se agregaron mayores aplicaciones, tal como, la economía (2004).

Además, se presenta el ciclo de vida del modelamiento. Según Hürlimann, el modelamiento se divide en cuatro fases. En primer lugar, se procede con el reconocimiento del problema, etapa en la que se le asigna el nivel de importancia. En segundo lugar, la formulación del modelo, donde se construye la lógica matemática. Asimismo, se considera que la formulación es la etapa de mayor dificultad del proceso. En tercer lugar, está la solución. En esta etapa, se obtiene un resultado óptimo a partir del modelo propuesto en la etapa anterior. Finalmente, se realiza un análisis del resultado obtenido en la etapa de validación e interpretación. En este último paso del proceso de modelamiento se procede a darle una interpretación a los datos obtenidos para poderlos convertir en información de valor para la organización (1999). A continuación, se presentará un esquema que ilustre el flujo de las fases de modelamiento:

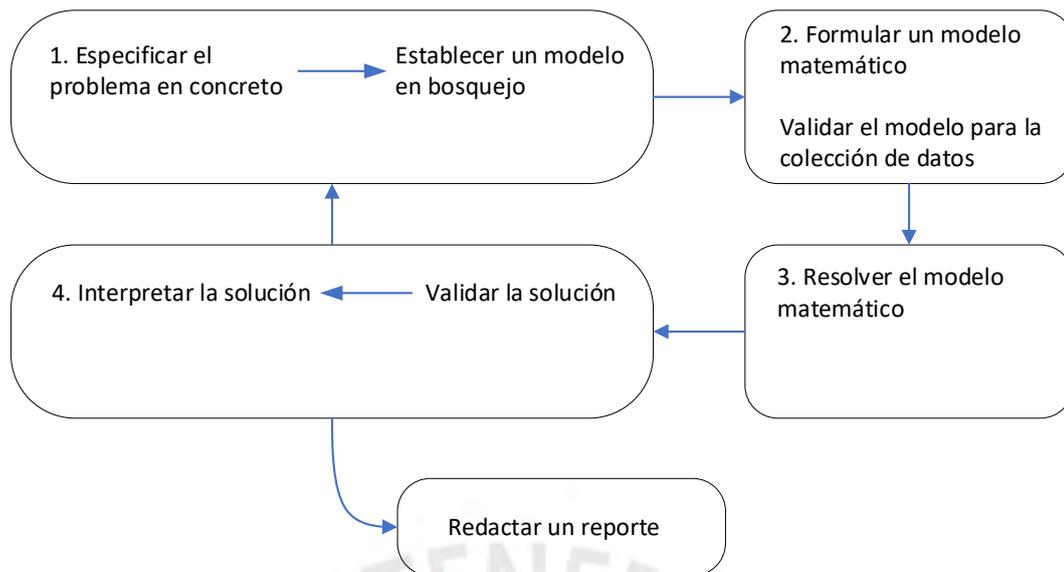


Figura 6. Ciclo de la modelación matemática.

Tomado de "Mathematical Modeling and Optimization", por Hürlimann, 1999

1.4.5. Clasificación de problemas de optimización

1.4.5.1. Programación Lineal

Dentro del alcance de la Programación Lineal, se encuentra la solución de un amplio campo de problemas. Lo que caracteriza principalmente a un problema es la linealidad que existe en las funciones e incógnitas. Si se compara con distintas ramas de modelamiento matemático, se podría inferir que existe preferencia por esta herramienta por no presentar mayor complejidad en su sintaxis; sin embargo, no es el principal motivo. Es evidente que existen métodos, principalmente computacionales, que son mucho más potentes que la Programación Lineal. No obstante, el nivel de popularidad y aceptación de esta herramienta es que está presente la etapa de formulación de análisis en vez de solución. Esto se puede deber a que una gran proporción del total de problemas de optimización pueden ser traducidos a un modelo de programación de carácter lineal. A menudo, es conveniente optar por un método lineal antes que otro de carácter más complejo y funcional debido a que su formulación es más fácil de definir. Sin embargo, para problemas de linealidad de carácter más especial, se opta

por métodos de programación lineal como el simplex (Yang, 2008). A continuación, se presenta una fórmula estándar de la programación lineal:

$$\text{minimizar } c_1x_1 + c_1x_1 + \dots + c_1x_1 \quad (7)$$

$$\text{sujeto a } a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1 \quad (8)$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n = b_2 \quad (9)$$

$$a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n = b_m \quad (10)$$

$$x_1 \geq 0, x_2 \geq 0, \dots, x_n \geq 0 \quad (11)$$

Del mismo modo, de acuerdo a Hillier y Liberman, indican la programación lineal sigue un conjunto de supuestos que deben estar implícitos dentro de los modelos de programación lineal (2015). A continuación, se presentarán los supuestos o principios más relevantes indicados por los autores:

A. Proporcionalidad

Sea x_j una variable de decisión y la función objetivo Z está denotada por c_jx_j , la contribución de cada variable de decisión a la función objetivo es proporcional a x_j . Siguiendo la misma lógica, la contribución de cada variable de decisión al lado izquierdo de la ecuación de la restricción es proporcional a x_j . Este supuesto mantiene la linealidad dentro de las ecuaciones en el modelo.

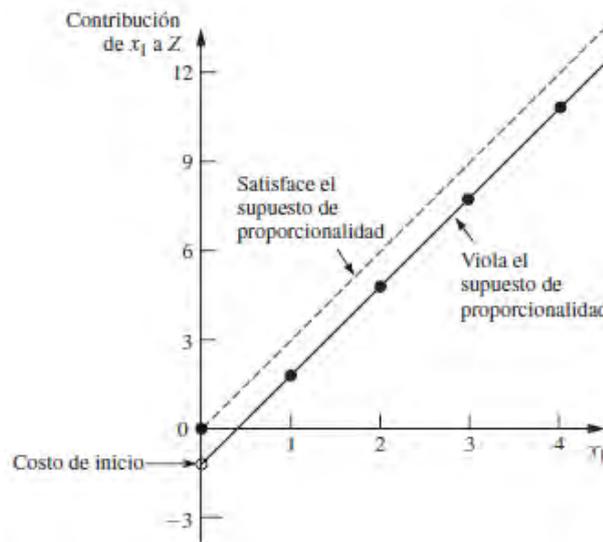


Figura 7. Principio de proporcionalidad.

Tomado de "Introducción a la investigación de operaciones", por Hillier y Liberman, 2015

B. Aditividad

La suma de las actividades individuales, es decir, las variables decisión, deben ser igual a la función objetivo o las funciones que describen las restricciones. Es decir, dichas funciones deben ser igual a la suma de los esfuerzos de las actividades. También, se puede definir como la suma de las contribuciones individuales es la función Z. En ciertos problemas, la aditividad no se cumple, puesto que algunas funciones o restricciones no son lineales.

C. Divisibilidad

En siguiente supuesto indica que las variables de decisión podrían adoptar cualquier valor dentro de un rango continuo. Esto quiere decir que las variables no se limitan únicamente a adoptar valores enteros. En otros términos, las variables que representan las actividades se pueden dividir en niveles fraccionales.

D. Certidumbre

Los coeficientes de las funciones de las restricciones y la función objetivo dentro del modelo son valores conocidos. Las variaciones en estos parámetros podrían

generar cierta incertidumbre en el alcance del modelo. Por ello, es importante realizar un Análisis de Sensibilidad para poder estudiar el rango de variabilidad de dichos parámetros y encontrar su nivel óptimo.

1.4.5.2. Problemas sin restricciones

Se podría sospechar que realizar una programación sin restricciones puede carecer de lógica, pero nada más alejado de la realidad. Existen dos principales motivos por el cual los problemas sin restricciones poseen aplicabilidad.

En primer lugar, las restricciones se encargan de acotar el alcance de un modelo. Entonces, si se amplía el alcance, de alguna u otra manera, podría crearse un indicio de que no existan restricciones. Un ejemplo de una restricción que podría no ser significativa podría ser el saldo presupuestal, puesto que se podrían conseguir fondos solicitando créditos, lo cual amplía el alcance del modelo. En este sentido, lo que se pretende explicar es que se puede tener un indicio de que no hay restricción cuando el alcance del modelo puede ser complementado o ampliado.

En segundo lugar, varios problemas con restricciones pueden tornarse ilimitados debido a que puede ocurrir que algunas variables sean dependientes de otras. Por ejemplo, si se tiene una restricción de igualdad con la forma $y_1 + y_2 = A$ podría reemplazarse el término y_2 por $y_2 = A - y_1$. Cabe resaltar que muchos modelos matemáticos y teoría han sido inspirados a partir de problemas sin restricción antes de proceder al modelo con restricciones (Luenberger, 2016).

1.4.5.3. Problemas restringidos

En la práctica, una amplia variedad de problemas se formula a partir de problemas restringidos. Esto sucede porque en una organización grande pueden existir diversos problemas de gran complejidad los cuales no pueden ser tratados con un modelo sin restricciones porque

normalmente se imponen para poder limitar el alcance. En otras palabras, por ejemplo, en una gran organización, si se quiere optimizar el plan presupuestal para una planificación, las alternativas de recaudación de presupuestos se podrían subdividir en otro problema restringido y así sucesivamente. Por lo general, este tipo de problemas se definen a través de la siguiente expresión matemática:

$$\text{minimizar } f(x) \quad (12)$$

$$\text{sujeto a } h_j(x) = 0, i = 1, 2, \dots, m \quad (13)$$

$$g_j(x) \leq 0, j = 1, 2, \dots, m \quad (14)$$

$$x \in S \quad (15)$$

Por lo general, las funciones descritas en el problema requieren que tengan un comportamiento continuo o presentar derivadas continuas. Del mismo modo, las variables suelen tener carácter continuo (Luenberger, 2016).

1.4.6. Características de los problemas de optimización

Según Krichen y Chaouachi, los problemas de optimización se pueden clasificar según la naturaleza de la función objetivo, las variables y restricciones (2014). Enfocándose en las características de los mencionados previamente, los autores han definido los siguientes puntos:

- El número de variables de decisión:

Si se trata de una variable de decisión, se estaría haciendo referencia a un problema de optimización, sino se trataría de un juego que se podría clasificar de cooperativo o no cooperativo.

- El número de objetivos:

Este atributo determina la naturaleza de la solución que se obtendrá. Si se formula solo un objetivo. No obstante, si se trata de más de un objetivo dentro del modelo, se podrá obtener un conjunto de soluciones óptimas.

- La linealidad:

Si, en el modelo, las restricciones y la función objetivo son de carácter lineal, significa que se está enfrentando un problema de optimización lineal. Si las restricciones o la función objetivo no son lineales, la solución del sistema será de un nivel más complejo.

- La naturaleza de las variables de decisión:

Se trata de un problema de optimización combinatoria si se está trabajando con variables de decisión de naturaleza entera.

1.4.7. Aplicaciones

Según Eiselt y Sandblom, la optimización matemática tiene un alto nivel de adaptabilidad respecto a su aplicación en diversos sectores de las industrias. En este apartado, se van a presentar una serie de aplicaciones de la optimización matemática en diversas casuísticas. Cabe resaltar que las aplicaciones mostradas a continuación pueden ser extrapoladas a diversos sectores adaptando la lógica del modelo. El principal enfoque en los modelos es el entendimiento y definición de las variables y funciones a tratar (2010).

Según Eiselt y Sandblom, las principales aplicaciones en las industrias son las siguientes:

1.4.7.1. Planeamiento de Producción

La optimización matemática puede ser muy útil para realizar la planificación estratégica de la producción. Por ejemplo, se puede calcular el nivel óptimo de producción de una empresa. Para poder ejemplificar se podría definir la utilidad a obtener por cada línea de producto y las restricciones podrían ser las capacidades de las máquinas manufactureras. Evidentemente, no se pueden definir la función objetivo y las restricciones sin definir las variables de decisión que, dado el caso, sería el nivel de producción de cada línea de producto. Un ejemplo estándar para ejemplificar este modelo podría ser el siguiente:

$$\text{maximizar } u_1x_1 + u_2x_2 + u_3x_3 \quad (16)$$

$$\text{sujeto a } a_1x_1 + a_2x_2 + a_3x_3 \leq B \quad (17)$$

$$x_1 \geq 0, x_2 \geq 0, x_3 \geq 0 \quad (18)$$

En este ejemplo las variables x_i representan los niveles de producción de las diversas líneas de producto. Asimismo, los coeficientes a_i son las tasas de tiempo de producción por unidad y B sería la capacidad de la planta. Finalmente, u_i representa la utilidad unitaria por cada producto y esta se inserta dentro de una función de maximización, puesto que se busca incrementar las ganancias del negocio mediante una planificación óptima.

1.4.7.2. Problemas de asignación

Los problemas de asignación son recurrentes en diversas organizaciones, ya que la asignación de diversos recursos, tales como, personal, dinero, materia prima suele ser de naturaleza escasa. Es por ello que se generan modelos matemáticos que permiten optimizar la asignación de estos recursos para poder incrementar el nivel de aprovechamiento de ellos y ser significativamente más eficiente en los procesos.

