



**Optimización del Margen Comercial de Préstamos de Consumo:  
Algoritmo de Optimización con Machine Learning**

Tesis presentada en satisfacción parcial de los requerimientos para obtener el  
grado de Maestro en Marketing

por:

Azabache La Torre Pablo Julio

Programa de la Maestría en Marketing

Lima, 23 de agosto de 2019

Esta tesis

**“Optimización del Margen Comercial de Préstamos de Consumo: Algoritmo de Optimización con Machine Learning”**

ha sido aprobada.

.....  
José Luis Wakabayashi Muroya (Jurado)

.....  
Gustavo Alexander Reyes Vergara (Jurado)

.....  
Alfredo Mendiola Cabrera (Asesor)

.....  
Carlos Antonio Aguirre Gamarra (Asesor)

Universidad ESAN

2019

## **Dedicatoria**

*A mi hijo Alejandro Azabache Crispín, el tiempo que dediqué a este proyecto personal fue de él, a mi madre Lola La Torre por ser ejemplo de superación y amor incondicional, y a mi hermano Irving por ayudarme con mi hijo en cada momento que esta tesis lo requirió.*

*Pablo Azabache La Torre*

## ÍNDICE GENERAL

<b>CAPÍTULO I : INTRODUCCIÓN</b> .....	1
1.1. Justificación .....	1
1.2. Objetivo.....	2
1.3. Alcances y limitaciones .....	2
<b>CAPÍTULO II : SISTEMA BANCARIO PERUANO</b> .....	3
2.1. El crédito bancario y la actividad económica .....	3
2.2. Comparación entre los principales bancos peruanos.....	4
2.3. Pricing de préstamos en la banca peruana y el problema de investigación.....	7
<b>CAPÍTULO III : PRICING EN INDUSTRIAS SELECCIONADAS</b> .....	11
3.1. “Pricing” en aerolíneas.....	11
3.2. “Pricing” en restaurantes.....	14
3.2.1. Modelo basado en costos .....	14
3.2.2. Modelo basado en la demanda.....	14
3.2.3. Modelo basado en la competencia .....	15
<b>CAPÍTULO IV : PRICING EN EL SECTOR BANCARIO</b> .....	16
4.1. “Pricing” en el contexto del marketing .....	16
4.2. La gestión de pricing en la banca.....	18
4.3. Literatura de pricing con foco en temas estratégicos .....	20
4.4. Literatura focalizada en temas analíticos y de algoritmos de optimización.....	21
<b>CAPÍTULO V MODELO DE OPTIMIZACIÓN DEL MARGEN DE GANANCIA DE PRÉSTAMOS BANCARIOS</b> .....	23
5.1. Fundamentos microeconómicos de problemas de optimización .....	23
5.2. Métodos de fijación de la tasa mínima de un préstamo bancario .....	24
5.3. Maximización del margen de ganancia de un préstamo .....	26
5.3.1. Problema de optimización .....	27
5.3.2. La función respuesta al precio y el problema de optimización.....	29
5.4. La función respuesta al precio y la disposición a pagar del cliente .....	33
<b>CAPÍTULO VI : MODELOS ECONOMETRICOS Y DE INTELIGENCIA ARTIFICIAL PARA CONSTRUIR EL ALGORITMO DE OPTIMIZACIÓN</b> .....	36
6.1. Métodos de segmentación con árboles - machine learning .....	36
6.1.1. Introducción a los métodos de árboles.....	36
6.1.2. Árboles de Clasificación (Classification trees).....	39
6.2. Modelo de regresión logística.....	43
<b>CAPÍTULO VII MODELO DE OPTIMIZACIÓN DEL MARGEN APLICADO A CRÉDITOS DE CONSUMO</b> .....	49

7.1. Esquema del modelo de optimización PriceESAN®.....	49
7.2. Visualización de la lógica de optimización y resultados del modelo PriceESAN®.....	50
<b>CAPÍTULO VIII : ESTIMACIÓN DEL MODELO DE OPTIMIZACIÓN DEL MARGEN DE GANANCIA DE PRÉSTAMOS BANCARIOS .....</b>	<b>55</b>
8.1. Definición de los datos y fuente de información .....	55
8.2. Recolección de datos y su preparación .....	56
8.2.1. Análisis exploratorio de los datos.....	56
8.2.2. Limpieza de los datos .....	57
8.2.3. Resultado de la estimación del modelo de <i>Machine Learning</i> .....	57
8.2.4. Esquema de Machine Learning del algoritmo de optimización .....	62
<b>CAPÍTULO IX PILOTO DEL ALGORITMO DE MAXIMIZACIÓN DEL MARGEN DE COMERCIAL .....</b>	<b>64</b>
9.1. Situación inicial de las ofertas proactivas sin aplicación del algoritmo .....	65
9.2. Impacto esperado de utilizar el algoritmo de optimización .....	66
9.3. Estrategia de implementación del algoritmo de optimización .....	67
9.4. Resultados del piloto del algoritmo de optimización.....	70
<b>CAPÍTULO X : CONCLUSIONES .....</b>	<b>72</b>
<b>CAPÍTULO XI : RECOMENDACIONES .....</b>	<b>72</b>
<b>ANEXOS .....</b>	<b>73</b>
I. Resultados al 1 de Julio de 2019.....	73
II. Resultados al 2 de Julio de 2019.....	73
III. Resultados al 3 de Julio de 2019.....	73
IV. Resultados al 4 de Julio de 2019.....	74
V. Resultados al 5 de Julio de 2019.....	74
VI. Resultados al 6 de Julio de 2019.....	74
VII. Resultados al 7 de Julio de 2019.....	75
VIII. Resultados al 8 de Julio de 2019 .....	75
IX. Resultados al 9 de Julio de 2019.....	75
X. Resultados al 10 de Julio de 2019.....	76
XI. Resultados al 11 de Julio de 2019.....	76
XII. Resultados al 12 de Julio de 2019.....	76
XIII. Resultados al 13 de Julio de 2019 .....	77
XIV. Resultados al 14 de Julio de 2019 .....	77
XV. Resultados al 15 de Julio de 2019.....	77
XVI. Resultados al 16 de Julio de 2019 .....	78
XVII. Resultados al 17 de Julio de 2019 .....	78

XVIII. Resultados al 18 de Julio de 2019 .....	78
XIX. Resultados al 19 de Julio de 2019 .....	79
XX. Resultados al 20 de Julio de 2019.....	79
XXI. Resultados al 21 de Julio de 2019 .....	79
XXII. Resultados al 22 de Julio de 2019 .....	80
XXIII. Resultados al 23 de Julio de 2019 .....	80
XXIV. Resultados al 24 de Julio de 2019 .....	80
<b>BIBLIOGRAFÍA</b> .....	<b>81</b>

## LISTA DE FIGURAS

Figura 1: Índice Margen Financiero Neto: 4 principales bancos de Perú .....	xiii
Figura 2: Modelo de Pricing PriceESAN®.....	xiv
Figura 3: Margen Financiero Bruto de la banca múltiple .....	1
Figura 4: Evolución del crédito del sistema bancario peruano .....	3
Figura 5: PBI y Ratio de Morosidad del sistema bancario peruano.....	4
Figura 6: Evolución de las colocaciones de los principales bancos peruanos.....	5
Figura 7: Evolución del ratio provisiones sobre colocaciones principales bancos (Índice: 2010=100).....	5
Figura 8: Margen financiero neto como % de los ingresos financieros .....	6
Figura 9: Evolución de los ingresos financieros de los principales bancos peruanos (Índice: 2010=100).....	7
Figura 10: Etapas generales del proceso de pricing en la industria de aerolíneas.....	12
Figura 11: Estructura de la gestión de pricing .....	19
Figura 12: Componentes de la tasa costo de préstamos bancarios.....	24
Figura 13: Curva de demanda de mercado de un producto.....	27
Figura 14: Curva de demanda de mercado de un producto y la función de ingresos.....	30
Figura 15: Curva de demanda de una empresa bajo competencia perfecta .....	31
Figura 16: Partición y CART – Paso 1 .....	37
Figura 17: Partición y CART – Paso 2 .....	38
Figura 18: Partición y CART – Paso 3 .....	39
Figura 19. Función logística.....	45
Figura 20: Estructura de optimización del modelo PriceESAN®.....	50
Figura 21: Tipos de datos del modelo PriceESAN® .....	51
Figura 22: Curvas de Comportamiento del Modelo PriceESAN® .....	51
Figura 23: Flujo Customer Lifetime Value, indicadores de rentabilidad y componentes de la tasa mínima: Modelo PriceESAN® .....	53
Figura 24: Modelo de Willingness-to-pay del Modelo PriceESAN® .....	54
Figura 25: Modelo CTREE de “DESEMBOLSO” vs “TASA” .....	58
Figura 26: Grupo 1: elección de variables de control .....	59
Figura 27: Grupo 1 – grupos observados y probabilidades estimadas.....	61

Figura 28: Esquema de Machine Learning del flujo de estimación de los modelos de optimización.....	63
Figura 29: Resultados del Piloto .....	71

## LISTA DE TABLAS

Tabla 1: Criterios de segmentación para la fijación de precios en aerolíneas.....	13
Tabla 2: Métodos tradicionales de fijación de precios .....	25
Tabla 3: Ventajas y desventajas de los métodos tradicionales de fijación de precios.....	26
Tabla 4: Tipos de elasticidad .....	30
Tabla 5: Funciones de demanda y sus propiedades .....	35
Tabla 6: Inputs determinísticos y estocásticos del modelo PriceESAN®.....	52
Tabla 7: Tasas mínimas, promedio y máximas por tipo de préstamo de consumo .....	56
Tabla 8: Montos de préstamos mínimos, promedio y máximo por tipo de préstamo .....	56
Tabla 9: Tasas mínimas, promedio y máximas por tipo de segmento comercial.....	56
Tabla 10: Montos de préstamos mínimos, promedio y máximo por segmento comercial.....	57
Tabla 11: Regresión logística para el grupo 1.....	60
Tabla 12: Tabla de clasificación para el grupo 1 .....	60
Tabla 13: Prueba de Hosmes y Lemeshow .....	60
Tabla 14: Distribución de leads por segmento comercial .....	65
Tabla 15: Resultados de la campaña del mes de junio.....	66
Tabla 16: Resultados esperados de la campaña del mes de julio con algoritmo parcial.....	67
Tabla 17: Estrategia de optimización de margen para el segmento 1 .....	67
Tabla 18: Estrategia de optimización de margen para el segmento 2 .....	68
Tabla 19: Estrategia de optimización de margen para el segmento 3 .....	68
Tabla 20: Estrategia de optimización de margen para el segmento 4 .....	69
Tabla 21: Estrategia de optimización de margen para el segmento 5 .....	69
Tabla 22: Resultados al 24 de Julio de 2019.....	70

## **AGRADECIMIENTOS**

*Agradezco a Alfredo Mendiola que por segunda vez fue mi profesor, esta vez en la maestría de marketing. A Carlos Aguirre que luego de haber sido mi profesor en la maestría de finanzas me ha permitido contar con su amistad y sus consejos profesionales. En ambos, destaco su calidad personal que combinado con su amplio conocimiento hicieron de ESAN una verdadera casa de estudio. Esta investigación está inspirada en una de las clases que impartió Alfredo en la maestría de marketing.*

*Sinceramente, gracias.*

## **PABLO JULIO AZABACHE LA TORRE**

Gerente con experiencia liderando estrategias de negocio, análisis de mercado y gestión de riesgos en bancos líderes. Trabajo en equipo con directores para alcanzar resultados en ventas, rentabilidad y morosidad. Líder en el diseño y ejecución de estrategias innovando en business intelligence (BI) & analytics (BA). Visión global para anticipar amenazas e identificar oportunidades para la toma de decisiones.