La asignación de personal a un conjunto de actividades o tareas suele ser un problema frecuente de optimización matemática. Para poder asignar capital humano a diversas actividades u operaciones, se debe tener en cuenta ciertas restricciones, por ejemplo, las horas disponibles, el requerimiento de personal por actividad, el presupuesto por concepto de sueldos y salarios, y la cantidad de personal con la que se dispone. Estos últimos atributos descritos pueden ser traducidos dentro de una serie de restricciones que, posteriormente, van a limitar el alcance del modelo. La definición de la función objetivo dependerá de la naturaleza del problema y los objetivos de la organización. Del mismo modo, las variables de decisión pueden ser la cantidad de personal asignados a cada área respectivamente.

Otro problema recurrente es la asignación de recursos económicos a múltiples actividades o proyectos de inversión. En este sentido, los saldos disponibles para realizar la

inversión pueden ser un limitante a la hora de realizar la asignación. Por ello, es importante optimizar la utilización de este recurso. La función objetivo debería maximizar la utilidad obtenida de la repartición de la inversión o, en un caso pesimista, reducir la pérdida.

1.4.7.3. Programación de horarios

En cierta medida, el modelo de asignación posee cierto nivel de semejanza con el modelo de asignación. No obstante, este tipo de aplicación posee sus propios matices respecto a la asignación de recursos convencional. La asignación de turnos es un caso recurrente dentro las aplicaciones de la optimización matemática, puesto que el volumen de trabajadores no se mantiene constante con el paso de las horas. Además, dependiendo del rubro en el cual se desea aplicar el modelo, puede cambiar la lógica de la formulación. Por ejemplo, la programación de horarios de los trabajadores dentro de una clínica y un restaurante son totalmente diferentes debido a que las necesidades de personal de ambas organizaciones poseen sus propias características.

También, cabe resaltar que el resultado de este modelo puede propiciar la toma de decisiones dentro de la organización, ya que, según las alternativas que maneja el negocio, se podría evaluar entre diferentes medidas, por ejemplo, tercerizar cierto porcentaje de la fuerza laboral, contratar o despedir personal o asignar turnos de horas extra.

1.4.7.4. Producción dinámica - modelos de inventario

La aplicación de estos modelos se diferencia principalmente respecto a los descritos previamente, ya que la lógica de la formulación, además de centrarse en el “cuánto”, debe darle una importancia significativa en el “cuándo” en términos de la programación de la producción. Se debe tomar decisiones con especial cautela respecto a la planificación para, de esta manera, no incurrir en una oferta insatisfecha.

En estos modelos, se debe analizar la variabilidad de la demanda en términos de estacionalidad y tendencia para incluir dichas consideraciones en el análisis. La incógnita de cuándo producir afecta al plan de producción y a los costos que se deducen de este proceso. Esto se debe a que, si se decide producir con anticipación para poder disminuir la posibilidad de rotura de stock, los costos por concepto de mantenimiento de inventarios se incrementarán.

Finalmente, a partir del modelo de optimización, se obtendrá una solución que estará influenciada por múltiples factores significativos, tales como, costos de producción, costos de mantenimiento, entre otros.



CAPÍTULO 2. ESTADO DEL ARTE

En este capítulo, se ilustrarán casos con la finalidad de demostrar la aplicabilidad de las metodologías de Analítica y Optimización Matemática. Se detallará la problemática inicial, la propuesta con la aplicación de la herramienta seleccionada a aplicar y las mejoras obtenidas en el sector de estudio.

2.1. Modelo predictivo de la tasa de abandono de los clientes jubilados aplicando herramientas de “*Big Data Analytics*”

Autor: Shirazi y Mohammadi

Año: 2018

La industria bancaria, a lo largo de los años, ha evolucionado rápidamente debido a la creciente innovación tecnológica y a las necesidades cada vez más cambiantes y exigentes de los clientes. En este escenario variable, surge una de las variables más importantes para la entidad bancaria: la retención del cliente. La gestión de la relación con el cliente se enfoca principalmente en crear estrategias con el objetivo de disminuir la tasa de abandono de los usuarios. Esta tasa es definida como el porcentaje anual de los clientes que abandona la relación comercial. Uno de los segmentos que se ha identificado como prioridad de las estrategias es el de las personas que abandonan la entidad. En este segmento, se encuentran las personas cuyo rango de edad oscila entre los 51 y 70 años. La población de estudio para este modelo predictivo constará de dos grupos principales: grupos adinerados masivos y no masivos, los cuáles fueron analizados entre los periodos del 2012 al 2015 y se encontró que el ratio de retiro era mayor cuando las personas eran clientes con un mayor periodo dentro del banco y que la tasa de deserción ha permanecido en un 5% a lo largo de los años como se muestra en la Figura 8. Asimismo, la Figura 9 indica que los clientes masivos respecto a los clientes no masivos tienen una relación de retiro de 3:1 respectivamente, en otras palabras, los clientes masivos adinerados son aproximadamente dos veces más propensos a retirarse.

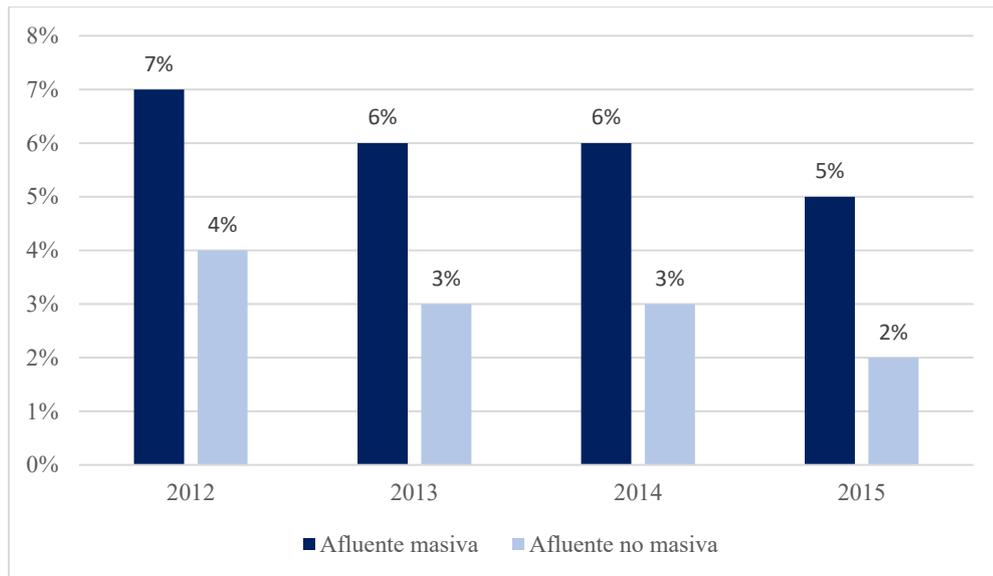


Figura 8. La tasa de deserción de los clientes masivos frente a los no masivos 2012-2015.

Tomado de “Modelo predictivo de la tasa de abandono de los clientes jubilados aplicando herramientas de “Big Data Analytics”, por Shirazi y Mohammadi, 2018.

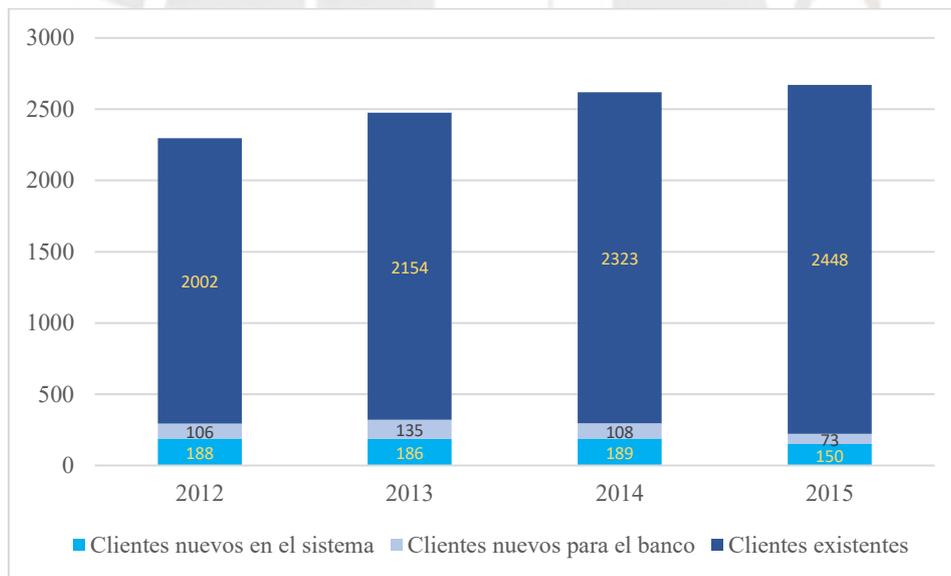


Figura 9. Distribución de clientes jubilados 2012-2015.

Tomado de “Modelo predictivo de la tasa de abandono de los clientes jubilados aplicando herramientas de “Big Data Analytics”, por Shirazi y Mohammadi, 2018.

De lo mencionado anteriormente, se colige que las estrategias de CRM se enfocarán principalmente en los clientes dado el mayor retorno que se obtendrá. Sin embargo, para

realizar los modelos predictivos correspondientes y responder ante las necesidades de los clientes, las herramientas actuales del banco objetivo no son suficientes. Debido a esta situación, se aplicarán diversas herramientas de Analítica tales como árboles de decisión y regresión. En primer lugar, se establecieron 5 hipótesis que al finalizar la metodología serán validados o rechazados. Las hipótesis son las siguientes:

H_1 : El ratio de abandono tiene una correlación significativa con los eventos de retiro.

H_2 : El periodo de permanencia del cliente tiene una correlación significativa con la tasa de abandono.

H_3 : La tendencia de abandono de los clientes masivos es diferente que el de los no masivos.

H_4 : El comportamiento de compra online tiene una correlación significativa con la tasa de abandono.

H_5 : El tipo de comportamiento de compra tiene una correlación significativa con la tendencia de abandono.

La metodología que se emplea comienza con la recopilación de la cantidad de datos de las diversas plataformas, en las cuales, interactúan los clientes, tales como, banca por internet o centros físicos. La recopilación alcanzó 3 millones de datos, de los cuáles fueron filtradas aquellas personas que hayan tenido una participación mayor a 3 meses y las clasificó en: clientes existentes, clientes nuevos (personas que se incorporaron al banco durante la etapa de análisis) y los clientes existentes que no tuvieron la edad del segmento en un inicio, pero con el avance la alcanzaron y se convirtieron en potentes clientes a retirarse de la entidad bancaria. Al finalizar dicha clasificación, se realizaron los análisis de datos de píxeles, que son aquellos que exploran el comportamiento de los clientes en los canales digitales del banco, a través de la herramienta “*Hadoop*” que permitió la integración de la data en la plataforma SAS Data Loader para que se obtenga la información en tiempo real y se almacene en una base de datos No SQL. Al momento de realizar este análisis, la compañía se percató de una limitación, la

cual consiste en que los clientes que se retiran no se comunican con la entidad bancaria para comunicar el retiro y por ello en la base de datos del banco existen clientes que han abandonado la entidad, pero son considerados como clientes. Para que esta situación no sea una limitante del estudio, se utilizó la técnica de CLV (Valor de tiempo de vida del cliente) y el cálculo del “*Money-In*” para identificar si un cliente es activo o pasivo. Asimismo, para la identificación de señales, se han determinado 4 grupos: estilo de vida, retroalimentación del cliente, búsqueda de información y comportamiento. Luego de esta clasificación, la población se dividió en 2 grupos: clientes retirados y clientes no retirados; y cada uno de estos se dividió en retenido y abandono. Este proceso de clasificación se llevó a cabo debido que las estrategias de retención son específicas para cada tipo de clientes. De este análisis, se obtuvo que las personas con un saldo menor a \$4,000.00 durante un periodo de 6 meses son clientes, probablemente, que abandonaron la entidad o están en el proceso. Asimismo, también se encontró que aquellos con saldo mayor a \$10,000,000.000 son clientes leales que continuarán operando en la empresa. Ambos grupos fueron excluidos del análisis dada la extrema situación económica de sus cuentas.

Este análisis arrojó que las personas con un crecimiento del 10% de MI son clientes que seguirán siendo leales con la entidad bancaria; por el contrario, aquellos con una reducción de 10% del MI, dentro de los 6 meses, eran clientes que posiblemente abandonen la relación comercial. Al finalizar el modelo de clasificación de estas variables, el análisis avanza a la siguiente etapa en la cual se estudia el comportamiento de aquellos clientes que se retiran de la entidad. Para segmentar a dichos clientes, se aplica la herramienta CRT en un árbol binario. De esta investigación, se encuentra que el 95.6% de los clientes se encuentran en la edad establecida y son propensos a retirarse. En primera instancia, se realizó un análisis preliminar en el cual se encontró que el 8.7% de la población son considerados como clientes que abandonaron el banco; mientras que, en este análisis con la aplicación de herramientas de

Analítica, el porcentaje de la población que abandona es el 24%. En base a estos resultados, se observa con claridad que el estudio presentado en el banco objetivo indica una mejora del 175% en la precisión de identificación de clientes. Asimismo, las hipótesis previamente mencionadas son evaluadas a través de un análisis estadístico de los estudios que se llevaron a cabo y se obtuvieron los siguientes resultados:

H_1 : El ratio de abandono tiene una correlación significativa con los eventos de retiro.

Del análisis estadístico, se obtuvieron los siguientes resultados de las pruebas realizadas como se muestran en la Figura 10. Se observa que el p-value es aproximadamente 0, con lo cual se valida la hipótesis 1, en efecto, sí existe una correlación significativa entre el ratio de abandono y los eventos de retiro.

Table of Retire_Ind by attr_typ			
Retire_Ind	attr_typ		
Frequency			
Percent			
Row Pct			
Col Pct	NON-Ret	Ret	Total
NON-Attr	2176823	509617	2686440
	71.19	16.67	87.86
	81.03	18.97	
	86.24	95.49	
Att	347191	24055	371246
	11.35	0.79	12.14
	93.52	6.48	
	13.76	4.51	
Total	2524014	533672	3057686
	82.55	17.45	100.00

Statistics for Table of Retire_Ind by attr_typ			
Statistic	DF	Value	Prob
Chi-Square	1	35320.0567	<.0001
Likelihood Ratio Chi-Square	1	43194.4035	<.0001
Continuity Adj. Chi-Square	1	35319.1898	<.0001
Mantel-Haenszel Chi-Square	1	35320.0452	<.0001
Phi Coefficient		-0.1075	
Contingency Coefficient		0.1069	
Cramer's V		-0.1075	

Fisher's Exact Test		
Cell (1,1) Frequency (F)	2176823	
Left-sided Pr <= F	.	
Right-sided Pr >= F	.	
Table Probability (P)	.	
Two-sided Pr <= P	.	

Figura 10. Correlación entre el ratio de abandono y los eventos de retiro.

Tomado de “Modelo predictivo de la tasa de abandono de los clientes jubilados aplicando herramientas de “Big Data Analytics”, por Shirazi y Mohammadi, 2018.

H_2 : El periodo de permanencia del cliente tiene una correlación significativa con la tasa de abandono.

Para rechazar o validar esta hipótesis, se realizó una prueba ANOVA, la cual arrojó un valor P menor a 0.0001. Esto indica que la hipótesis es válida, es decir, sí existe correlación significativa entre el periodo de permanencia y la tasa de abandono. Asimismo, se encontraron datos atípicos por lo que el segmento analizado se redujo a aquellas personas con menos de 45 años en el banco.

H_3 : La tendencia de abandono de los clientes masivos es diferente que el de los no masivos.

Los clientes masivos adinerados tienen una tasa de abandono mucho más baja que los clientes no masivos. Este escenario se presenta ya que los clientes adinerados masivos tienen una estrecha relación con sus planificadores financieros y se vinculan en alto grado con la entidad bancaria. Asimismo, el análisis estadístico arroja un p-value cercano a 0, lo cual indica que existe una alta correlación entre el tipo de cliente y la tasa de abandono.

H_4 : El comportamiento de compra online tiene una correlación significativa con la tasa de abandono.

Los resultados demuestran que la tasa de abandono no varía si las personas compran online; sin embargo, esta hipótesis no se rechaza completamente ya que se necesita una mayor cantidad de datos del comportamiento online del segmento de retirados.

H_5 : El tipo de comportamiento de compra tiene una correlación significativa con la tendencia de abandono.

Se encontró que las personas que abandonan las relaciones comerciales y utilizan las plataformas físicas son un 7%, mientras que las que realizan transacciones a través de plataformas digitales tiene un 5.4%. Esta diferencia no es significativa y, por ende, esta hipótesis se rechaza.

2.2. iCARE: Un marco para análisis de clientes bancarios basados en Big Data

Autor: Sun, Morris, Xu, Zhu y Xie

Año: 2014

La era del Big Data ha revolucionado crecientemente cada sector de la industria. En este contexto, el sector bancario ha sido parte de esta transformación debido a que el flujo de información que circula dentro de las bases de datos conforma un gran volumen, tiene una diversidad de formatos y crece a una velocidad rápida. Esta es una característica que, con la metodología correcta de análisis de datos, permitirá a los bancos tomar mejores decisiones para incrementar el nivel de satisfacción al cliente.

La metodología que se utiliza para explotar la información de las bases de datos es el análisis inteligente de clientes para el reconocimiento y la exploración con el objetivo de determinar los patrones de comportamiento de los diversos clientes de los bancos para determinar con precisión la oferta de productos que satisfarán sus necesidades. Para visualizar el impacto y resultados de este método, se aplicó en un banco del Sureste de China, el cual se encontraba ante dos retos. El primero de ellos es el manejo efectivo de la extensa cantidad de datos que posee la entidad bancaria y el segundo de ellos es la capacidad de generar valor agregado del análisis de data para convertir este en una ventaja competitiva para el banco. Asimismo, tenía la necesidad de convertir los clientes que asisten y realizan sus transacciones de manera convencional en plataformas físicas se cambien a las plataformas digitales con el objetivo de reducir los costos operacionales. En este contexto, el análisis inteligente de clientes para reconocimiento y exploración, el cual será nombrado en las siguientes como ICARE por sus siglas en inglés, se aplicó para la resolución de los desafíos presentados.

El método ICARE consta de 4 fases: adquisición de datos, preparación de datos, modelado de datos y la aplicación de estos. Esta es una herramienta que trabaja con diversas fuentes de datos y aplicaciones de IBM como SPSS que utilizan “*parallel computing*” para la utilización y comprensión de la data analizada. La aplicación de ICARE comenzó con

la recolección de información, aproximadamente, de un tamaño de 20 terabytes de datos, los cuales fueron identificados como ambiguos, con diversos formatos y códigos incompatibles. Posteriormente, los datos recogidos se transformaron al formato estándar para poder cargarse al *BigInsights*, la cual es una plataforma digital que se basa en el método *Hadoop*. Luego con la ayuda de *Big SQL* realizar una limpieza y preparación de datos con el objetivo de minimizar el ruido de la data inconsistente de los datos atípicos. Al culminar esta etapa, la información se integra en tablas de la plataforma *BigInsights* para consolidar los datos de las diversas fuentes. La data estructurada se extrae con la herramienta SPSS, la cual arrojó 200 atributos de los clientes, tales como, transacciones e información personal de estos. Al evaluar la calidad de los datos, se encontró data irrelevante de las diversas fuentes, la cual fue mapeada con el código del cliente para identificar los clientes digitales y los no digitales. Este análisis es descrito en la Figura 11, la cual indica los diversos procedimientos antes mencionados. Asimismo, muestra las fuentes de data, tales como, el sistema de banca en línea, centro de información, plataforma de pago y el sistema principal. El objetivo principal de esta infraestructura es la determinación del patrón preciso de abandono de clientes que realizan transacciones de manera online.

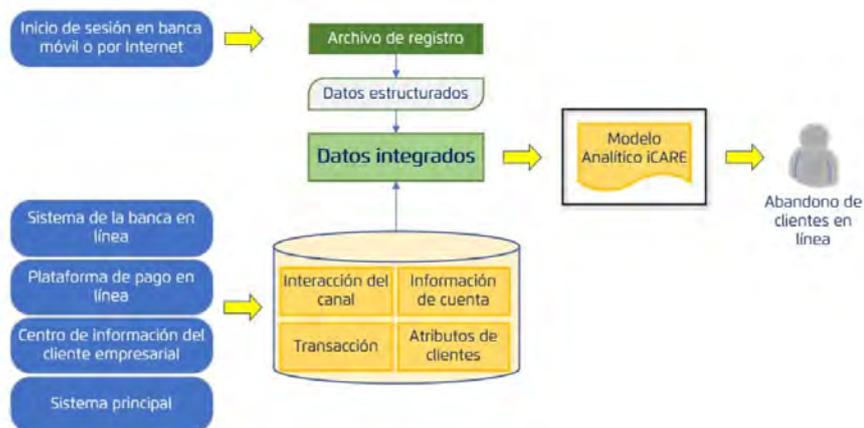


Figura 11. La infraestructura de ICARE de la solución del caso.

Tomado de “Análisis inteligente para reconocimiento y exploración: Un marco para análisis de clientes basados en Big Data”, por Sun, Morris, Xu, Zhu y Xie, 2014.

Al implementarse la metodología ICARE, se obtuvo que el modelo es 1.59 veces más preciso que la línea base con la cual se había trabajado en la entidad bancaria. Esta significativa diferencia se muestra en la Figura 12. Se observa que, a un mayor número de consumidores identificados, la línea de precisión decae, es decir, el % de precisión disminuye. En base a este contexto, se concluye que el modelo es satisfactorio, pero existe una amplia posibilidad de mejorarlo para analizar mayor cantidad de data y no disminuir la precisión.

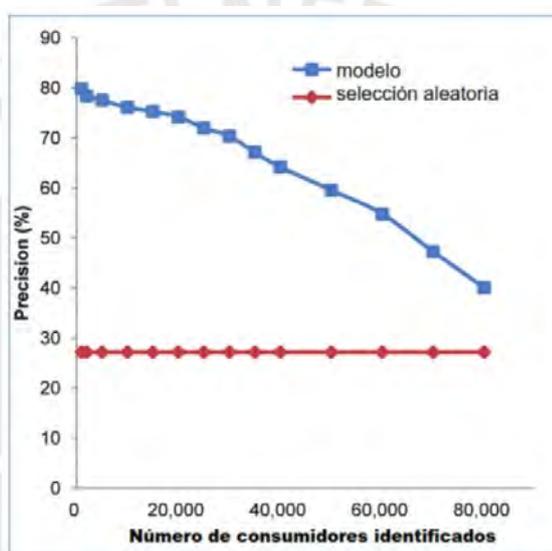


Figura 12. La infraestructura de ICARE de la solución del caso.

Tomado de “Análisis inteligente para reconocimiento y exploración: Un marco para análisis de clientes basados en Big Data”, por Sun, Morris, Xu, Zhu y Xie, 2014.

Además, es importante para el banco, la velocidad con la que los datos son analizados debido a que permite la generación de estrategias comerciales que respondan rápidamente las necesidades de los clientes. En este escenario, ICARE ayudó al banco chino ya que el modelo implementado se ejecutó 12 veces más veloz que el anterior, tal como se indica en la Figura 13.

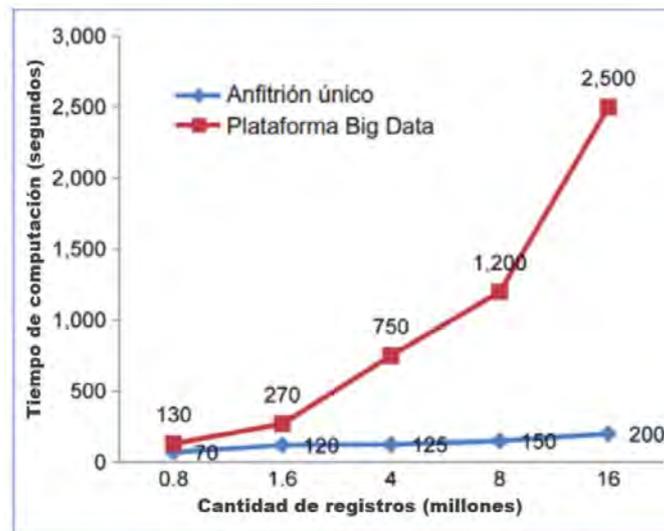


Figura 13. La infraestructura de ICARE de la solución del caso.

Tomado de “Análisis inteligente para reconocimiento y exploración: Un marco para análisis de clientes basados en Big Data”, por Sun, Morris, Xu, Zhu y Xie, 2014.

2.3. Retención de clientes en el sector bancario mediante técnica de minería de datos predictiva

Autor: Chitra y Subashini

Año: 2011

Los clientes, en la actualidad, son cada vez más exigentes y selectivos al momento de elegir las entidades bancarias. Dado este contexto, la rotación de los clientes se ha convertido en un problema para los bancos ya que los clientes cambian con frecuencia de entidad financiera si existe alguna propuesta de valor que sea más atractiva. En este sentido, las organizaciones bancarias se convierten en compañías más competitivas porque desean situarse como aquella líder del mercado que otorgue los mejores servicios a los menores costos. Asimismo, según investigaciones nacionales e internacionales, existen 4 necesidades que los bancos deberán de poseer para convertirse en una entidad competitiva. Estas son las siguientes: retención de clientes, enfoque tecnológico, segmentación de mercado y productividad.

Entre estas, la primordial de ellos es la retención de clientes debido a que, como se mencionó anteriormente, genera un gran impacto en el crecimiento de la compañía bancaria y,

en consecuencia, determina la rentabilidad del banco. El área de Gestión de Relaciones con los clientes, más conocido por sus siglas en inglés como CRM, es la cual se encarga de recopilar y consolidar la información obtenida de los clientes para que dicha data sea analizada a través de modelos estadísticos y se encuentren atributos de gran relevancia que permitan conocer las necesidades de los clientes y, de este modo, proponer estrategias que generen un impacto positivo en el cliente.

La autora propone la aplicación de diversas herramientas de Minería de Datos para contrarrestar la rotación de clientes, la cual es una de las problemáticas que impide el crecimiento de los bancos. En primer lugar, se analizaron los factores que provocan la rotación de los clientes, como, por ejemplo, las situaciones en las cuales los usuarios al no encontrar agencias o ATMs cercanos a sus viviendas o trabajos optan por cambiar de compañía bancaria. Estos son hechos que las entidades bancarias no encuentran en su base de datos por lo que es un reto encontrar datos de las causas para el análisis de estos. Debido a esta observación, se comenzó con la recopilación de data, la cual posteriormente fue comparada con la data histórica para encontrar semejanzas entre ellas y establecer una guía que permita identificar las características de los clientes que abandonan el banco. De esta manera, se encontrarán datos significativos que se convertirán en conocimiento utilizando técnicas de minería de datos predictivos.