### **EXPERIENCIA PROFESIONAL**

#### **BBVA CONTINENTAL**

##### **Principal Pricing Manager**

noviembre 17-Actualidad

- Gestión de pricing en los productos crédito efectivo, incremento de S/ 50 millones en facturación.
- Diseño de estrategias para defender la rentabilidad de un portafolio de 1,780 millones de masa salarial (13 mil empresas nominas), ante ataque de bancos competidores sobre CTS y pago de haberes. En la propuesta de valor y pricing se utilizó modelos de customer lifetime value.
- Aumento en 20 millones en los ingresos financieros del producto tarjetas de crédito, mediante el diseño de estrategias de repricing de los productos: compras, efectivo y subrogado.
- Construcción de modelos de pricing de los productos: PCOM-CP Negocios, Leasing Negocios, PCOM-LP Empresas.
- Recalibración de modelos de pricing de los productos: hipotecario, PLD y todos los modelos de los productos del segmento Negocios.

#### **BANCO DE CRÉDITO DEL PERÚ**

##### **Gerente Pricing Banca Minorista y Pyme**

2015- agosto.2017

Liderar la nueva gerencia de pricing que incluye banca mayorista. Reportar a los Gerentes Centrales el monitoreo de rentabilidad y precios. Soporte analítico al negocio en el diseño de estrategias de marketing y ventas. Liderar la innovación en BI & BA. Supervisaba a 9 personas.

- Incremento en S/. 20 millones en la utilidad neta de la banca minorista, mediante estrategias de precios y nuevas políticas de descuento en hipotecario, vehicular, crédito efectivo y tarjetas de crédito.
- Aumento de 10% en la efectividad de las campañas de tarjetas de debito, a través de la construcción del modelo de valorización de tarjetas (CLV) y nueva segmentación de clientes.
- Innovación en business intelligence y analytics, logrando:
  - Creación y lanzamiento de los productos crédito efectivo Bajos Ingresos y Pyme Multipropósito, mediante la identificación de nuevos segmentos y perfiles de clientes.
  - Reducción de pérdidas por S/. 6 millones al año en crédito efectivo, incorporando el error de modelo en los precios, nueva herramienta de pricing y reduciendo la mala venta.
  - 7% de incremento en las ventas de hipotecario, utilizando willingness to pay, frontera eficiente y rentabilidad “visión cliente”.
- Diseño y despliegue de tableros de control (dashboard) con KPIs, mapas de valor y price waterfall; permitiendo por primera vez monitorear el performance de precios y la rentabilidad de los productos a nivel de cosechas.

- Reducción de 3 meses a 1 mes en el tiempo de generación de reportes para el monitoreo de rentabilidad y precios, mediante nuevo modelo de datos y automatización de procesos de Big Data.
- Liderazgo en desarrollo de talento humano incorporando capacitación y alcanzando un clima laboral de 99/100.

#### **Gerente Adjunto Pricing Pyme**

2014-2015

Creación de la gerencia de pricing. Gestión de pricing Pyme. Innovar en BI & BA. Supervisaba a 3 personas.

- Miembro del equipo que creó la gerencia de pricing, con responsabilidades en: definir sus funciones, establecer el gobierno de políticas de precios y crear la infraestructura de business intelligence & analytics.
- Incremento de S/. 150 millones en ventas y S/. 10 millones anual en la utilidad neta, mediante estrategias de precios.
- Innovación en business intelligence y analytics, logrando:
  - 5% de aumento en el saldo utilizado de las tarjetas de crédito Pyme, mediante elasticidades.
  - Ahorro de S/. 1.5 millones al año en gastos por comisiones de ventas, vía nueva política de comisiones para reducir la mala venta.
  - Aumento del ROE en 100 pbs., mediante la rentabilización de clientes identificados con utilidad negativa.
  - Política y herramienta de retención de clientes, evitando fuga de préstamos por S/. 120 millones al año.
- Reducción de la morosidad en S/. 15 millones al año en el producto capital de trabajo y S/. 5 millones en tarjeta de crédito Pyme, utilizando algoritmos de optimización y nuevos métodos de segmentación.

#### **Subgerente Gestión Global de Riesgos**

2012-2013

Administración de los modelos de capital económico e informes de gestión de riesgos corporativos.

- Gestión de los modelos de capital económico y stress testing de riesgo de crédito, ALM, trading y operacional.
- Construcción de modelo para estimar el impacto de las variaciones del tipo de cambio sobre las provisiones.
- Líder de un equipo de 3 personas para validar las herramientas de pricing del producto hipotecario y tarjetas de crédito, detectando oportunidades de mejora en la fijación de precios y líneas.

### **BANCO CENTRAL DE RESERVA DEL PERÚ (BCRP)**

#### **Especialista Senior en Política Monetaria | Estabilidad Financiera**

2006-2012

- Diseño de estrategias de operaciones monetarias y cambiarias (emisión de certificados de depósitos, compra/venta de dólares, etc.) con el objetivo de influir en la tasa de interés interbancaria.
- Miembro del equipo que elabora la propuesta de política monetaria de cambios en la tasa de referencia.
- Encargado de la valorización de bancos, CMACs, CRACs, Edpymes y Financieras.
- Construcción de modelos de proyección y de stress testing de riesgo de crédito del sistema bancario peruano.

## **MINISTERIO DE ECONOMÍA Y FINANZAS**

### **Asesor en estudios macro-fiscales**

2004-2006

- Elaboración de informes técnicos requeridos por el Viceministro de Economía en temas de política fiscal.
- Miembro del equipo que elabora el Marco Macroeconómico Multianual.

## **CORPORACIÓN FINANCIERA DE DESARROLLO-COFIDE**

### **Analista de Riesgos**

2003-2004

- Evaluación de propuestas de crédito para el otorgamiento de líneas a Cajas Municipales.
- Elaboración de la metodología para evaluar la exposición de COFIDE al riesgo cambiario crediticio.

## **FORMACIÓN PROFESIONAL**

### **ESAN Graduate School of Business**

- Magister en Finanzas (Mención: Valorización de Empresas)

2012-2014

### **UNIVERSIDAD NACIONAL DE TRUJILLO**

- Economista, titulado

1997-2002

### **OTROS ESTUDIOS**

- FONDO MONETARIO INTERNACIONAL-FMI -Washington D. C.
- OSINERG-UNIVERSIDAD DEL PACÍFICO
- BANCO CENTRAL DE RESERVA DEL PERÚ

2008 y 2012

2004

2003

## **IDIOMAS**

Inglés – Nivel Avanzado

## **MANEJO DE PROGRAMAS**

Microsoft Office – Nivel avanzado

Python – Nivel avanzado

SQL – Nivel avanzado

Eviews – Nivel avanzado

Stata – Nivel avanzado

## RESUMEN EJECUTIVO

**Grado:** Maestro en Marketing

**Título de Tesis:** Optimización del Margen Comercial de Préstamos de Consumo: Algoritmo de Optimización con Machine Learning

**Autor:** Azabache La Torre, Pablo Julio

### **Resumen:**

Las innovaciones realizadas en esta era digital han incrementado el poder de los consumidores y ha traído el concepto de: “todo está al alcance de un botón”. Los consumidores ven con naturalidad la hiperdisponibilidad de búsquedas y compras. Así, los grandes volúmenes de información y su facilidad de acceso han incrementado el poder de los consumidores. El marketing de las marcas ya no tiene el poder de influencia de antes y los consumidores buscan información de otros para decidir qué comprar y dónde comprar el producto con más calidad a menor precio.

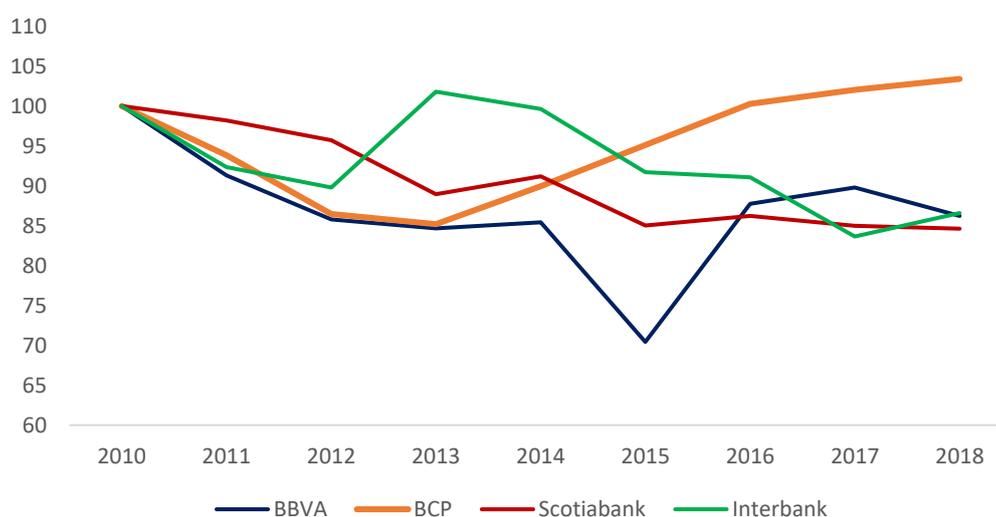
El negocio bancario no es ajeno al impacto de la transformación digital. La tecnología ha mejorado las ofertas de productos y servicios financieros, ha incrementado el acceso a este mercado y ha disminuido los costos para los clientes. Por otro lado, los gigantes tecnológicos (Amazon, Google, Facebook) amenazan a la banca tradicional y a su estabilidad. Estos nuevos oponentes son expertos en inteligencia artificial, big data y la computación en la nube. Esto último ha sido presentado en el reporte de estabilidad financiera, publicado el 14 de febrero de 2019, elaborado por Financial Stability Board.