La minería de datos, como se determina y explica en el marco teórico del presente trabajo de investigación, es aquel sistema que consiste en el procesamiento y análisis de los datos en conjunto con herramientas computacionales para identificar patrones significativos y reglas relevantes. Estos “*inputs*” permiten, a las entidades bancarias, una mejor toma de decisiones. La cantidad de datos que serán analizados será muy grande y debido a ello se analiza, en primera instancia, la aplicación de un método para reducir aquellos datos no significativos; sin embargo, se propone aplicar un cronograma que varíe dependiendo del cliente a analizar. Esta

segunda propuesta es más lógica y precisa ya que cada cliente abandona el banco en diferente periodo y, de este modo, no se excluirían datos y los resultados serán más certeros.

A continuación, se aplica la herramienta árbol de decisión para dividir, según atributos categóricos y numéricos, la data recopilada. Esta herramienta utilizará el método “CART” para distribuir en diferentes nodos las diversas categorías de la data aplicando índices Gini y generando reglas de decisión y patrones que permitan un mejor conocimiento de los clientes en su conjunto.

Luego del análisis de la clasificación de una población de 1000 datos, de los cuales 700 son de entrenamiento y 300 de muestra. a través del árbol de decisión se encontraron variables significativas como el comportamiento de cliente dependiendo de factores demográficos, percepciones, entre otros. Estas variables fueron los datos de entrada para formular los modelos predictivos para cada estado predefinido en la propuesta de mejora. En las siguientes tablas, se observan la cantidad de predicciones que se llevaron a cabo y el indicador de éxito de la predicción.

Tabla 2.

Tasa de éxito de los datos de entrenamiento.

Clase	Muestras Totales	Predicción de Activo	Predicción de Abandono	Éxito
Activo	545	455	90	83.48
Abandono	155	15	140	90.32

Nota: Tomado de “Customer Retention in Banking Sector using Predictive Data Mining Technique”, por Chitra y Subashini, 2011.

Tabla 3.

Tasa de éxitos de los datos de la prueba.

Clase	Muestras Totales	Predicción de Activo	Predicción de Abandono	Éxito
Activo	216	179	37	82.87
Abandono	84	7	77	91.66

Nota: Tomado de “Customer Retention in Banking Sector using Predictive Data Mining Technique”, por Chitra y Subashini, 2011.

De las tablas, se observa que el indicador de éxito de los clientes es relativamente menor y esto es una consecuencia de que algunos clientes identificados como activos según la entidad bancaria presentaron características de clientes que abandonan el banco. Se concluye que las compañías financieras al apoyarse en métodos estadísticos, herramientas de minería de minería de datos logran formular un modelo predictivo con un índice de éxito alto, es decir, logra una predicción certera para la identificación de los clientes abandonarán la entidad bancaria y, de esta manera, el área de CRM logró plantear estrategias de retención a tiempo que impidan el abandono y rotación de clientes.

2.4. Identificación de clústeres de clientes que utilizan los servicios de la banca electrónica

Autor: Ivan Soukal y Martina Hedvicaková

Año: 2010

El presente estudio de casos se enfoca en el mercado de RCBS, que es la abreviatura de “*Retail Core Banking Services*”. Este conjunto de términos se refiere a los servicios financieros que se ofrecen a través de las diversas plataformas digitales de las entidades bancarias como, por ejemplo, realización de transacciones monetarias y no monetarias, consultas financieras, administración de saldos y servicios adicionales. Esta investigación se centra principalmente en los países de la Unión Europea ya que dichos países se encuentran frente a una problemática semejante. Esta problemática consiste en la poca transparencia que existe de la información de los costos de los productos debido a la falta de claridad de las estructuras de tarifa que los bancos muestran a los clientes. Esto, en consecuencia, genera insatisfacción en los clientes ya que no logran comparar el beneficio/costo que obtendrán al realizar la selección del banco donde realizarán las operaciones. La problemática que esta empresa presenta es la escasez del conocimiento de sus usuarios y, en consecuencia, la inconsistencia de las estrategias

Ante esta situación, el banco en cuestión tomó en consideración la aplicación de un sistema experto de RCBS, el cual en las siguientes líneas será llamado como “La Calculadora”. Este sistema utilizó el análisis de Clúster, una de las herramientas del *Big Data Analytics* que permite segmentar y clasificar a los clientes y productos a través de diferentes variables que compartan características similares. La Calculadora es el servicio que permite, a los clientes de las entidades bancarias, comparar los costos con el uso de RCBS y recomendar aquellos productos que satisfagan las necesidades al menor costo. El método para la recolección de los datos que serán procesados en el sistema es la clasificación de la retroalimentación de los clientes respecto al servicio que reciben en la plataforma de banca electrónica a través de un formulario con diversas preguntas. De esta manera, las entidades bancarias logran reunir en un único sistema información valiosa que sea clara y transparente con el objetivo de que sus usuarios puedan elegir la opción que logró satisfacer sus necesidades al menor costo. Debido a la cantidad de encuestados que el sistema requirió, se aplicó el método de “*K-means*”. El tratamiento se llevó a cabo en dos poblaciones, una de ellas incluye los clientes extremos y la otra los excluye.

- Tratamiento con clientes extremos

En este procesamiento, se recolectaron 8804 respuestas para 21 variables que fueron evaluados mediante “*listwise*”. Estas variables fueron clasificadas en diferentes clusters y se calculó el porcentaje de cada uno de ellos para lograr analizarlos como porcentaje de la totalidad de la población evaluada.

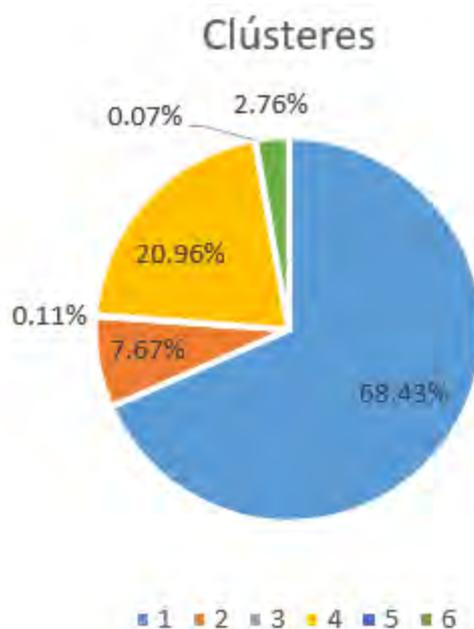


Figura 14. Clústeres de tratamiento con clientes extremos.

Tomado de "Identificación de clústeres de clientes que utilizan los servicios de la banca electrónica", por Ivan Soukal y Martina Hedvicaková, 2010

De la imagen previa, se observa que los clientes se categorizaron en 6 clústeres. En primer lugar, el clúster 1 posee el 68.43% de la población. En este, se identificó que los clientes comparten la frecuencia de retiro de dinero de los ATMs. Asimismo, dichos usuarios son aquellos que realizan la mayoría de sus operaciones a través de la banca electrónica. Se determinó que uno de cada 10 clientes, pertenecientes a este clúster, realizan transacciones una vez al mes en establecimientos físicos.

En segundo lugar, el clúster 2 es el opuesto al clúster 1 ya que es aquel en el que la mayoría de sus usuarios se inclinan por realizar sus operaciones en establecimientos físicos y muy rara vez a través de la banca por Internet. En este clúster, la cantidad de personas es muy reducida.

En tercer lugar, el clúster 4 es aquel cuyas características son similares al clúster 1 pero la diferencia radica en la frecuencia del uso de las RCBS por mes ya que en este segmento los clientes utilizan un 50% más que los del primer clúster.

En cuarto lugar, el clúster 6 representa a aquellos clientes que realizan varias transacciones mensualmente y la mayoría de sus operaciones las realizan virtualmente a excepción de los depósitos. Por último, los clústeres 3 y 5 son aquellos usuarios con la mayor frecuencia de transacciones.

- Tratamiento sin clientes extremos

Para una clusterización más certera y precisa que entregue información valiosa para categorizar a los clientes de acuerdo a las variables analizadas, se excluyeron las personas cuyas características se encontraban en los extremos de los segmentos de las variables. Del cálculo de los clústeres de la población, se encontraron los siguientes porcentajes:

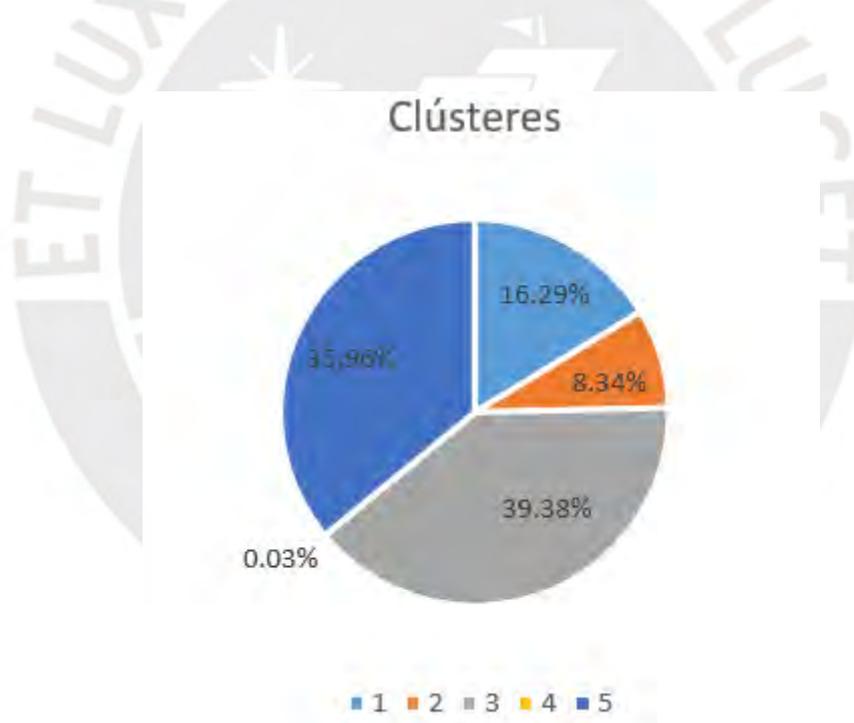


Figura 15. Clústeres de tratamiento sin clientes extremos.

Tomado de “Identificación de clústeres de clientes que utilizan los servicios de la banca electrónica”, por Ivan Soukal y Martina Hedvicaková, 2010

En primer lugar, el clúster número 3 es aquel que posee el mayor porcentaje de la población analiza, este clúster se caracteriza por la utilización de la banca electrónica. La

interpretación de estos clientes es similar al clúster 1 del primer tratamiento, ya que uno de cada 10 usuarios se dirige una vez al mes a establecimientos físicos para realizar alguna operación.

En segundo lugar, el clúster 1 es el grupo más activo comparando la cantidad de transacciones de la población y en este segmento se encuentran aquellos que utilizan ATMs en el extranjero.

En tercer lugar, se encuentra el clúster 2, cuyo segmento tiene una cantidad muy reducida de clientes cuya frecuencia de uso de RCBS es similar al de los demás segmentos, pero la diferencia radica en que ellos prefieren recibir los servicios físicamente.

Por último, el clúster 5 que representa el 35.96% de la población son aquellas personas que no realizan una significativa cantidad de operaciones en las entidades bancarias pero las pocas que hacen son a través de la Banca por Internet.

El análisis de clústeres dependerá de la población analizada y de los objetivos que busca el estudio. Asimismo, para el análisis se deberá excluir los datos que son extremos para que no influyan en los segmentos. El tratamiento 1 utilizó los clientes extremos mientras que el segundo tratamiento no. El primer tratamiento indica que los clientes tienen una gran preferencia por la Banca por Internet, aunque existe un grupo pequeño que prefiere realizar operaciones en establecimiento físicos. Asimismo, los segmentos comparten la frecuencia del uso de ATMs siendo esta 3 veces al mes. En comparación con el tratamiento 1, el tratamiento 2 permitió una mejor clasificación de clientes dado que separó a aquellos clientes extremos y del grupo restante los dividió para poder separar los clientes pasivos de los clientes promedio y esta es una característica crucial para el área de Marketing y el planteamiento de sus estrategias de atracción y retención.

2.5. Enfoque de clasificación y redes neuronales para identificar el comportamiento del cliente en el sector bancario: un estudio de caso de un banco internacional

Autores: Ogwueleka, Misra, Colomo-Palacios, Fernandez

Año: 2012

El objetivo principal de las entidades bancarias es satisfacer las necesidades de los clientes. Para cumplir dicha finalidad, las organizaciones bancarias plantean e implementan estrategias de negocio que ayuden a la creación y el mantenimiento de relaciones sólidas y rentables con los usuarios. Los bancos, a lo largo de los años, buscan métodos para encontrar soluciones efectivas que generen valor y optimicen el flujo de las operaciones y servicios que ofrecen. En este panorama, el avance de las herramientas analíticas se vuelve atractiva para poder determinar aquellas oportunidades de mejora que se deben realizar. En este caso la herramienta que será aplicada es la red neuronal artificial, conocida por sus siglas en inglés como ANN. Esta será aplicada por el Banco Internacional, la cual es una entidad bancaria que ofrece servicios financieros a las entidades pertenecientes a la banca minorista, tales como, las personas naturales y pequeñas empresas. Se encarga de gestionar las tasas de interés y administrar la oferta monetaria que circula en la economía. Asimismo, funciona como prestamista del Gobierno en épocas de crisis. Esta entidad, como las demás, se encuentra ante la incertidumbre del comportamiento futuro de sus clientes y se encuentra preocupado por ello dado que su objetivo es satisfacerlos y para lograr dicho objetivo necesitan conocer de cerca las características que ellos buscan en una entidad bancaria y, con esta información, crear propuestas de valor que coloqué al Banco Internacional como la mejor opción.

Como se mencionó en líneas previas, la herramienta que el Banco Internacional aplicará para conocer el comportamiento futuro de sus clientes es la red neuronal artificial, pero para la implementación de esta se realizó una segmentación previa. En principio, se realizó la clasificación de los usuarios utilizando la base de datos del banco, en esta se encuentran datos

dinámicos como las transacciones y estáticos como la información personal del cliente. Para la clusterización, se analizaron 3 variables del historial de compras de los clientes: atributos de tendencia, frecuencia de compra y el monto de consumo. Para hallar la tendencia, se utiliza el método de mínimo cuadrado cuya fórmula es la siguiente:

$$T = \frac{\sum_{t=1}^n t \cdot y(t)}{\sum_{t=1}^n t^2} \quad (19)$$

En esta ecuación, t representa la coordenada tiempo, n el número de tendencias y $y(t)$ es la función que representa el monto de consumo del cliente en el tiempo t . Este monto se halla para el posterior análisis de la contribución de los clientes dado que es un factor que se ve reflejado en dicha variable. En este estudio, las capas utilizan la función sigmoidea para que el rango del resultado se encuentre entre 0 y 1. Para el entrenamiento de las redes neuronales, se utilizará 0.2 para que los resultados de las variables a la salida no sean menores que 0.2.

Posteriormente, el modelo propuesto para la clasificación categoriza a la data en data de entrenamiento y data de muestra. La data de entrenamiento es aquella que ingresa al modelo para encontrar las características que permitan distinguir entre la clase anormal de la normal. Asimismo, se introduce la data de la muestra al modelo, el cual asigna las etiquetas para la categorización y si el resultado de la modelación es satisfactorio entonces se determina que este modelo predice el comportamiento de las variables desconocidas.

Luego del proceso de segmentación y clasificación de las variables presentes en el estudio, se procede con la modelación del diseño de redes neuronales. Esta es una herramienta que es representada a través de un conjunto de nodos interrelacionados a través de diversas capas.

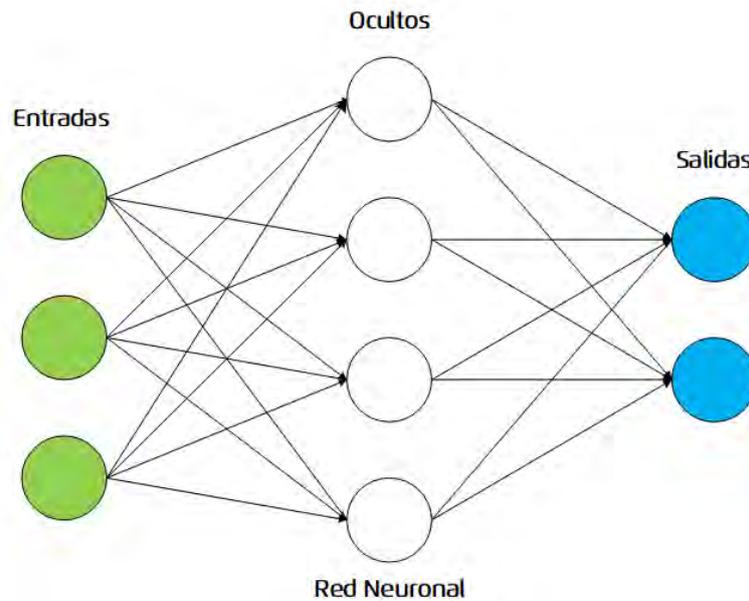


Figura 16. Redes neuronales.

Tomado de "Neural Network and Classification Approach in Identifying Customer Behaviour in the Banking Sector: A Case Study of an International Bank", por Ogwueleka, Misra, Colomo-Palacios y Fernandez, 2012

En esta red neuronal, se identifican 3 capas, la capa de entrada, capa intermedia y capa de salida. En este estudio, las variables de entrada son los factores que influyen en la satisfacción del cliente como nivel de precios, tiempo de espera para el pago, actitud de servicio, entre otros. Asimismo, el sistema utilizado para el análisis fue de 4 capas con 2 capas ocultas y se realizaron 32 operaciones con un peso de 0.2 para un modelo óptimo. El procedimiento que esta herramienta sigue es el siguiente:

Primero, se definen los datos y los patrones de dichos se introducen en la capa de entrada. Luego de ello, la data será clasificada como la data de entrenamiento que tendrá que ser validada para encontrar el modelo óptimo. Posteriormente, se determinan las capas ocultas y la cantidad de neuronas que existen en cada capa. A continuación, se realiza la formación del modelo con el cálculo de la salida de los datos de entrada y los pesos de cada uno de ellos a

través de un algoritmo que le permite a la red neuronal ser capaz de aprender a actuar por aprendizaje automático.

Se plantean dos hipótesis nulas:

$$H_t: t^{n+1} = (t_1^{n+1}, \dots, t_m^{n+1})$$

$$H_d: t^{n+1} = (t_1^{n+1}, \dots, t_m^{n+1})$$

Si la primera hipótesis se acepta, la transacción del cliente es considerado como una transacción normal, es decir aquella que es realizada por un cliente que permanecerá en el banco. Por el contrario, si la segunda hipótesis es aceptada, la transacción se considera como una realizada por un cliente anormal, es decir, un cliente que no planea afiliarse al banco.

El sistema diseñado de redes neuronales artificiales clasifica el comportamiento de los tipos de clientes definidos e identificados previamente, es decir, los clientes normales y anormales. Esta herramienta ayuda a determinarlos y otorgarles una puntuación a cada segmento de ellos para lograr formular las estrategias que el Banco Internacional debe realizar.

Con la clasificación, segmentación de las variables que influyen en la calidad de servicio de los clientes y la predicción del comportamiento de los clientes, el Banco Internacional realizó mejoras en el servicio del cliente diferencias las estrategias para clientes normales de los anormales dado que la primera categoría requería de planes estratégicos relacionados con el incremento del servicio para lograr su satisfacción. Se aplicaron planes de retención para los clientes anormales y lograr que estos se afilien al banco. Asimismo, se observa que, dada la problemática respecto a la falta de estrategias, la entidad bancaria logró predecir el comportamiento de los clientes de tarjetas de crédito y, en consecuencia, plantear estrategias que permitan optimizar las transacciones de estos clientes y reducir los costos transaccionales. Por último, se recomienda analizar los clientes, en su totalidad, es decir no únicamente de aquellos que utilicen tarjetas de crédito.

2.6. Modelo matemático para la asignación de trabajadores en una entidad bancaria

Autores: Andrey F. Shorikov, Anna S. Filippova and Vladimir A. Tyulyukin

Año: 2018

Los problemas de optimización en el sector bancario deben ser tratados con especial precisión para poder obtener resultados beneficiosos en términos de eficiencia con la finalidad de incrementar la competitividad de los bancos dentro del sistema.

Básicamente, los bancos buscan continuamente optimizar la asignación de sus recursos con el objetivo de minimizar riesgos e incrementar la utilidad neta en sus arcas. Uno de los casos de asignación de recursos en el sistema bancario es la gestión de la fuerza laboral. Frente al incremento en la demanda y exigencia de los clientes hacia el sistema bancario, es necesario que las organizaciones ofrezcan servicios financieros óptimos en términos de calidad y eficiencia. Una de las claves del éxito de múltiples bancos es la eficiente gestión de los recursos que posee y uno de los recursos más valioso es el humano. Es por ello que, en respuesta a este incremento de la demanda, es necesario realizar ajustes en la organización de horarios y asignación de trabajadores para realizar una óptima cobertura a la entidad bancaria.

Es importante para los bancos procurar que se encuentren disponibles para poder atender la necesidad de los clientes. Para esta asignación, se deben establecer lineamientos para poder alcanzar la optimalidad. En la actualidad, existen diferentes maneras para lograr la mayor eficiencia posible en la gestión de recursos. Dentro de una entidad bancaria, en múltiples ocasiones, se realizan tomas de decisiones basadas en la experiencia de ciertos miembros de la organización. Sin embargo, en otras oportunidades, el rumbo del banco se puede definir a partir de datos para poder determinar una solución óptima.

La disponibilidad de datos es una ventaja competitiva, ya que permite a los bancos realizar la toma de decisiones en la distribución de recursos de una manera más eficiente y con

fundamentos en base a información cuantitativa de calidad que permite realizar un óptimo análisis de la situación.

A continuación, para poder encontrar una cantidad óptima para el volumen de trabajadores dentro de una entidad bancaria, se presenta un caso de estudio donde se realiza un modelamiento matemático, en el cual se analiza el indicador Costo/Ingreso como principal criterio. En otros términos, los ingresos y gastos operacionales serán empleados para determinar la cantidad de trabajadores a mantener en la fuerza laboral del banco.

Para el modelo, se consideraron los parámetros que influyen dentro del proceso de venta y el impacto que estas tienen sobre el banco. Es decir, se realizó el análisis de la cantidad de trabajadores que posee el banco diferenciados por perfil y los beneficios que generan para la organización por la venta de los productos que hay en la cartera. Entre los productos que ofrece el banco se encuentran los préstamos, tarjetas de crédito y débito, depósitos a plazo, entre otros.

El modelo se centraba en obtener el valor óptimo del Ratio Costo/Ingreso. Este es un indicador financiero que mide la eficiencia de los bancos a través del cociente de los costos entre los ingresos operacionales. En el sector bancario, los accionistas e inversionistas toman en consideración este indicador para medir la rentabilidad del negocio. Entonces, el modelo busca optimizar los costos e ingresos con la finalidad de obtener un mejor Ratio Costo/Ingreso a partir de la gestión de la cantidad de trabajadores que hay dentro de la organización.

Para la formulación del modelo, se tomaron en cuenta los siguientes parámetros y variables para construir la ecuación del modelo matemático:

- La cantidad de cada tipo de producto del banco en el periodo t

$$x(t) = (x_1(t), x_2(t), \dots, x_n(t)) \quad (20)$$

- La cantidad de categorías de los colaboradores

$$y(t) = (y_1(t), y_2(t), \dots, y_n(t)) \quad (21)$$

- Ventas estándar por mes

$$A(t) = \| a_{ij}(t) \| \quad (22)$$

- Cantidad de productos del tipo i vendidos por colaborador de la categoría j en el periodo t

$$a_{ij}(t) \quad (23)$$

- Costo por venta por cada tipo de producto

$$z(t) = (z_1(t), z_2(t), \dots, z_n(t)) \quad (24)$$

- Reembolso mensual por cada tipo de producto

$$H = (h_1, h_2, \dots, h_n) \quad (25)$$

- Valor medio de los productos

$$S = (s_1, s_2, \dots, s_n) \quad (26)$$

- Cantidad de colaboradores por cada categoría

$$u(t) = (u_1(t), u_2(t), \dots, u_n(t)) \quad (27)$$

Del mismo modo, para acotar el alcance del modelo, se definieron las siguientes funciones de restricción de acuerdo a las limitantes del sistema:

- Siendo j la categoría de cada colaborador:

$$|u_j^k(t)| \leq 0.1 \cdot y_j(t-1) \quad (28)$$

Donde $k \in \{1, N_t\}$, siendo N la cantidad de controles permisibles en el periodo t .

- Siendo $T_{m\acute{a}x}$ y $T_{m\acute{i}n}$ los l\imites de los tiempos disponibles mensuales:

$$\sum_{j=1}^n y_j(t) \leq 10000 \quad (29)$$

$$T_{m\acute{i}n} \leq \sum_{i=1}^n [a_{ij}^{(k)}(t) \cdot z_i] \leq T_{m\acute{a}x} \quad (30)$$

$$a_{ij}^{(k)}(t) \geq 0 \quad (31)$$

$$a_{ij}^{(k)}(t) \cdot z_i \geq 0.1 \cdot \sum_{i=1}^n [a_{ij}^{(k)}(t) \cdot z_i] \quad (32)$$

Asimismo, para poder definir la funci3n objetivo del modelo, se debe introducir los siguientes parámetros previamente:

- El valor del salario de los trabajadores

$$v = (v_1, v_2, \dots, v_m) \quad (33)$$

- Tasa de interés anual de los ingresos por cada tipo de producto en la cartera del banco

$$r = (r_1, r_2, \dots, r_n) \quad (34)$$

- Tasa de interés anual de los egresos por cada tipo de producto en la cartera del banco

$$c = (c_1, c_2, \dots, c_n) \quad (35)$$

- Gastos administrativos

$$q \quad (36)$$

Entonces, para poder alcanzar una gestión óptima respecto a la cantidad de colaboradores en el banco, se plantea la siguiente función objetivo en que está definida por el Ratio Costo/Ingreso, “CIR” por sus siglas en inglés.

$$\text{maximizar } \Phi_{(0,T)}(x(0), \bar{u}(\cdot)) = CIR(T) = \frac{T \cdot q + \sum_{t=1}^T \sum_{j=1}^m v_j \cdot y_j(t)}{\frac{1}{24 \cdot 100} \cdot \sum_{t=1}^T \sum_{i=1}^n (x_i(t) + x_i(t-1)) \cdot (r_i - c_i)} \quad (37)$$

Para poder brindar un mayor entendimiento, se presentarán las categorías de los colaboradores que se están considerando dentro del modelo matemático planteado por la entidad bancaria en estudio.