En Perú el bajo crecimiento económico, las innovaciones tecnológicas y la entrada de nuevos competidores han incrementado la competencia en la banca. Esta mayor competencia ha reducido la tasa de interés de los préstamos, algo positivo para los consumidores. Sin embargo, se han reducido los márgenes de ganancia de los bancos. Esto podría llevar a los bancos a tomar mayor riesgo para mantener sus márgenes y con ello un impacto negativo en la estabilidad financiera. Por ejemplo, en la figura 1 se muestra la evolución del índice de margen financiero neto de provisiones de los 4

principales bancos de Perú (año base 2010). Se observa que, luego de la crisis financiera internacional todos han reducido sus márgenes con excepción del Banco de Crédito.

La evolución del margen neto de los principales bancos de Perú trae consigo la siguiente pregunta ¿por qué el BCP ha sido el único banco que ha incrementado su margen? La razón es que ha sido el único banco que ha innovado en tecnología para gestionar la fijación de sus precios (esto también es llamado “pricing”). El BCP en el año 2013 creó su gerencia de pricing e invirtió en modelos de fijación de precios llamados CLV (*customer life-time value*), los cuales tienen algoritmos que maximizan el margen del préstamo otorgado. El resto de bancos han creado su unidad de precios en los últimos años, pero aún no cuentan con la tecnología de optimización de márgenes.

Figura 1: Índice Margen Financiero Neto: 4 principales bancos de Perú



Fuente: SBS.

Elaboración: Autor de esta tesis.

En Perú, a pesar que los bancos tienen grandes volúmenes de información (estructurada y no estructurada) no la utilizan en su totalidad para conocer a sus clientes y fijar precios dinámicos que les permita maximizar sus ganancias. Además, aún no utilizan los avances en inteligencia artificial para construir algoritmos que les permita conocer la disposición a pagar de sus clientes. Cabe mencionar que, en Perú hay pocos profesionales con experiencia en inteligencia artificial aplicado al pricing de préstamos,

lo cual es una limitante. Ha esto se suma la escasa literatura tanto teórica como empírica de esta línea de trabajo.

En esta investigación se utilizan técnicas de inteligencia artificial para diseñar un algoritmo que permite maximizar el margen comercial de los préstamos bancarios. El margen comercial es definido como la diferencia entre la tasa de interés que se cobra menos la tasa costo del préstamo. En otras palabras, es el margen que crea valor para el banco. El algoritmo es incorporado en un modelo de pricing llamado PriceESAN® (ver figura 2).

Figura 2: Modelo de Pricing PriceESAN®

The screenshot shows the 'PriceESAN® Loan PLD' interface. It is divided into two main panels: 'DATOS DE SOLICITUD DEL PRÉSTAMO' (Loan Application Data) and 'MODELO DE ELASTICIDAD' (Elasticity Model).

**DATOS DE SOLICITUD DEL PRÉSTAMO:**

- Datos generales del cliente:** Tipo Documento: DNI, N° de Documento: 80902019, Nombre/Razón Social del Cliente: Alejandro Gabriel La Torre.
- Datos personales:** Género: M, Edad: 33, Estado civil: Casado, N° Dependientes: 1, Vivienda: Propia, Años de residencia: 5.
- Datos profesionales:** Educación: Magister, Ocupación: Economista, Situación laboral: Estable, Años en la empresa: 7, Cargo: Gerente, Sector económico: Telecom.
- Financiera:** Ingresos: S/. 25,000, Otros ingresos: S/. 0.0, Total deuda SF: S/. 250,000, Hipotecario: S/. 225,000, PLD: S/. 0.0, Vehicular: S/. 0.0, Tarjetas: S/. 25,000, CTS: S/. 200,000, Ahorros: S/. 0.0.
- Banca:** Score: Riesgo bajo, Segmento comerc.: VIP, Estrategia: Vincular.

**MODELO DE ELASTICIDAD:**

- Modelos de WTP:** Logit demand:  $d(p) = N \frac{e^{-bp}}{1 + e^{-bp}}$ ; Additive uncertainty:  $\epsilon(p, \xi) = \frac{p}{D(p, \xi)} \frac{\partial D(p, \xi)}{\partial p} = \frac{\epsilon(p)}{1 + \xi/d(p)}$ .
- Estimation methods:** 
$$l = \prod_{k=1}^N \left[ \frac{e^{\beta^T c(k)}}{\sum_{j \in S} e^{\beta^T y_j} + 1} \right] \max_{\beta} \ln l$$
- Figura Willingness to pay:** A scatter plot showing 'Probabilidad' (Probability) on the y-axis (0% to 120%) and 'Tasa de Interés' (Interest Rate) on the x-axis (0.00% to 15.00%). The plot shows a dense cloud of blue points and a curve of red points, indicating the relationship between interest rate and probability.

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

En la aplicación empírica se utiliza información de créditos de consumo de un banco. Por fines de confidencialidad no se da el nombre del banco y se dan nombres generales a las variables.

El algoritmo de inteligencia artificial definió 4 grupos homogéneos. Las variables de homogenización de clientes son: riesgo del cliente, nivel de deuda en el sistema

financiero, nivel de pasivos, nivel de ingresos. Luego, en la estimación del modelo de *willingness-to-pay* se utilizó la función llamada *logit-response function*:

$$d(p) = \frac{C e^{-(a+bp)}}{1 + e^{-(a+bp)}}$$

Finalmente, se hizo un piloto de prueba en las ofertas proactivas del banco del mes de julio de 2019. Estas ofertas son llamadas leads. La meta fue incrementar el volumen de las colocaciones en 30 millones y el margen neto en 4.5 millones. Desde que este piloto iba a tener un impacto real en la cuenta de resultados del banco se decidió aplicar de manera parcial. Es decir, se aplicó en los leads de la fuerza de ventas de distintos canales. Sin embargo, luego de que en la primera semana se dieron resultados positivos se decidió expandir el piloto a las ofertas reactivas.

El piloto fue exitoso se logró incrementar las colocaciones de los créditos de consumo en 33 millones con un margen de utilidad de 5.1 millones adicional. Debe comentarse que, la implementación de un sistema de esta naturaleza requiere de un soporte administrativo operativo de la institución bancaria.

En conclusión, los bancos pueden aumentar sus márgenes de ganancia a través de una gestión de pricing soportada por algoritmos que permitan identificar la disposición a pagar de sus clientes. Estos algoritmos de inteligencia artificial se pueden automatizar en línea en el momento que ingresa nueva información de los clientes.

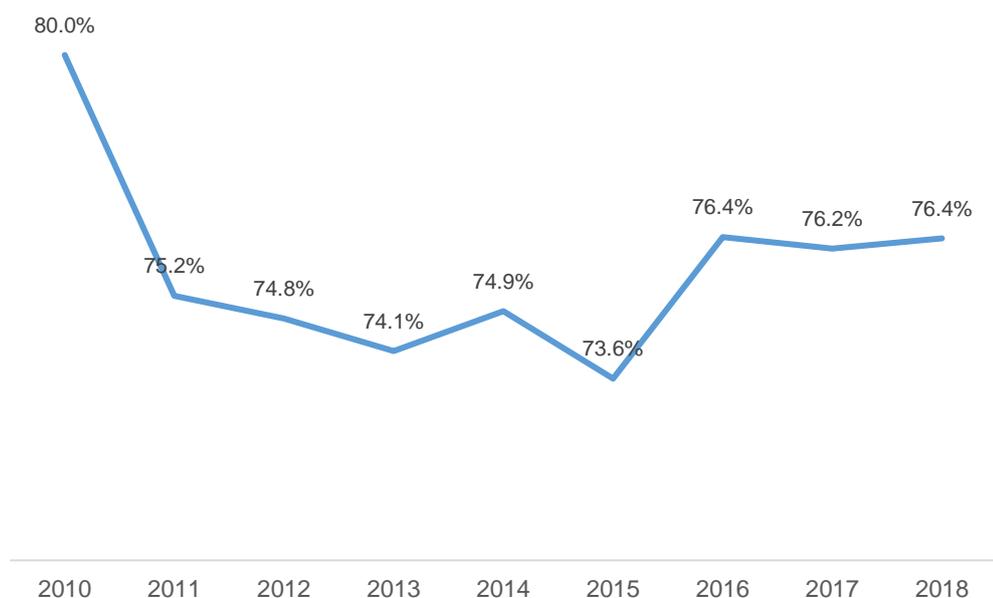
## CAPÍTULO I : INTRODUCCIÓN

### 1.1. Justificación

La era digital casi ha eliminado las barreras geográficas de los mercados y los costos de transporte. Los consumidores comparan las ofertas disponibles en sus países con las ofertas de China, India, etc. La única barrera es el tiempo de envío. Según el último informe de Euromonitor 2019 “los consumidores son tan conscientes del precio como las recomendaciones de sus pares,..., además, esperan más de las empresas y desean que sus productos y servicios sean entregados tan rápido como sea posible”.

Las innovaciones tecnológicas también han influido en el negocio bancario. Sus efectos han sido positivos para los clientes. Sin embargo, también son una amenaza para la banca tradicional. Luego de la crisis financiera internacional del año 2008 se ha observado una reducción del margen financiero en casi todos los sistemas bancarios del mundo, lo que es atribuido a la mayor competencia (Ngai et all., 2016). El sistema bancario peruano no ha sido ajeno a este hecho; por ejemplo, el margen financiero bruto como porcentaje de los ingresos financieros pasó de 80 por ciento en el año 2010 a 76.4 por ciento en el año 2018 (ver figura 3).

*Figura 3: Margen Financiero Bruto de la banca múltiple*



Fuente: SBS.

Elaboración: Autor de esta tesis.