Tabla 4.

Categoría de los colaboradores.

i	Categoría
1	Gerentes de ventas
2	Gerente de créditos hipotecarios
3	Especialistas en venta directa
4	Especialistas senior en venta directa
5	Gerente de proyectos salariales
6	Gerentes que trabajan con socios
7	Especialistas en el servicio privado

Nota: Tomado de “Application of Dynamic Economic-Mathematical Modeling in Optimization Problems in Banking”, por Shorikov, Filippova and Tyulyukin, 2018.

Según las categorías descritas por cada colaborador, se obtuvieron los siguientes resultados del modelo. Cabe resaltar que los resultados fueron calculados a partir de los datos primarios recolectados por el banco en estudio. A continuación, se presentará la cantidad óptima de colaboradores por cada categoría.

Los resultados obtenidos fueron calculados con la finalidad de alcanzar un indicador Costo/Ingreso óptimo, ya que, como se ha descrito previamente, es un indicador muy potente en el sector bancario para poder medir la eficiencia de la organización.

Tabla 5.

Asignación por cada tipo de colaborador por periodo.

$u_i(t)$	t		
	0	6	12
$u_1(t)$	0	0	163
$u_2(t)$	0	0	21
$u_3(t)$	0	0	25
$u_4(t)$	0	0	15
$u_5(t)$	0	0	4
$u_6(t)$	0	0	3
$u_7(t)$	0	0	183

Nota: Tomado de “Application of Dynamic Economic-Mathematical Modeling in Optimization Problems in Banking”, por Shorikov, Filippova and Tyulyukin, 2018.

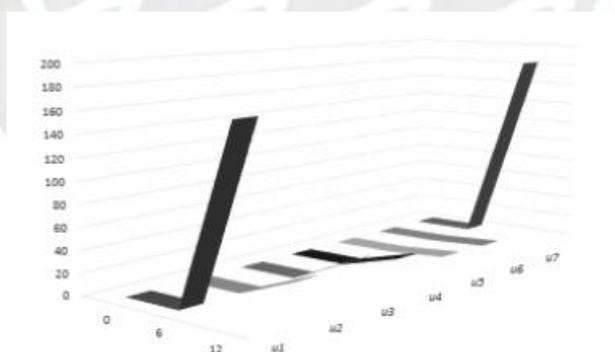


Figura 17. Asignación de colaboradores.

Tomado de “Application of Dynamic Economic-Mathematical Modeling in Optimization Problems in Banking”, por Shorikov, Filippova and Tyulyukin, 2018.

Con dicha distribución de tamaño de colaboradores por cada una de las 7 categorías descritas, se logró alcanzar un indicador Costo/Ingreso igual a 52.78%, lo cual indica que el

banco en estudio está siendo eficiente en sus procesos operacionales, ya que esto implica que los ingresos operativos son aproximadamente el doble en comparación de los costos operativos.

En síntesis, este modelo permite encontrar una solución a un problema de gestión de recursos humanos, donde se calculó la cantidad óptima de colaboradores por categoría para, de esta manera, poder alcanzar un mayor nivel de eficiencia en los costos operacionales, lo cual posee un gran impacto en el indicador Costo/Ingreso. Este modelo permite a los bancos obtener mayores beneficios a partir de una óptima gestión de los recursos apoyándose en herramientas de Optimización Matemática.

2.7. Desarrollo de un modelo de asignación de límite de crédito para bancos utilizando un Técnica para la preferencia de orden por semejanza con la solución ideal difuso integrado y programación lineal

Autores: Yusuf Tansel İç

Año: 2012

La gestión del riesgo del portafolio es uno de los factores que deben analizarse al presentarse problemas dentro del sector bancario. La línea de crédito de las entidades es un recurso limitado. Es por ello que debe realizarse una asignación óptima de este recurso. El portafolio de una entidad bancaria está determinado por diferentes factores de diversas índoles, tales como, el sector geográfico y nivel socio-económico. Para el banco, es una potencial amenaza que existan concentraciones de alguna de dichas variables, puesto que ello supondría un incremento en el nivel de riesgo de portafolio. Uno de los principales objetivos de las finanzas es reducir el riesgo y mantener una óptima línea de crédito.

La concentración crediticia debe ser sometida a un riguroso estudio, en el cual se determina el límite crediticio que se va a asignar a cada concentración para disminuir el riesgo de una potencial pérdida, ya que los altos niveles de concentración eventualmente son las

causas de dichas pérdidas. Este estudio debe ser realizado por diferente tipo de entidades, pero, como se ha venido detallando, en esta oportunidad, se desarrollará el caso de un banco. Es por ello que se realiza la asignación a cada cabeza regional del banco.

Existe una creciente tendencia de emplear diversos modelos matemáticos para poder asignar correctamente riesgo crediticio entre diferentes alternativas de manera óptima bajo las regulaciones de parámetros como las diversas concentraciones y el presupuesto disponible por la entidad bancaria. Para poder gestionar estos recursos, se empleará la programación lineal para poder asignar correctamente el riesgo del portafolio en combinación de una serie de criterios y restricciones que existen por las características de la entidad y el sector.

Previo a realizar la modelación a través de la programación lineal, se definen pesos para poder priorizar entre las diferentes cabezas regionales a través de ciertos criterios establecidos por la entidad bancaria.

En el modelo matemático, se procedió a definir el conjunto de parámetros y variables que participarán dentro de la formulación del modelo. Dichos parámetros y variables son los siguientes:

Tabla 6.

Notación de las variables y parámetros del modelo.

Notación	Descripción
R_i	Pesos de priorización para la cabeza regional i
X_i	Cantidad límite de concentración de riesgo crediticio para la cabeza regional i
CL_i	Línea de crédito para la cabeza regional i
D_i	Demanda límite para la cabeza regional i
p, q, r, s, t	Coefficientes de concentración de la región geográfica
B	Presupuesto crediticio del banco

Nota: Tomado de “Development of a credit limit allocation model for banks using an integrated Fuzzy TOPSIS and linear programming”, por Yusuf Tansel Iç, 2012.

Del mismo modo, el propósito del modelo es aumentar la eficiencia en la asignación de los créditos. Por ello, se define la función objetivo como la maximización del valor del valor del capital a asignar y es la siguiente:

$$\text{maximizar } \sum_{i=1}^n R_i \cdot X_i \quad (38)$$

Asimismo, se procede a definir las restricciones del modelo. En primer lugar, el nivel de riesgo del portafolio concentrado en una cabeza regional no debería sobrepasar su línea de crédito que posee actualmente. Esta restricción se ilustra a través de la siguiente expresión matemática:

$$CL_i \leq X_i \quad (39)$$

Además, la línea de crédito asignada a una cabeza regional no puede exceder a la demanda demográfica. Se describe a través de la siguiente ecuación:

$$X_i \leq D_i \quad (40)$$

Del mismo modo, la concentración de la región del crédito del portafolio no debería exceder a la porción de presupuesto del banco:

$$\sum_{i=1}^j X_i \leq (p \cdot B) \quad (41)$$

$$\sum_{i=j+1}^k X_i \leq (q \cdot B) \quad (42)$$

$$\sum_{i=k+1}^l X_i \leq (r \cdot B) \quad (43)$$

$$\sum_{i=l+1}^m X_i \leq (s \cdot B) \quad (44)$$

$$\sum_{i=m+1}^n X_i \leq (t \cdot B) \quad (45)$$

Cabe resaltar que j, k, l, m, n son valores enteros ($j < k < l < m < n$). Asimismo, sobre las proporciones de concentración, se cumple con la siguiente condición:

$$p + q + r + s + t = 1 \quad (46)$$

También, es sumamente importante que el valor total a asignar no exceda al presupuesto establecido por el banco para las líneas de crédito. Esta proposición podría ser denotada por la siguiente notación:

$$\sum_{i=1}^n X_i = B \quad (47)$$

El problema de la asignación de riesgo crediticio es frecuente en las entidades bancarias. El modelo propuesto por los autores logra optimizar las cantidades a asignar. De esta manera, se alcanza una maximización en el valor del capital utilizado.

El modelo fue contrastado con una asignación realizada por expertos en créditos. Se realizó la comparación entre los resultados de los expertos y los obtenidos por el modelo. Para realizar la validación, se utilizó la prueba de Spearman, donde se planteó la siguiente hipótesis nula con un nivel de significancia de 95%:

H_0 : No hay semejanza entre ambas muestras.

Luego de realizar el análisis, se obtuvo que estadístico de prueba superó al valor crítico Z para el nivel de significancia establecido, lo que significa que se rechaza la hipótesis nula y se valida el modelo.

La aplicación del modelo en el banco de prueba piloto obtuvo una serie de beneficios, puesto que esta asignación le permite distribuir óptimamente sus recursos, es decir, su presupuesto de línea de crédito en las diferentes regiones para, de esta manera, reducir el riesgo del portafolio.

2.8. Un enfoque de programación matemática difusa para la optimización de ventas cruzadas en la banca minorista

Autores: John F Welch Technology Centre, Bangalore, Karnataka, India

Año: 2009

En el sector bancario, existe una creciente tendencia de fortalecer la relación con los clientes para poder establecer relaciones redituables con ellos. En los últimos años, la relevancia de tener una cultura cliente-céntrica ha crecido notablemente. Es por ello que se ha implementado el área denominada Gestión de la Relación con el Consumidor en el sector bancario, *CRM* por sus siglas en inglés.

Para las entidades bancarias, es de suma importancia poseer dentro de su cartera a clientes que generen altos niveles de rentabilidad. Para conseguir dicho hito, es necesario incrementar el valor que se genera al cliente y maximizar el beneficio obtenido de los clientes.

Por un lado, el principal objetivo buscado por las entidades bancarias es maximizar las ganancias obtenidas a partir de los clientes y minimizar el nivel de riesgo del capital distribuido en el portafolio del banco. Para ello, se aplican modelos de asignación del presupuesto del banco con la finalidad de mitigar las concentraciones y reducir el riesgo.

Por otro lado, como se ha explicado, es sumamente importante mantener una relación cercana con los clientes para poder entender sus necesidades y poder satisfacerlas de una manera óptima. Para ello, se debe ofrecer el producto indicado en el momento indicado. La finalidad es poder retener a los clientes que generan mayores niveles de rentabilidad para la entidad bancaria.

Hay diversas maneras para poder atraer y retener a los clientes y, además, obtener beneficios para las arcas del banco. Para poder maximizar los ingresos, hay que asegurar que se mantenga la disponibilidad de los productos en el momento que se presente la necesidad del cliente. Del mismo modo, se debe establecer un precio razonable para el cliente que, a su vez, genere rentabilidad según los objetivos planteados por el banco.

Otra manera de poder incrementar el nivel de satisfacción del cliente y generar rentabilidad para el banco es a través de las ventas cruzadas. Esta herramienta se encarga de la oferta de un conjunto de productos complementarios. En este sentido, es importante que se los productos estén situados en el lugar indicado en el momento indicado bajo un contexto óptimo.

Para ello, es necesario realizar una estimación acerca de los consumidores para poder conocer si, efectivamente, son propensos a realizar una compra cruzada. Para poder realizar las estimaciones se aplican herramientas estadísticas y de minería de datos. Luego, en base a las estimaciones, se debe realizar una selección del público objetivo al cual aplicar la venta cruzada

y poder generar un consolidado de dichos clientes. Para poder determinar el valor de esta variable, se realiza una programación lineal para realizar una optimización tomando en cuenta las restricciones y la función objetivo.

Para poder realizar la venta cruzada, se debe poder ofrecer más de un producto a cada cliente. El banco debe analizar y delimitar correctamente a su público objetivo, y observar las tendencias de estos acerca de los productos bancarios que consume. En este sentido, se deben analizar diversos factores que podrías afectar al modelo, tales como, propensión de respuesta del cliente, las ganancias potenciales y el riesgo de incumplimiento.

Dichas variables pueden ser obtenidas a partir de predicciones realizadas a partir de datos históricos recopilados y almacenados para poder deducir el comportamiento que presentan los clientes. De este modo, se puede realizar el modelo para aplicar las ventas cruzadas en el banco.

Se planteó para la entidad bancaria que se debe maximizar el ingreso neto, cuyo cálculo depende, a su vez, de ciertas variables.

$$NI = E(Profit) - E(OpEx) - TargCost \quad (48)$$

Donde:

$E(\text{profit})$: Ganancia esperada de la campaña

$E(\text{OpEx})$: Costo de abrir una cuenta y adquirir un producto a través de venta cruzada

$TargCost$: Costo de contactar al público objetivo

Para la formulación del modelo, se considera que existen J tipos de productos y una población total de N consumidores durante la campaña en la que se ofrecerán los productos por ventas cruzadas.

Del mismo modo, para poder definir la variable entera que define la decisión de ofrecer un producto a un cliente. Esta variable se define como y_{ij} .

$$y_{ij} = \begin{cases} 1, & \text{si se le ofrece el producto } j \text{ al cliente } i \\ 0, & \text{Caso contrario} \end{cases} \quad (49)$$

Donde $i = 1, \dots, N$ y $j = 1, \dots, J$, respectivamente.

Asimismo, se definen los siguientes parámetros:

- r_{ij} : La ganancia obtenida por el cliente i por consumir el producto j
- p_{ij} : La probabilidad de que el cliente i consuma el producto j
- v_{ij} : La cantidad de clientes i que consumen el producto j
- θ_j : Costo operativo por la venta del producto j
- m : Costo unitario de contactar a un cliente

Una vez definidos los parámetros, se procede a realizar la formulación de la función objetivo que será igual al ingreso neto, que puede ser representada por la siguiente expresión matemática:

$$\sum_{i=1}^N \sum_{j=1}^J \{(p_{ij} \cdot p_{ij} \cdot p_{ij}) - (p_{ij} \cdot p_{ij} \cdot p_{ij}) - (m \cdot p_{ij})\} \quad (50)$$

Además, el modelo puede estar acotado principalmente por tres restricciones. Por un lado, la entidad bancaria no puede afrontar costos por contactar a los clientes del público objetivo por un monto mayor al presupuesto. Se denota mediante la siguiente expresión, donde B es el valor del presupuesto:

$$\sum_i \sum_j m \cdot y_{ij} \leq B \quad (51)$$

Por otro lado, según la estimación de los clientes que se va a realizar, se debe asegurar que se va a poder cubrir la demanda de todos los clientes que se incluirán dentro del diseño del proceso de ventas cruzadas. Esta restricción se representa a través de la siguiente ecuación, donde T_j es el volumen de clientes a consumir el producto j :

$$\sum_i v_{ij} \cdot p_{ij} \cdot y_{ij} \geq T_j \quad (52)$$

Adicionalmente, cada tipo de cliente no puede exceder al tamaño del grupo al que se le hace la oferta, el cual es representado por N_i . La restricción es ilustrada de la siguiente manera:

$$\sum_j y_{ij} \leq N_i \quad (53)$$

En el presente caso, se realizó el estudio para poder determinar el tamaño del público objetivo al cual se le aplicaría una oferta de venta cruzada para, de esta manera, incrementar el valor del ingreso neto.

El modelo fue aplicado en un banco modelo donde se realizó una oferta de venta cruzada entre en producto A y producto B. El principal producto a ofrecer es el A y se ofreció el producto B como complementario. En otras palabras, en este caso, se barajan 3 ofertas diferentes las cuales son las siguientes: producto A, producto B, y producto A y B. En este caso, se pudo observar que se incrementó el valor del ingreso neto al poder incluir al producto B dentro de una misma oferta dentro del periodo de campaña. Particularmente, en esta entidad bancaria, obtuvo un incremento en sus ingresos netos por un valor de 500 000 dólares.

Este incremento incrementó a pesar que se observó una reducción en la cantidad de consumidores que adquirirían únicamente el producto B según el modelo, pero este decremento fue ampliamente compensado por los ingresos obtenido por la cantidad de consumidores que adquirirían el producto A y B en conjunto.

CAPÍTULO 3 DIAGNÓSTICO

Como se ha podido apreciar, según el estudio de casos, las herramientas de Analítica y Optimización Matemática han contribuido con diversos aportes en el sector bancario-financiero.

En el sector bancario peruano, la época de transición hacia la transformación digital empezó hace aproximadamente 4 años. En este contexto, la banca digital ha crecido en más de 25% recientemente. Esto ha supuesto una reducción en el índice de reclamos de 22 a 16 por cada 10000 plásticos. Además, se ha disminuido la cantidad de agencias físicas de los principales bancos en un 6%. En el BBVA, se pudo alcanzar índices de recomendación que duplicaron a los tradicionales y, de este modo, se logró elevar los niveles de satisfacción de los usuarios. Asimismo, en Scotiabank, se logró triplicar la cantidad de transacciones digitales desde que se implementó la banca móvil. Además, en el Banco de Crédito, la transformación digital ha permitido atraer a una gran cantidad de clientes, puesto que su cartera aumentó de 6 a 8 millones, de los cuales aproximadamente el 40% registran actividad digital (Castillo, 2019).

Por un lado, las entidades bancarias cada vez están más inmersas en las culturas de transformación digital, principalmente con la implementación de los canales digitales. La tendencia de la transformación digital ha generado la necesidad de apostar por herramientas innovadoras para poder realizar el procesamiento y análisis de la variedad de datos que se registran. Por ello, en el sistema bancario, se han implementado herramientas de Analítica con el objetivo de incrementar la eficiencia de los procesos, planificación y toma de decisiones de la entidad bancaria.

En las entidades bancarias, como se especificó en los apartados previos, hay diversos casos en los cuales la aplicación de la Analítica ha significado una contribución relevante para la organización. Por ejemplo, se ha logrado aplicar un análisis de Clúster para poder realizar una correcta segmentación de los clientes según las compras y transacciones que realizaban a

través de los canales digitales que ofrece el banco. Esta clasificación permite a los bancos realizar una recomendación que se ajuste a la medida de las necesidades de los clientes y, de esta manera, incrementar el nivel de satisfacción de los consumidores. Además, se ha podido realizar una predicción en el comportamiento de los clientes respecto al uso de la tarjeta de crédito. De acuerdo a dichas predicciones, la entidad bancaria puede realizar planes estratégicos con la finalidad de poder elevar el nivel de servicio al cliente para que, de esta manera, se puedan atraer nuevos clientes a la cartera del banco y retener a los actuales.

En el sector bancario peruano, se está trabajando para poder implementar estas herramientas. Por ejemplo, en la economía peruana, con la finalidad de maximizar el retorno de las colocaciones, los bancos han optado por aplicar herramientas de *Big Data* para reducir el riesgo crediticio (Gestión, 2015). La ciencia de datos permite realizar una oferta precisa en el momento más apropiado al cliente indicado. Debido a ello, la transformación de datos en información genera valor en las entidades bancarias (Castillo, 2019).

La aplicación de *Data Analytics* en el sector bancario peruano está creciendo a pasos agigantados. Por ejemplo, ya se están introduciendo instrumentos que permiten elevar el nivel de gestión de cobranza de los bancos y poder entender el motivo de las moras mediante la codificación de las conversaciones con los clientes. Asimismo, se está implementando y diseñando algoritmos que permitan determinar la capacidad de pago de una persona con la finalidad de evaluar una opción a un eventual préstamo (Alva, 2019).

La aplicación de instrumentos de Analítica ha permitido proveer al sistema bancario peruano de un conjunto de soluciones innovadoras. El Banco de Crédito ha podido realizar la optimización del efectivo, ya que se analizó el costo de oportunidad de la disponibilidad de dinero en los diversos locales. De este modo, lograron ajustar en un 25% el dinero gestionado a lo largo del Perú. Asimismo, se redujo la tasa de reclamos de 8.4 a 5.4 reclamos por cada 1000 clientes. Del mismo modo, a través de la implementación de *Big Data*, se logró identificar

aproximadamente 19,8 millones de transacciones que podrían realizarse a través de canales más económicos (Zurita, 2017).

Sin embargo, si se compara al sector bancario peruano respecto al resto de los países de Latinoamérica, se puede evidenciar que se el sistema bancario del Perú no está al nivel de desarrollo de sus similares de Brasil, Chile, entre otros. Dicho desarrollo en Analítica se ve reflejado en los porcentajes de participación en el sistema financiero de la región. Según la Federación Latinoamericana de Bancos y la Asociación de Bancos Privados de Ecuador, la participación en los países latinoamericanos es la siguiente:

Tabla 7.

Participación en el sistema financiero por país.

Ranking	País	Participación 2018
1	Brasil	39%
2	México	16%
3	Chile	11%
4	Colombia	8%
5	Argentina	6%
6	Perú	4%
7	Otros	15%

Nota: Tomado de “Informe de inclusión financiera”, por FELABAN, 2018.

Como indica la tabla, en el 2018, Perú se encontró en el sexto puesto de participación. Como se ha evidenciado en la investigación, el desarrollo en herramientas de Analítica permite incrementar las eficiencias de los bancos. La ventaja de Brasil, México, Chile, Colombia y Argentina radica también, en parte, en el nivel de aplicación de dichas herramientas en sus respectivas regiones.

Por otro lado, la optimización matemática es una herramienta que permite la optimización en diversos sectores económicos. Como se ha podido contrastar en el estudio de casos, el sector bancario no es la excepción, ya que hay entidades bancarias en las cuales se ha podido obtener beneficios mediante la aplicación de diferentes modelos matemáticos, tales como, la optimización en la asignación de personal, capital, entre otros.

En el sector bancario peruano, no se ha realizado una interiorización de las herramientas de optimización de matemática a gran profundidad como sí se pudo evidenciar en el estudio de casos. La tendencia de utilizar modelos matemáticos no está muy difundida en el sector. Sin embargo, sí existen estudios de aplicación dentro del sector realizados por el Banco Central de Reserva del Perú.

En primer lugar, se desarrolló una investigación en la cual se realiza un análisis donde se brinda un acceso total al Banco Central de Reserva al mercado de valores, dejando a la banca privada excluida. Sin embargo, el objetivo del estudio era determinar una cuota óptima de mercado que debería abarcar el Banco Central de Reserva. Para ello, se realizó un modelo en el cual se plantea maximizar la cantidad de *households*, los cuales son un grupo económico que efectúa la toma de decisiones dentro del mercado de valores, y se establece como restricción el presupuesto para realizar las eventuales colocaciones (Bacchetta y otros, 2012).

En segundo lugar, en la base de datos del BCRP, se elaboró una investigación en la cual se podría realizar una optimización en los portafolios de inversión de las AFP, la cual podría ser extrapolable al sector bancario. En dicho modelo, se pretende minimizar el riesgo del portafolio, considerando los pesos que se asignan a cada colocación. Del mismo modo, el modelo está sujeto a la relación entre activos y pasivos de la AFP, donde se evalúa el nivel de endeudamiento que se debe asumir para poder nivelar correctamente el riesgo de las inversiones realizadas (Mendoza, 2014).

En síntesis, como se puede observar, las herramientas de optimización matemática no están dentro de las principales tendencias dentro del sistema bancario en el Perú. No obstante, existen indicios de diversas investigaciones publicadas en la base de datos de publicaciones del Banco Central de Reserva del Perú donde se evidencian indicios de estudios que comprueban que se pueden aplicar diversos modelos para poder optimizar la asignación de recursos, tal como, el capital de inversión.

CONCLUSIONES

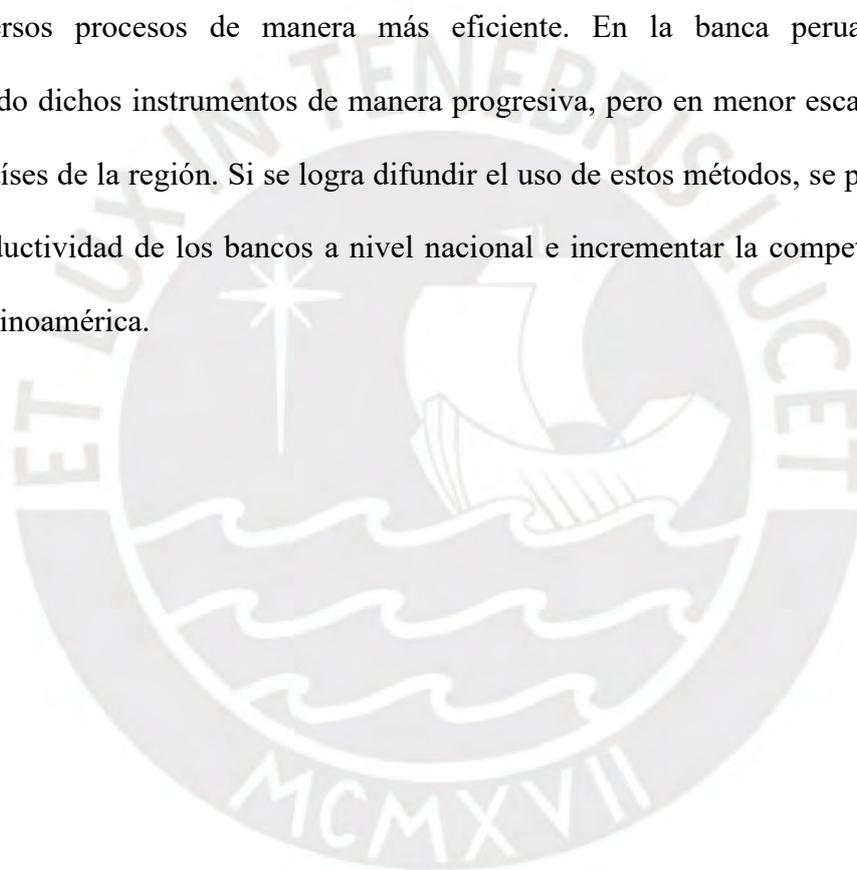
En el presente trabajo de investigación, se desarrolló el análisis de los métodos de Analítica, donde se detallan sus principales herramientas y campos de aplicación. De la misma manera, se precisaron los principios de la Optimización Matemática, donde se indicaron diversos conceptos y metodologías. Además, se exponen los resultados y beneficios de ambas herramientas dentro del sector bancario a través de diversos casos de aplicación. Asimismo, se presenta el contexto de ambas metodologías en el sector bancario peruano y Latinoamericano.