En este contexto la actividad de fijación de tasas de interés, llamada “pricing”, es clave en la gestión de la rentabilidad de los bancos.

Los clientes, personas y empresas, creen que los bancos con toda la información que poseen los conocen bien, y que utilizan algoritmos sofisticados para obtener toda su disposición a pagar. Incluso, algunos supuestos expertos en banca, que no han trabajado en esta creen lo mismo.

Sin embargo, la realidad es otra y en general los bancos no conocen bien a sus clientes. Estos han venido fijando sus tasas de interés haciendo uso de métodos básicos que poco reflejan el comportamiento de los clientes. Esto último se ha mantenido por muchos años a pesar de contar con amplia información y tener a su disposición los últimos avances estadísticos y matemáticos.

Hasta hace pocos años los bancos han fijado sus tasas de interés sólo considerando criterios de monto y riesgo; y en algunos casos incorporando variables demográficas. Es decir, han fijado su tasa de interés haciendo uso de matrices de doble entrada. Dada la coyuntura actual esta forma de fijar los precios no da respuesta a ningún objetivo que quieran alcanzar los bancos.

Debe anotarse que, diversa literatura señala que el “pricing” es una de las palancas más poderosas para incrementar los beneficios en las empresas. Se estima que mejoras en la fijación de precios tiene un impacto entre 6%-15% en los ingresos financieros (Baker et al., 2010).

Lo anterior muestra la relevancia y la necesidad que tienen los bancos de hacer un pricing que les permita maximizar sus ingresos.

## 1.2. Objetivo

Diseñar un algoritmo para bancos que permita diseñar estrategias de pricing sobre la base del perfil del cliente y su disposición a pagar a fin de maximizar su margen comercial.

## 1.3. Alcances y limitaciones

El alcance de esta investigación es diseñar y estimar un algoritmo que permita a un banco maximizar su margen comercial. Se estima la función de respuesta al precio del

banco que permite estimar la elasticidad precio de los préstamos. Aunque en esta investigación se utiliza la metodología *risk-based-pricing* para estimar el margen comercial no se presentan las estimaciones. Es decir, no se ocupa de presentar la metodología económica y estadística de los componentes de la tasa costo de un préstamo.

La principal limitación en esta investigación es la disponibilidad de información de cotizaciones y perfiles de clientes. Esta información no es pública.

## **PARTE 1**

### **MARCO CONTEXTUAL**

*La investigación se inicia con el marco conceptual de la relación de la banca con el crecimiento económico. Se presenta las principales características de los beneficios y de riesgo de los 4 bancos principales de Perú*

## CAPÍTULO II : SISTEMA BANCARIO PERUANO

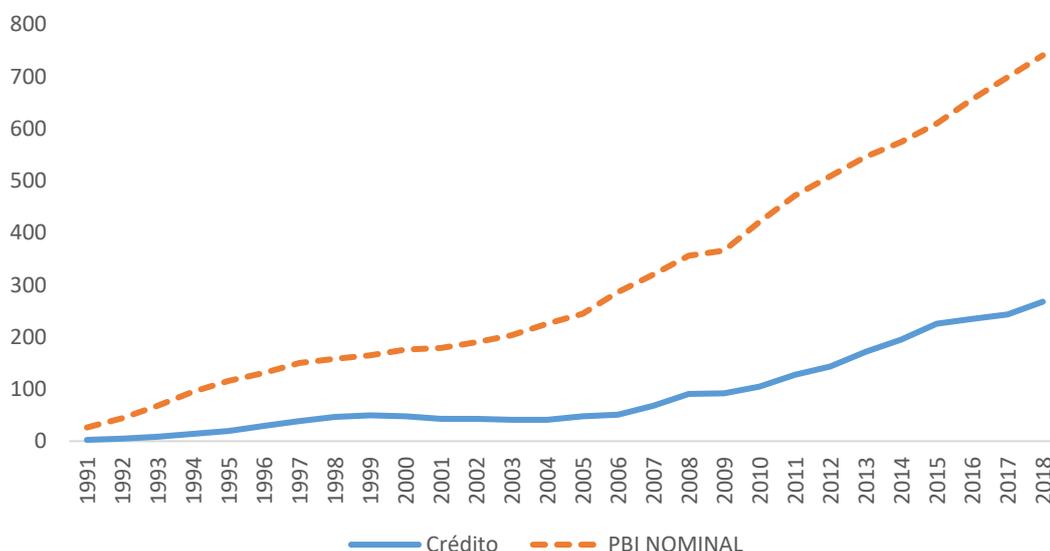
Se inicia la investigación caracterizando al sistema bancario peruano. Se describe su relación e importancia con el crecimiento económico. Luego, se hace una comparación de los indicadores de rentabilidad y métricas de riesgo entre los cuatro bancos principales de Perú.

### 2.1. El crédito bancario y la actividad económica

Dado que esta investigación se centra en el pricing de préstamos bancarios es relevante conocer la situación actual de la industria bancaria. En particular, las características del sistema bancario peruano y su forma de hacer pricing.

El crédito bancario juega un rol importante en el desarrollo económico de los países, más aún en países en vías de desarrollo donde el mercado de bonos y de acciones no es muy dinámico. Existe vasta literatura que respalda lo mencionado; por ejemplo, Levine, R. (2005); Rault et al. (2014).

*Figura 4: Evolución del crédito del sistema bancario peruano*



Fuente: SBS.

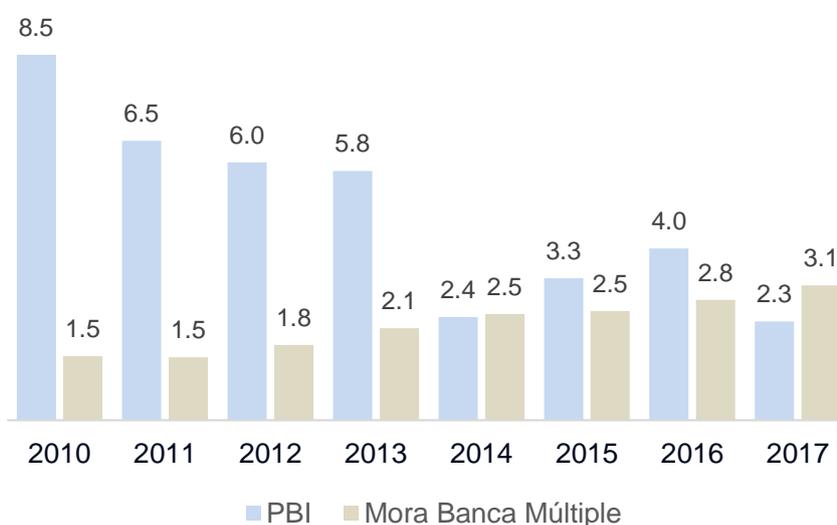
Elaboración: Autor de esta tesis.

El crédito bancario como el PIB se caracterizan por mantener una tendencia paralela (ver figura 4). Si crece el PIB tiende a crecer el crédito bancario. En otras palabras, el crecimiento económico implica una mayor demanda de financiamiento que es

satisfecha en parte por los bancos. Por ejemplo, entre el 2009-2018 en Perú el crédito al sector privado creció a una tasa promedio de 11.6 % mientras que el PBI real creció en 4.4% en promedio.

La mayor actividad crediticia expone a los bancos al riesgo de crédito. Una medida básica de este riesgo es el ratio de morosidad. En Perú, este ratio ha ido incrementándose luego de la crisis financiera internacional, pasando de 1.5% en el año 2010 a un ratio de 3.1% en el año 2017. Este comportamiento de la morosidad ha sido acompañado por una reducción en la actividad económica (ver figura 5).

*Figura 5: PBI y Ratio de Morosidad del sistema bancario peruano*



Fuente: SBS y BCRP.  
Elaboración: Autor de esta tesis.

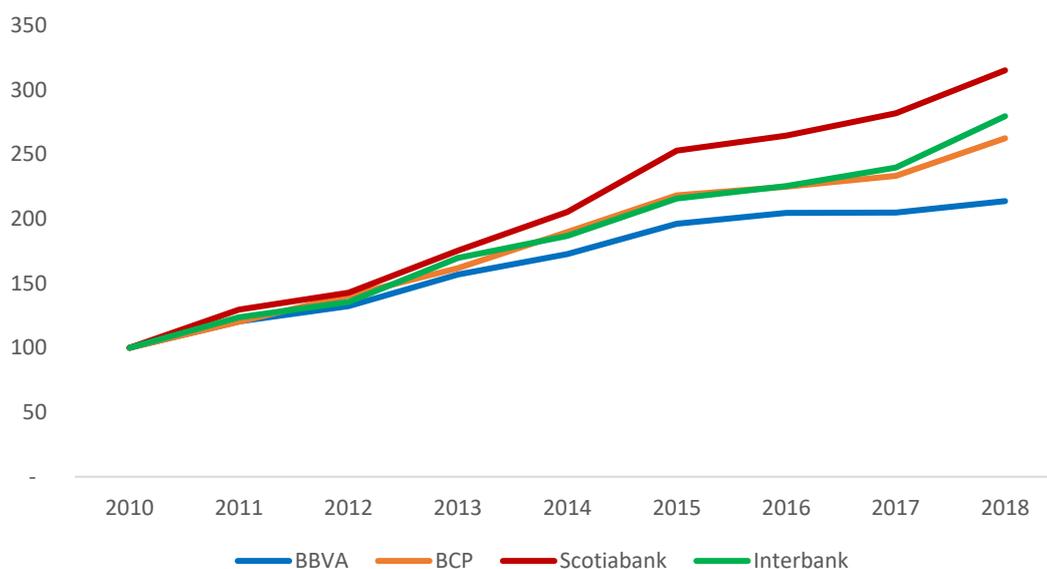
## 2.2. Comparación entre los principales bancos peruanos

Es relevante para esta investigación establecer las características de los principales bancos que componen el sistema bancario peruano: Banco de Crédito del Perú -BCP, Banco Bilbao Vizcaya Argentaria - BBVA, banco Scotiabank y banco Interbank.

En los últimos nueve años el banco que ha registrado el mayor crecimiento en colocaciones es el Scotiabank. Por otro lado, el BBVA aun siendo el segundo mayor banco en tamaño<sup>1</sup> es el que menos ha crecido (ver figura 6).

<sup>1</sup> El tamaño se define como el saldo del total de colocaciones brutas en millones de soles.

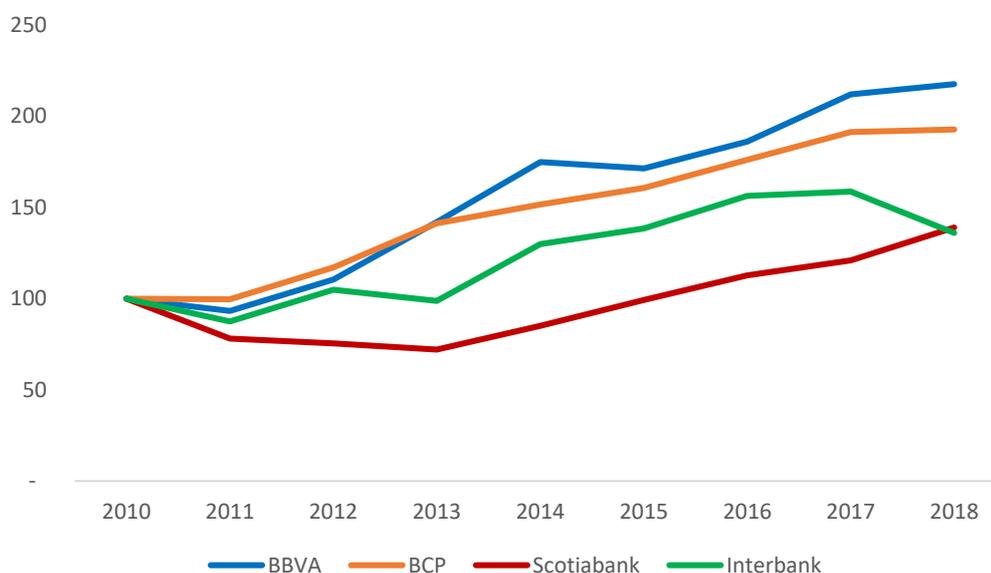
Figura 6: Evolución de las colocaciones de los principales bancos peruanos (Índice: 2010=100)



Fuente: SBS.

Elaboración: Autor de esta tesis.

Figura 7: Evolución del ratio provisiones sobre colocaciones principales bancos (Índice: 2010=100)



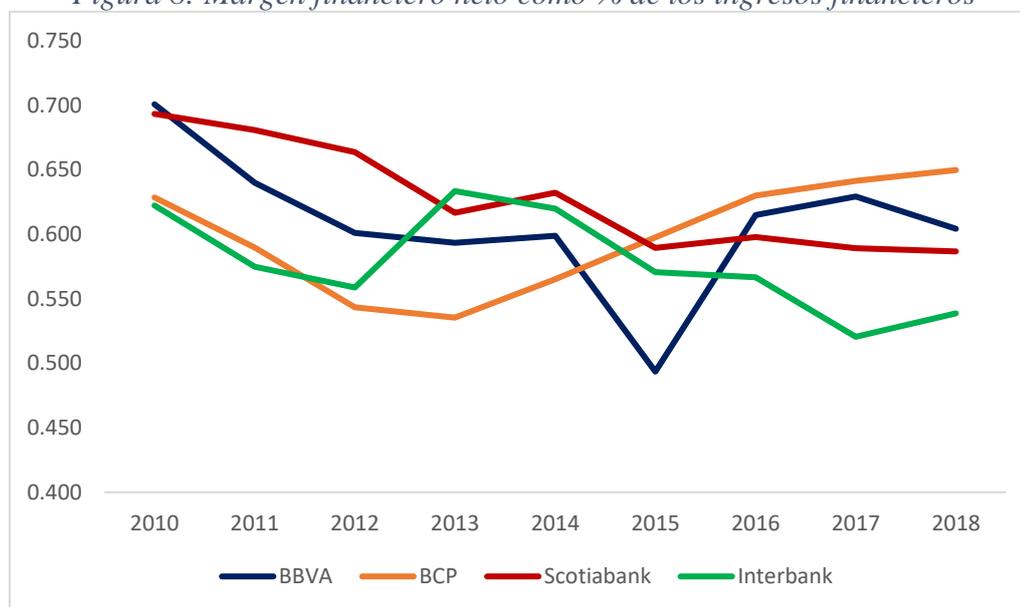
Fuente: SBS.

Elaboración: Autor de esta tesis.

En términos de riesgo de crédito todos los bancos han presentado un incremento en su ratio de provisiones sobre colocaciones. En la figura 7 se presenta el índice de este ratio. El BBVA es el que presenta el mayor crecimiento en su ratio de morosidad.

En la banca uno de los indicadores que permite medir la gestión del pricing es el margen financiero neto de provisiones (margen neto). Como se observa en la figura 8 este se ha ido reduciendo luego de la crisis financiera internacional.

*Figura 8: Margen financiero neto como % de los ingresos financieros*



Fuente: SBS.

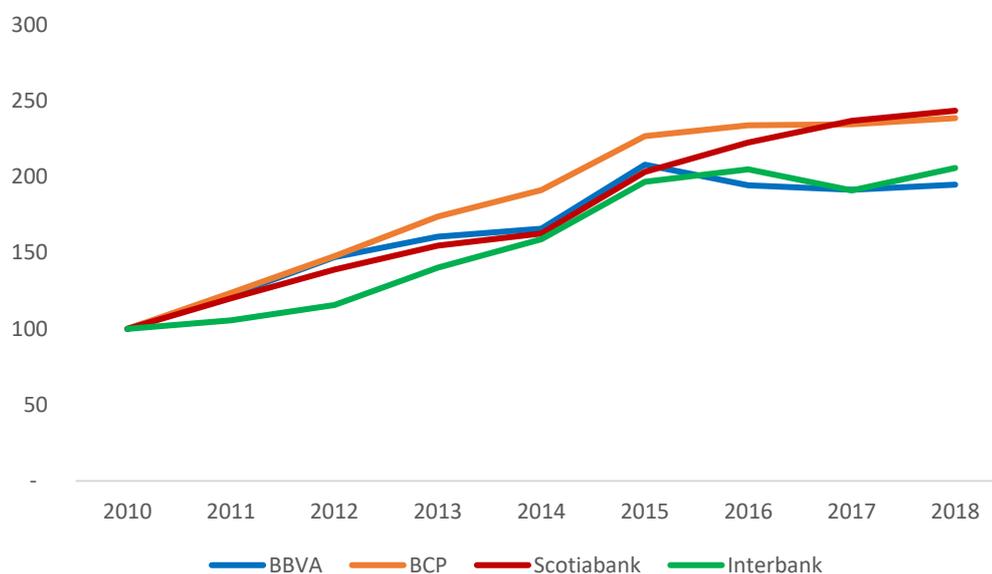
Elaboración: Autor de esta tesis.

Es interesante observar que el margen neto se ha reducido en el BBVA, Scotiabank e Interbank; pero se ha incrementado en el caso del BCP (ver figura 8). El incremento del margen neto en el BCP se relaciona con su mejor gestión de pricing. En particular, en el año 2013 el BCP crea su Gerencia de Pricing y comienza a realizar esta función apoyándose en modelos de optimización. Los otros bancos aún siguen rezagados tanto en la gestión como en las herramientas de pricing avanzado. Los gerentes de pricing de los tres bancos en los que se ha reducido el margen neto podrían asegurar que tienen un sistema de pricing avanzado; sin embargo, la realidad es que aún no llegan al nivel de desarrollo de la gestión de pricing de bancos internacionales y del BCP.

Otro indicador de la gestión de pricing es el índice de los ingresos financieros (ver figura 16). Respecto de este índice, el BCP mantuvo el mayor crecimiento hasta el año 2016, en los últimos dos años el Scotiabank ha superado al BCP en el crecimiento de los ingresos financieros. Cabe mencionar que en los últimos cinco años el BCP ha

mejorado sus procesos (en busca de eficiencia), ha reducido personal, y ha innovado en sus procesos de “pricing”.

*Figura 9: Evolución de los ingresos financieros de los principales bancos peruanos (Índice: 2010=100)*



Fuente: SBS.

Elaboración: Autor de esta tesis.

### 2.3. Pricing de préstamos en la banca peruana y el problema de investigación

De lo anterior se concluye que en la última década se ha incrementado la competencia entre los cuatro principales bancos del sistema bancario de Perú. Esto ha beneficiado a los clientes, empresas y familias, al reducirse la tasa de los préstamos. Sin embargo, ha reducido los márgenes de ganancia de los bancos. Un efecto adicional, es que los bancos han incrementado su “apetito” por el riesgo lo que podría exponer a la economía a una crisis bancaria.

La creación de valor (margen comercial positivo) es necesaria para que los bancos sigan creciendo y contribuyan al crecimiento económico (PBI). En otras palabras, para que la economía siga creciendo en forma sostenida es necesario que el sistema bancario y financiero también crezca, y así satisfacer la demanda de financiamiento de las empresas y familias; además de, mejorar los servicios que ofrecen.

La relación entre la evolución de la banca y mercados financieros y el crecimiento económico ha sido revisada ampliamente. Por ejemplo, las teorías del ciclo de vida y

de ingreso permanente del consumo señalan que las personas y familias pueden suavizar su consumo y con ello maximizar su utilidad gracias a que pueden trasladar consumo presente al futuro y viceversa; y esto sólo se logra gracias a que pueden ahorrar y tomar préstamos. Asimismo, la teoría de inversión de las empresas llamada Q-Tobin, da un rol relevante a la tasa de interés, sea de préstamos o de bonos, para las decisiones de inversión de las empresas. Por lo tanto, la generación de valor (márgenes comerciales positivos) es necesaria para que los bancos incrementen su oferta de crédito. Una revisión exhaustiva de estas teorías se puede encontrar en los trabajos de Larraín y Sachs (2002); Romer, (2012); Argandoña et al. (1996); Blanchard (2017).

Debe anotarse que la era digital y el surgimiento de bancos digitales continuarán reduciendo los márgenes financieros y afecta la continuidad de la banca tradicional. Por ello, los bancos buscan evolucionar hacia un modelo de pricing dinámico que les permita maximizar sus ingresos. Esta última idea es el foco de esta tesis.

En esta investigación se propone un algoritmo de optimización a través del cual los bancos pueden maximizar su margen comercial en función de las preferencias de los clientes.