En base a la investigación realizada, la aplicación de las herramientas de Analítica genera diversos beneficios, ya que permite a las empresas realizar una mejor toma de decisiones con fundamento en un mejor análisis de los datos. Asimismo, la implementación de este instrumento se encuentra en constante crecimiento debido a los evidentes resultados que se han obtenido en las empresas líderes, tales como, Google y Yahoo. En este contexto, las entidades bancarias de Rusia, India y China, como se presenta en el estudio de casos, elevaron sus indicadores de eficiencia y satisfacción al cliente. En vista de ello, los bancos peruanos tales como, BBVA y el Banco de Crédito del Perú avanzan progresivamente en el uso de estas herramientas, puesto que se requiere de una tecnología avanzada y personal capacitado en Ciencia de Datos para ejecutar las investigaciones requeridas y abordar las diversas variables relevantes para una toma de decisiones óptima.

Según lo presentado, la implementación de la Optimización Matemática dentro de las empresas atrae un conjunto de beneficios que incrementan la eficiencia que se traduce en mayores utilidades. Dicha metodología ha sido implementada en el sector bancario para poder optimizar la asignación de recursos de diversa índole, tales como, capital de inversión, capital humano, entre otros, en el cual se ha podido validar con los resultados obtenidos las ventajas que ofrecen las herramientas de Optimización Matemática. Sin embargo, en el Perú, la aplicación de estas herramientas no está muy interiorizada en comparación al resto de países

de Latinoamérica. Por ello, en la banca peruana, se puede impulsar el uso de estas metodologías para que las entidades bancarias realicen procesos con un mayor grado de eficiencia y, de este modo, poder obtener un incremento en el nivel de utilidades y servicio al cliente.

En síntesis, la implementación de la Analítica y Optimización Matemática atraen múltiples beneficios, ya que optimizan el proceso de toma de decisiones dentro de diversas organizaciones. El sector bancario no es ajeno a la aplicación de estas metodologías, puesto que se ha evidenciado la compatibilidad con las necesidades de las entidades bancarias para realizar diversos procesos de manera más eficiente. En la banca peruana, se están implementando dichos instrumentos de manera progresiva, pero en menor escala en relación al resto de países de la región. Si se logra difundir el uso de estos métodos, se podrá elevar el nivel de productividad de los bancos a nivel nacional e incrementar la competitividad en la región de Latinoamérica.



BIBLIOGRAFÍA

Ackoff, Russell L. & Sasieni, Maurice W. (2003). *Fundamentals of Operations Research*.

Alva, M. (2019). *Entidades financieras ya evalúan pupilas de clientes para prestarles*. Gestión. <https://gestion.pe/tecnologia/entidades-financieras-evaluan-pupilas-clientes-prestarles-266233-noticia/>

Angelopoulos, S., Brown, M., McAuley, D., Merali, Y., Mortier, R., & Price, D. (2021). *Stewardship of personal data on social networking sites*. *International Journal of Information Management*, 56, 102208. doi: 10.1016/j.ijinfomgt.2020.102208

Arévalo, N. C. (2019). *Banca digital: Mejoras que son tendencia*. El Comercio Perú. <https://elcomercio.pe/economia/dia-1/transformacion-digital-banca-digital-mejoras-que-son-tendencia-bcp-bbva-scotiabank-amazon-microsoft-dia1-noticia/?ref=ecr>

Auriga (2016) Digital transformation: history, present, and future trends. <https://auriga.com/blog/digital-transformation-history-present-and-future-trends/>. Retrieved 15 June 2017

Bacchetta, P., Benhima, K., & Kalantzis, Y. (2012). *Capital Controls with International Reserve Accumulation: Can this Be Optimal?* BANCO CENTRAL DE RESERVA DEL PERÚ.

Bell, J. (2020). *Machine Learning: Hands-On for Developers and Technical Professional*.

Bhaskar, T., Sundararajan, R., & Krishnan, P. G. (2009). A fuzzy mathematical programming approach for cross-sell optimization in retail banking. *Journal of the Operational Research Society*, 60(5), 717–727. doi: 10.1057/palgrave.jors.2602609

Castillo, C. (2019). *El poder del «big data» para brindar una mejor experiencia al cliente financiero*. BBVA NOTICIAS. <https://www.bbva.com/es/pe/el-poder-del-big-data-para-brindar-una-mejor-experiencia-al-cliente-financiero/>

Chaouchi, Hakima. (2010). *The internet of things: connecting objects to the web*.

Chen, M., Mao, S., Zhang, Y., & Leung, V. C. M. (2014). *Big Data*. In Springer Briefs in Computer Science. Springer International Publishing. doi: 10.1007/978-3-319-06245-7

Chitra, K., & Subashini, B. (2011). *Customer Retention in Banking Sector using Predictive*. Madurai: Dept of Computer Applications.

Data Science: Making It Smart. (2017). *In Monetizing Your Data* (pp. 145–163). John Wiley & Sons, Inc. doi: 10.1002/9781119356271.ch9

David G. Luenberger & Yinyu Ye (2016). *Linear and Nonlinear Programming*. *International Series in Operations Research & Management Science*. Volume 228. Springer New York Heidelberg Dordrecht London.

Diwekar, U. (2008). *Introduction to Applied Optimization*. Springer Optimization and Its Applications. doi: 10.1007/978-0-387-76635-5

Eiselt, H. A., & Sandblom, C.-L. (2012). *Operations Research*. Springer Texts in Business and Economics. doi:10.1007/978-3-642-31054-6

FELABAN (2018). Informe de Inclusión Financiera. <https://felaban.s3-us-west-2.amazonaws.com/publicaciones/archivo20191120203800PM.pdf>

Finlay, Steven. (2014). Predictive Analítica, Data Mining and Big Data. Myths, Misconceptions and Methods.

Gestión (2015). *Big Data Analytics reduciría en millones pérdidas por riesgo crediticio en sistema financiero*. Gestión. <https://gestion.pe/tecnologia/big-data-analytics-reduciria-millones-perdidas-riesgo-crediticio-sistema-financiero-102786-noticia/>

Ghanbari, Elham & Najafzadeh, Sara. (2020). Machine Learning. doi: 10.1002/9781119654834.ch7.

González-Carrasco, I., Jiménez-Márquez, J. L., López-Cuadrado, J. L., & Ruiz-Mezcua, B. (2019). Automatic detection of relationships between banking operations using machine learning. Information Sciences. doi:10.1016/j.ins.2019.02.030

Hedvicaková, M., & Soukal, I. (2012). *Retail core banking services costs optimization*. *Procedia Technology*, 1, 177–182. doi: 10.1016/j.protcy.2012.02.033

Hillier, F. & Liberman, G. (2015). *Introducción a la Investigación de Operaciones*.

Hürlimann, T. (1999). *Mathematical Modeling and Optimization*. In Applied Optimization. Springer US. doi: 10.1007/978-1-4757-5793-4

Issa, T. (2014). Online Shopping and Human Factors. In E-commerce Platform Acceptance (pp. 131–150). Springer International Publishing. doi: 10.1007/978-3-319-06121-4_7

Jordan, M.I. and Mitchell, T.M., Machine learning: Trends, perspectives, and prospects. *Science*, 349, 6245, 255–260, 2015

Lange, T. A. (1998). *Internet Banking*. Gabler Verlag. doi:10.1007/978-3-322-84622-8

Larose, Daniel & Larose, Chantal. (2019). *Data Science Using Python and R*.

Linear and Nonlinear Programming. (2008). *International Series in Operations Research & Management Science*. doi:10.1007/978-0-387-74503-9

Kallrath, J. (Ed.). (2004). *Modeling Languages in Mathematical Optimization*. Applied Optimization. doi:10.1007/978-1-4613-0215-5

Krichen, S., & Chaouachi, J. (2014). *Graph-Related Optimization and Decision Support Systems*. John Wiley & Sons, Inc. doi: 10.1002/9781118984260

- Kulperger, Reg & Yu, Hao. (2013). Parallel Computing: Statistical and Environmetric Uses. doi: 10.1002/9780470057339.vap003.pub2
- Meerschaert, M. M. (2013). *One Variable Optimization. Mathematical Modeling*, 3–19. doi:10.1016/b978-0-12-386912-8.50001-4
- Mehmed Kantardzic. (2020). *Data Mining: Concepts, Models, Methods, and Algorithms*, Third Edition.
- Mendoza, R. (2014). *Eficiencia financiera en los portafolios de inversión de las AFP en el Perú: Un enfoque robusto de Multifondos BANCO CENTRAL DE RESERVA DEL PERÚ*.
- Neugebauer, R. (Ed.). (2019). *Digital Transformation*. doi:10.1007/978-3-662-58134-6
- Nicoletti, B. (2014). *Mobile Banking*. Palgrave Macmillan UK. doi:10.1057/9781137386564
- Numerical Optimization. (2006). Springer Series in Operations Research and Financial Engineering. doi:10.1007/978-0-387-40065-5
- Ogwueleka, F. N., Misra, S., Colomo-Palacios, R., & Fernandez, L. (2012). *Neural network and classification approach in identifying customer behavior in the banking sector: A case study of an international bank. Human Factors and Ergonomics in Manufacturing & Service Industries, n/a–n/a*. doi:10.1002/hfm.20398
- Prabhu, C. S. R., Chivukula, A. S., Mogadala, A., Ghosh, R., & Livingston, L. M. J. (2019). *Big Data Analítica: Systems, Algorithms, Applications*. Springer Singapore. doi: 10.1007/978-981-15-0094-7
- Pyne, S., Rao, B. L. S. P., & Rao, S. B. (Eds.). (2016). *Big Data Analítica*. Springer India. doi:10.1007/978-81-322-3628-3
- Pollock, S. M., & Maltz, M. D. (1994). *Chapter 1 Operations research in the public sector: An introduction and a brief history. Operations Research and The Public Sector, 1–22*. doi:10.1016/s0927-0507(05)80082-9
- Rana, N. P., Slade, E. L., Sahu, G. P., Kizgin, H., Singh, N., Dey, B., ... Dwivedi, Y. K. (Eds.). (2020). *Digital and Social Media Marketing. Advances in Theory and Practice of Emerging Markets*. doi:10.1007/978-3-030-24374-6
- Sabarmathi, G. & R, Dr. Chinnaiyan. (2020). *Big Data Analítica Framework for Opinion Mining of Patient Health Care Experience*.
- Schallmo, D. R. A., & Williams, C. A. (2018). *Digital Transformation Now! SpringerBriefs in Business*. doi:10.1007/978-3-319-72844-5
- Schichl, H. (2004). *Models and the History of Modeling*. In *Applied Optimization* (pp. 25–36). Springer US. doi: 10.1007/978-1-4613-0215-5_2
- Shivakumar, S. K., & Sethii, S. (2019). *Building Digital Experience Platforms*. doi:10.1007/978-1-4842-4303-9

Shivakumar, S. K. (2016). *Enterprise Content and Search Management for Building Digital Platforms*. John Wiley & Sons, Inc. doi:10.1002/9781119206842

Shorikov, A. F., Filippova, A. S., & Tyulyukin, V. A. (2018). Application of dynamic economic-mathematical modeling in optimization problems in banking. doi: 10.1063/1.5082023

Shu, H. (2016). Big data Analítica: six techniques. *Geo-Spatial Information Science*, 19(2), 119–128. doi: 0.1080/10095020.2016.1182307

SN Education B.V. (2001). *Electronic Banking*. Vieweg Teubner Verlag. doi:10.1007/978-3-322-86627-1

Sun, N., Morris, J. G., Xu, J., Zhu, X., & Xie, M. (2014). iCARE: A framework for big data-based banking customer analytics. *IBM Journal of Research and Development*, 58(5/6), 4:1–4:9. doi:10.1147/jrd.2014.2337118

Taha, Handy (2012). *Investigación de operaciones*.

Tansel İç, Y. (2012). *Development of a credit limit allocation model for banks using an integrated Fuzzy TOPSIS and linear programming*. *Expert Systems with Applications*, 39(5), 5309–5316. doi: 10.1016/j.eswa.2011.11.005

The Analítica. (2014). In the Analítica Revolution (pp. 175–206). John Wiley & Sons, Inc. doi: 10.1002/9781118936672.ch7

Venkateswarlu, C., & Jujjavarapu, S. E. (2020). *Basic features and concepts of optimization. Stochastic Global Optimization Methods and Applications to Chemical, Biochemical, Pharmaceutical and Environmental Processes*, 1–25. doi:10.1016/b978-0-12-817392-3.00001-6

Wells, Andrew & Chiang, Kathy. (2017). *Monetizing Your Data: A Guide to Turning Data into Profit-Driving Strategies and Solutions*

Yang, X.-S. (2008). *Introduction to mathematical optimization*. Cambridge, UK: Cambridge International Science Publishing.

Zomaya, A. Y., & Sakr, S. (Eds.). (2017). *Handbook of Big Data Technologies*. doi:10.1007/978-3-319-49340-4

Zurita, M. (2017). *Digital Day: Cuatro soluciones que BCP creó con Big Data*. El Comercio Perú. <https://elcomercio.pe/economia/peru/digital-day-cuatro-soluciones-bcp-creo-big-data-427332-noticia/?ref=ecr>