Tanto el ciudadano de a pie, así como las grandes empresas pueden pensar que los bancos tienen algoritmos sofisticados que les permiten extraer su máxima disposición a pagar. Es decir, en el lenguaje popular “sacarles todo lo que pueden”. Esto no es del todo cierto; al menos, en el sistema bancario peruano. Es sorprendente conocer que los diferentes bancos en Perú han venido fijando sus tasas de interés utilizando segmentaciones demográficas o segmentaciones comerciales. Estos métodos de pricing no responden a ningún objetivo (maximizar beneficios, incrementar la cuota de mercado o minimizar riesgo) de la institución.

Esta investigación propone un método que soporte al pricing dinámico que es de especial relevancia para el sistema bancario peruano. También, aporta a la literatura tanto teórica como empírica, de métodos de optimización. Sin embargo, la disponibilidad de información es una limitante para probar cualquier algoritmo de maximización de beneficios. En particular, la información de préstamos a nivel de clientes no es pública.

## **PARTE 2**

### **MARCO TEÓRICO**

*La segunda parte de esta investigación está compuesta de 4 capítulos. En capítulo 3 se presenta como se realiza la fijación de precios en la industria de aerolíneas y de restaurantes. En el capítulo 4 se aborda el tema del pricing en el contexto del marketing y los métodos de estimación de la tasa costo de los préstamos bancarios. En el capítulo 5 se dan los fundamentos microeconómicos del problema de maximización de los beneficios. Se plantea el problema de optimización del margen comercial de los préstamos. Finalmente, en el capítulo 6 se presentan los métodos de estimación de machine learning y modelos logit. Estos métodos permiten estimar la función respuesta al precio de los préstamos de consumo y resolver el problema de optimización.*

## CAPÍTULO III : PRICING EN INDUSTRIAS SELECCIONADAS

En este capítulo se hace un breve resumen de cómo se hace la fijación de precios en la industria de aerolíneas y en la industria de restaurantes. Es una introducción para el siguiente capítulo que aborda el pricing en la banca.

### 3.1. “Pricing” en aerolíneas

El producto de una aerolínea es intangible. Es un servicio de transporte aéreo entre dos o más ciudades a un precio determinado con requisitos y restricciones de compra especificados. Las características del servicio de transporte aéreo son:

- a. El producto es altamente perecible, cualquier asiento vacío no tiene valor después que el avión ha despegado.
- b. El costo marginal de ofertar una unidad adicional en venta es relativamente bajo.
- c. Los precios son categorizados y fijados dentro de un conjunto pre-determinado de clases de vuelo (ejemplo, económica, clase ejecutiva o de negocios).
- d. El producto es reservado con antelación.
- e. La demanda de los clientes y su comportamiento es incierta.
- f. Los precios son asumidos para mantenerse constantes con el propósito de determinar disponibilidad de inventario.

Estos servicios son dirigidos a varios segmentos de pasajeros basados en las diferentes valoraciones que los clientes asignan a un asiento en un vuelo en particular. Las ofertas de este servicio son diseñadas para hacer “match” entre los patrones de reserva y preferencias de viaje con la disposición a pagar del cliente por ciertas características del servicio (ejemplo, disponibilidad de asiento de último minuto y servicio directo).

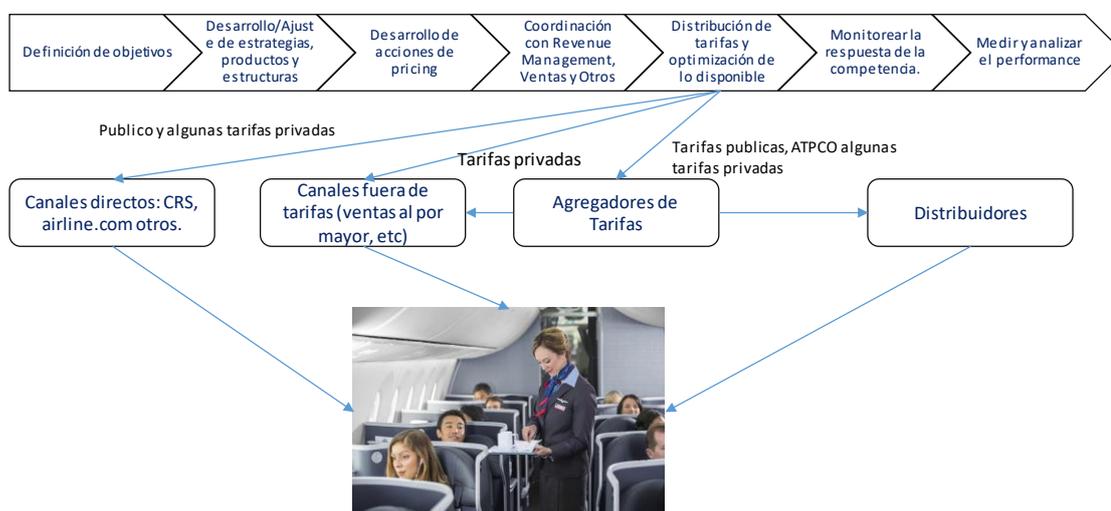
Así, aunque los pasajeros son segmentados de acuerdo a su propósito primario de viaje: negocio u ocio. Se realizan sub-segmentaciones dentro de estos dos grandes segmentos. Por ejemplo, segmentación según la trayectoria de las reservas, de acuerdo a preferencias de viaje, y segmentación por sensibilidad al precio. Esta última manera

de segmentar crea la oportunidad de sub-segmentar más y conducir un incremento en los ingresos.

La gestión de precios e ingresos en este sector está compuesta de actividades estratégicas, tácticas y operativas que usualmente se dan 12 meses antes de la salida de un vuelo (Brenda A. Barnes, 2012). La gestión es con 12 meses de anticipación debido al alineamiento con el plan corporativo. Sin embargo, esta planificación es dinámica; tal es así que las estrategias e iniciativas tácticas regionales y de grupo van evolucionando durante el año conforme las condiciones competitivas y de mercado cambian, las reservas se van realizando y se van midiendo los resultados. Con respecto a las tarifas (pricing) estas se revisan en fechas predeterminadas antes de la salida y se van ajustando con mayor frecuencia más cerca de la salida del vuelo.

En esta industria se realiza una gestión de pricing dinámica que involucra un monitoreo continuo de: las tarifas competitivas, la posición en el mercado, los cambios de horario, los eventos especiales, la estacionalidad, las tendencias de reserva y las promociones de ventas, entre otros factores (ver figura 10).

Figura 10: Etapas generales del proceso de pricing en la industria de aerolíneas



Fuente: Brenda A. Barnes - in The Oxford Handbook of Pricing Management.  
Elaboración: Autor de esta tesis.

En esta industria el modelo de precios es llamado “restriction-based-pricing” el cual es un modelo que ha evolucionado del programa “Super Savers”. Este modelo utiliza

reglas, restricciones, términos y otras condiciones de compras para calificar a un pasajero como potencial comprador de un cierto tipo de boleto. En el cuadro 1 se presentan los ocho criterios de segmentación más comunes para hacer pricing en esta industria.

*Tabla 1: Criterios de segmentación para la fijación de precios en aerolíneas*

Criterios de segmentación	Consideraciones
Sensibilidad al precio	La disposición a pagar de los clientes que viajan por negocios es diferentes a los que viajan por ocio.
Sensibilidad al tiempo	Los viajeros de negocios tienen más disposición a pagar por el vuelo y la aerolínea que mejor cumpla con los requisitos de su horario. Los pasajeros de ocio están más dispuestos a aceptar vuelos menos convenientes a cambio de precios más bajos.
Tiempo de reserva	Los viajeros por ocio tienden a comprar con mucha anticipación para acceder a descuentos. Mientras que reservas de última hora de pasajeros por negocios tienden a pagar un precio alto.
Flexibilidad	Las restricciones de reembolso, las tarifas de cambio y las tarifas de reemisión de boletos diferencian a los clientes de acuerdo con sus requisitos de flexibilidad
Duración del viaje	Los viajes de negocios tienden a ser mucho más cortos que los viajes de placer.
Afiliaciones y grupos calificados	Muchos viajeros califican para descuentos basados en su afiliación con una organización, grupo o consorcio.
Loyalty	Desde la introducción de los programas de viajero frecuente en la década de 1980, la lealtad del cliente, medida por las millas recorridas, se ha convertido en un factor importante en la segmentación del cliente.
Canal de distribución	A medida que las ventas de viajes por Internet han crecido y los canales de distribución se han multiplicado, el canal de reserva se ha convertido en un criterio de segmentación cada vez más importante.

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

### 3.2. “Pricing” en restaurantes

Los restaurantes es un gran negocio (en USA reportó 580 billones de dólares en el 2010), pero también es un negocio de alto riesgo (cerca del 25% de nuevos restaurantes quiebran en el primer año). Existen tres modelos en que los restaurantes fijan sus precios:

- a. Basado en costos
- b. Basados en la demanda, y
- c. Basado en la competencia.

#### 3.2.1. Modelo basado en costos

Bajo este modelo los restaurantes determinan el costo de la comida asociado con cada menú y aplica un multiplicador (generalmente entre 3 o 4) para determinar el precio. Sin embargo, este modelo no considera la demanda y por lo tanto los precios pueden ser más bajos de lo que los clientes están dispuestos a pagar. Además, este modelo no incorpora lo que cobra la competencia.

Los restaurantes no aplican el mismo multiplicador a ciegas a todos los platos. Los comensales traen un conjunto de expectativas de precios cada vez que abren un menú, y la mayoría de los restaurantes buscan precios para que estas expectativas no se violen.

Una desventaja de este método es que requiere una estimación precisa de los costos. Recuérdese que el costo de la comida que se sirve generalmente está determinado por las recetas las cuales están escritas por el chef. Adicionalmente, algunos restaurantes ofrecen artículos adicionales como pan y condimentos de forma gratuita, los cuales deben tenerse en cuenta en el costo de las comidas. Este costo adicional aplicado a los artículos para contabilizarlos a veces se denomina factor Q (ejemplo, en un restaurante típico de alta gama el factor Q promedio puede ser de alrededor de \$ 3.00 o más).

#### 3.2.2. Modelo basado en la demanda

Este modelo busca determinar el precio correcto para un artículo del menú al comprender cómo el precio afecta la demanda. Se utilizan comúnmente tres enfoques

para estimar el efecto del precio sobre la demanda: estimación de la disposición al pago del cliente, menú ingeniería y estimación de elasticidad de precios.

### 3.2.3. Modelo basado en la competencia

Este modelo establece los precios basado en lo que la competencia está cobrando. Los restaurantes se "compararán" con restaurantes similares o cercanos e intentarán posicionar sus precios en relación con esos restaurantes. Por ejemplo, un restaurante puede decidir que no quiere tener los precios más altos del mercado y puede intentar posicionarse como el segundo más alto. O bien, un restaurante puede decidir que quiere mantener los precios de su menú a la par con los de la competencia.

## CAPÍTULO IV : PRICING EN EL SECTOR BANCARIO

Habiendo definido la importancia de la gestión de pricing en la banca, en este capítulo se presentan los fundamentos teóricos del pricing de bancos. Se explica el rol del pricing en el contexto del marketing, se esquematiza la estructura de la gestión estratégica del pricing. Finalmente, hace una revisión de la literatura de temas de gestión y de aspectos cuantitativos del pricing.

### 4.1. “Pricing” en el contexto del marketing

El marketing ha ido evolucionando desde el marketing del producto (1.0), luego el marketing centrado en el cliente (2.0) hasta el marketing centrado en el ser humano (3.0). Para un análisis detallado de esta evolución, ver Kothler (2010).

Actualmente la economía digital está redefiniendo el marketing mix (el de las 4 P’s) hacia el marketing que busca ganar el apoyo y la confianza de los clientes a través de: i) la interacción online y el marketing digital, y ii) la interacción offline con el marketing tradicional. Con la integración de los canales online y offline se busca llegar a una estrategia de atención omni-canal (*omnichannel*). Este es llamado marketing 4.0 presentado en el libro Marketing 4.0 de Kartajaya, Setiawan y Kotler (2017).

Entre los aportes del marketing 4.0 el cambio de las 4 P’s por las 4 C’s es de especial interés en esta investigación. Las empresas utilizan el marketing mix como herramienta para planificar qué ofrecer (producto y precio) y cómo ofrecer (plaza y promoción) a los clientes. Pero en esta planificación la participación del cliente es limitada, casi nula. Sin embargo, en esta era digital los consumidores tienen más poder al estar socialmente conectados entre ellos. Los clientes pueden comparar de manera inmediata distintas ofertas, informarse sobre la experiencia de otros consumidores al usar el producto de su interés, y ahora se puede hablar de comunidades de clientes.

En este contexto, las empresas están en la necesidad de dar más participación a los clientes en su proceso de planificación. Es así que, en los últimos años se ha planteado que el marketing mix (el de las 4 P’s) sea redefinido como el marketing mix de las 4 C’s: *co-creation, currency, communal activation, and conversation*.

En el campo del marketing esta investigación se ubica en la segunda P (precio) del marketing mix que está evolucionando a la segunda C (currency) del marketing 4.0.

En el marketing mix 3.0 el precio de venta se establece a través de una combinación de diversos métodos: precio basado en costos, precio basado en la competencia y métodos de fijación de precios basados en el valor *-value-based pricing-* (Tim Smith, 2016). Se podría decir que este último método es el más evolucionado.

El método *value-based* tiene como input principal la disposición a pagar del consumidor, y esta disposición es la que conecta al cliente con las estrategias de fijación de precios de la empresa. Sin embargo, en esta era digital y de productos personalizados el marketing 4.0 propone evolucionar de un pricing estándar a un pricing dinámico (Kartajaya, Setiawan y Kotler, 2017).

Pricing dinámico es fijar precios flexibles basados en la demanda del mercado y la capacidad de utilización. Este método no es nuevo en algunas industrias tales como la hotelería y aerolíneas. Además, en la última década se ha extendido a otras industrias tales como las de online retail; ejemplo, Amazon, ebay, AliExpress, etc.

La idea fundamental del pricing dinámico es fijar un precio personalizado para cada cliente. Esto permite a las empresas optimizar sus ingresos en base al comportamiento de compra histórico de sus clientes y de sus características individuales entre otras cosas. Es decir, en la economía digital el pricing se comporta como el precio de las monedas, el cual fluctúa dependiendo de la demanda de mercado.

Una condición para realizar un pricing dinámico es contar con grandes volúmenes de información de transacciones de compra, de comportamiento de compra, perfil del cliente, datos de la competencia, entre otros. Es decir, es necesario que las empresas dispongan de grandes volúmenes de datos estructurados y no estructurados. Esto, último permite realizar análisis de big data y poder construir algoritmos de inteligencia artificial.

Es importante entender que, el pricing de préstamos bancarios, foco de esta investigación, es diferente al de otras industrias. En las demás industrias el pago para obtener un bien o servicio es inmediato y usualmente cubre todos los costos más el margen comercial. Sin embargo, en la banca la recuperación de los costos y del margen de ganancia se realiza durante un periodo de tiempo, durante el cual el cliente puede hacer fraude y no pagar. Este fraude es conocido como riesgo de crédito y su probabilidad de ocurrencia es medida por la probabilidad de default.

El riesgo de crédito ha generado crisis económicas en diversos países. En Perú en 1998 se dio una crisis bancaria con un resultado de quiebra de bancos y otras entidades financieras. Además, se rompió la cadena de pagos afectando la actividad económica. Por ejemplo, en el año 1998 el PBI creció en menos 0.4 por ciento. Trabajos referenciales de crisis bancarias por riesgo de crédito son las de Laeven, Luc and Fabian Valencia, 2008; Laeven, Luc and Fabian Valencia, 2010. Esto último evidencia la relevancia y la diferencia entre el pricing de bienes y servicios tradicionales con el pricing de préstamos bancarios.

#### 4.2. La gestión de pricing en la banca

Es muy importante tener en cuenta que la gestión de pricing debe responder a los objetivos estratégicos de la empresa. Para la banca estos objetivos estratégicos pueden ser: cuota de mercado, crecimiento de ventas, una meta de rentabilidad o un nivel de riesgo.

Es así que para implementar la gestión de pricing se requiere de una estructura que soporte dos áreas: i) la gestión estratégica de pricing y ii) sus facilitadores. De manera específica la gestión del pricing involucra tres actividades fundamentales:

1. Fijación de precios: su objetivo es fijar los precios correctos que apoyen el objetivo estratégico que la institución ha priorizado (ventas, rentabilidad o riesgo). Esto involucra diseñar estrategias de precios haciendo uso de análisis avanzados de información (*business intelligence* y *business analytics*) y de algoritmos de optimización.
2. Despliegue de precios: se centra en cómo será el despliegue del proceso de fijación de precios en los canales de venta.
3. Monitoreo de las estrategias de precios: después de desplegar el nuevo proceso de fijación de precios es necesario monitorear y evaluar si se están logrando los objetivos. En caso estos no se cumplen se realizan acciones correctivas.

Los facilitadores o palancas de pricing corresponden a todos los recursos que dan soporte y permiten que se implemente una gestión de pricing de alto nivel. Estos facilitadores involucran:

- a. Organización de la unidad de pricing.
- b. Un equipo de pricing.
- c. Recursos de tecnología de información.
- d. Modelo de datos específico para precios.
- e. Gobierno de las decisiones de pricing.
- f. Gobierno de las herramientas de pricing.

En la figura 11, se presenta la estructura de pricing antes indicada.

*Figura 11: Estructura de la gestión de pricing*



Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Este trabajo se enfoca en la fijación de precios dentro de la gestión estratégica de pricing. En particular, se centra en el diseño de un algoritmo de pricing que permita diseñar estrategias que maximicen los beneficios esperados.

Habiendo contextualizado la estructura de la gestión de pricing es posible dividir la literatura en dos grupos: literatura focalizada en temas estratégicos y literatura especializada en temas analíticos que soportan las estrategias de pricing. Esta revisión se presenta a continuación. En vista que el objetivo de esta investigación es un algoritmo de optimización del margen comercial, la literatura sobre temas estratégicos no es

profunda. Sin embargo, se dan referencias importantes para los investigadores que deseen profundizar en esta área estratégica de pricing.

#### 4.3. Literatura de pricing con foco en temas estratégicos

Hunt y Saunders (2013) presentan un “*roadmap*” para que cualquier organización evolucione hasta un nivel de excelencia en la gestión de pricing. Este *roadmap* presenta cinco niveles en la evolución de la gestión de pricing, que se detalla a continuación:

- Gestión de pricing de bombero. En esta etapa la gestión de pricing es reactiva y el gerente de precios siempre está tratando de controlar el último problema que ha surgido (pricing de bombero), usualmente con presiones para hacer reducción de precios. En este nivel de evolución se observa que los gerentes de ventas tienen alto poder de negociación en las estrategias de precios.
- Gestión de pricing de policía. En esta segunda etapa el gerente de pricing gana cierto control en el diseño de las estrategias. Los autores hacen referencia a lograr ganar el control en los descuentos y comenzar a diseñar una estructura ordenada del proceso de pricing. Así, en este nivel se relaciona al gerente de pricing como un policía que controla el tráfico.
- Gestión de pricing de compañero con el negocio. Aquí el gerente se comporta y es considerado como un compañero del negocio. Se puede decir, que hay armonía de trabajo con los gerentes de marketing, ventas y finanzas. No sólo fija los precios en base a los costos del producto o servicio, sino que considera la propuesta del valor del producto, pero no necesariamente de manera correcta. Además, se comienzan a construir modelos que soporten las estrategias de precios y a realizar análisis en base a información disponible. El pricing comienza a utilizar información de la sensibilidad de los clientes a los precios.
- Gestión de pricing científico. En esta etapa se logra una sofisticación en las herramientas que soportan las decisiones de pricing. En esta etapa se pasa de una fijación de precios en función del valor a una de optimización.

- Gestión master de pricing. Son pocas las organizaciones que llegan a este nivel de diseño de estrategias de pricing, se dice que en este nivel el gerente de pricing equilibra el arte con la ciencia.

#### 4.4. Literatura focalizada en temas analíticos y de algoritmos de optimización

La revisión de literatura de esta sección es sólo para pricing de préstamos bancarios. Para dar un orden a esta revisión primero se describe los métodos generales de estimación de la tasa mínima. Luego, se presentará la literatura relacionada a la maximización del margen de ganancia, luego a la optimización de portafolio y finalmente a temas de inteligencia artificial en pricing.

La literatura relacionada con el pricing de bancos no es extensa. Algunas investigaciones se centran en el método de fijación de la tasa mínima. El trabajo más relevante de esta línea de investigación es el de Thomas (2009). El autor muestra las técnicas estadísticas para estimar un pricing en base a riesgos. Es decir, incluir el costo del riesgo de crédito en la estimación de la tasa mínima. Este costo, es medido a través de la pérdida esperada de un préstamo, la cual se estima utilizando la técnica de modelo logit. En trabajos posteriores, se han encontrados otras técnicas que aumentan la capacidad de predicción.

Los métodos de pricing de frontera utilizan técnicas de supervivencia y riesgos en competencia para estimar la pérdida esperada durante el tiempo que el cliente tiene relación con el banco (*lifetime*). Además, esta técnica permite estimar los prepagos y cancelaciones de los créditos. Con esto, se da un gran aporte al pricing bancario al no sólo incorporar el riesgo de crédito sino el riesgo de “attrition”<sup>2</sup>. Una aplicación interesante es en el pricing de tarjetas de crédito, en la cual se tiene que hacer una optimización dual; es decir, encontrar la línea y la tasa de interés que maximizan la ganancia del banco (Azabache, 2014). Una revisión exhaustiva de esta literatura puede ser encontrada en los trabajos de Bijak et al. (2014); Tong et al. (2016).

---

<sup>2</sup> Este riesgo es definido como la probabilidad que el cliente realice una cancelación total del crédito antes de su vencimiento contractual.

Las técnicas de optimización en pricing de bancos se pueden dividir en técnicas de equilibrio general y técnicas de equilibrio parcial. Las técnicas de equilibrio general del préstamo buscan una maximización de los beneficios considerando la interrelación que existe entre todos los componentes de la tasa del préstamo. Trabajos representativos de estas técnicas son los de Dey (2010); So, Kyong y Yonghan (2014).

Los trabajos de técnicas de maximización parcial buscan la maximización del beneficio centrándose en funciones de demanda del préstamo. En particular, estas técnicas buscan fijar la tasa del préstamo estimando la disposición a pagar del cliente, pero no la interrelacionan con los otros componentes de la tasa de préstamo final. Ver el trabajo de Phillips (2005).

## CAPÍTULO V MODELO DE OPTIMIZACIÓN DEL MARGEN DE GANANCIA DE PRÉSTAMOS BANCARIOS

En este capítulo se presentan los fundamentos microeconómicos del problema de optimización del margen. Se bordan los distintos métodos para fijar la tasa costo de un préstamo bancario. Se dan los conceptos de la disposición a pagar del cliente, la función de respuesta al precio y su relación con la elasticidad precio de la demanda. Y se hace la formulación del problema de maximización a resolver.

### 5.1. Fundamentos microeconómicos de problemas de optimización

Dado que el fin de esta investigación es la maximización del margen comercial es necesario dar su definición. En esta investigación, el margen comercial es la diferencia entre la tasa de interés que se cobra y la tasa que refleja el costo total del préstamo. La tasa costo es la que cubre todos los costos que incurre el banco al otorgar un préstamo. Estos costos, van desde el costo de fondeo hasta el pago de impuestos. Más adelante se explicarán los componentes de la tasa costo en forma detallada. Por lo tanto, el margen comercial es:

$$\textit{Margen Comercial} = \textit{Tasa Cobrada} - \textit{Tasa Costo del Préstamo} \quad (1)$$

El marco teórico del problema optimización de pricing se sustenta en las teorías de optimización de los agentes económicos a nivel microeconómico. Es decir, es posible tomar los fundamentos de la teoría microeconómica del consumidor y de las empresas.

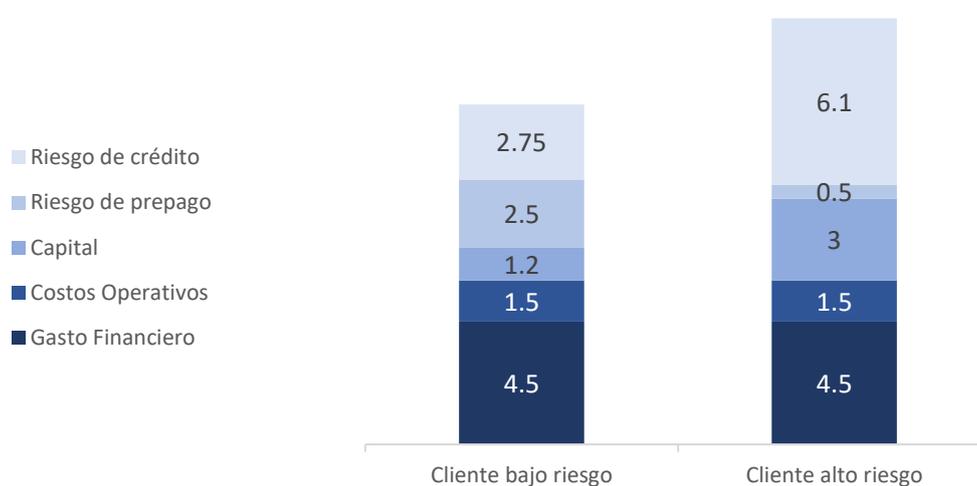
Aunque existe una extensa literatura sobre el comportamiento de maximización de las familias y las firmas, existe escasa literatura sobre modelos de optimización de pricing. Literatura representativa sobre el comportamiento de maximización de las familias y empresas son las de Nicholson (2008), Varian (2015). En estos libros de texto se abordan temas como: teorías de maximización de la utilidad de las familias, la optimización de los beneficios de las firmas, la demanda y oferta de mercado, los tipos de mercado (de competencia perfecta, monopolio, duopolio, oligopolio entre otros) y teoría de juegos.

Freixas y Rochet (1999) es considerado como referencia principal en el estudio de los fundamentos microeconómicos de la intermediación financiera de la banca. Sin embargo, los autores no dan referencia sobre modelos de optimización de pricing. En general, ellos abordan los roles de la intermediación financiera, la relación entre los prestamistas y prestatarios, cuestiones sobre racionamiento de crédito, las consecuencias macroeconómicas de las imperfecciones financieras, temas de riesgo sistémico y la gestión del riesgo en las empresas bancarias.

## 5.2. Métodos de fijación de la tasa mínima de un préstamo bancario

A fin de estimar el margen comercial es relevante definir como los bancos estiman su tasa costo, también llamada tasa mínima. Esta se define como la tasa que cubre todos los costos en los que incurre el banco al otorgar un crédito; además, incluye la rentabilidad exigida por el accionista. Los componentes de esta tasa son los siguientes: i) gasto financiero, ii) costos operativos, iii) requerimiento de capital iv) riesgo de crédito, v) riesgo de prepago y vi) rentabilidad exigida por el accionista. En la figura 12 se muestran los componentes de la tasa costos para dos tipos de clientes, el primero es de bajo riesgo y el segundo es de alto riesgo.

*Figura 12: Componentes de la tasa costo de préstamos bancarios*



Fuente: Autor de esta tesis.  
Elaboración: Autor de esta tesis.

En la literatura de pricing de productos y servicios no bancarios se destacan tres métodos para fijar precios: *cost-plus*, *market based* y *value based* (Phillips, 2005).

En el método *Cost plus* se determina el costo de cada producto y agrega un recargo porcentual para determinar el precio final. Usualmente el recargo porcentual corresponde a cubrir los costos fijos y a un retorno requerido sobre el capital. En otros casos este recargo se fija sobre una tasa histórica que usualmente se ha cargado (*rule of thumb*).

En el método *market based* la fijación de los precios se realiza de acuerdo al precio del líder del mercado, el que usualmente es menor al del líder.

El método *value based* hace referencia a un pricing *one-to-one* o personalizado; los precios se fijan para cada cliente de acuerdo al valor que este asigna al producto que ofrece la empresa. Esta metodología utiliza encuestas, focus groups y *conjoint analysis* para estimar cómo el cliente valora un producto relativo a sus alternativas, el cual es un insumo para fijar el precio final. Si bien esta metodología es la más razonable es muchas veces imposible de aplicar.

En la tabla 2 se resumen las características de estos métodos tradicionales de fijación de precios.

*Tabla 2: Métodos tradicionales de fijación de precios*

<b>Aproximación</b>	<b>Basado en</b>	<b>Ignora</b>	<b>Valorado por</b>
Cost-plus	Costos	Competencia y la disposición a pagar del cliente	Departamento de Finanzas
Market based	Competencia	Costos y disposición a pagar del cliente	Departamento de Ventas
Value based	Disposición a pagar del cliente	Costos y la competencia	Departamento de marketing

Fuente: Phillips (2005).

Elaboración: Autor de esta tesis.

En la práctica muchas empresas no adoptan una de estas metodologías al 100%; usualmente cambian de una a otra de acuerdo a objetivos que persiguen. Phillips (2005) recomienda usar un híbrido de estas metodologías en lugar de adoptar una de ellas por completo. Esto se debe a que cada una de ellas tiene ventajas y desventajas. En la tabla 3 se presentan estas ventajas y desventajas.

Para la banca, el método estándar y considerado como la mejor práctica en la industria es el llamado “*Risk-Based-Pricing*”, que examina a detalle Thomas (2009). Esta metodología incluye el riesgo de crédito del cliente entre los componentes de la tasa costo. En los últimos años esta metodología se ha complementado al agregar el riesgo de *attrition*.

Tabla 3: Ventajas y desventajas de los métodos tradicionales de fijación de precios

Aproximación	Ventajas	Desventajas
Cost-plus	Podría considerarse una fijación prudente desde el punto de vista financiero (incluye todos los costos).	<ul style="list-style-type: none"> <li>▪ No considera al mercado, sólo toma la visión de costos.</li> <li>▪ No considera discriminación de precios. Es decir, no considera un foco de optimización de rentabilidad.</li> <li>▪ Desde que los costos no son forward-looking generan una distorsión en el pricing con resultados inesperados (pueden llevar a que el producto no sea competitivo en precios).</li> </ul>
Market based	<ul style="list-style-type: none"> <li>▪ Es fácil de realizar.</li> <li>▪ Se puede lograr participación de mercado fijando un precio por debajo del líder.</li> </ul>	<ul style="list-style-type: none"> <li>▪ No asegura que se genere valor.</li> <li>▪ Seguir a la competencia o al líder, si no se tiene economías de escala adecuada podría destruir valor.</li> <li>▪ No se hace discriminación de precios, por lo que no hay optimización.</li> </ul>
Value based	<ul style="list-style-type: none"> <li>▪ Método ideal para la fijación de precios.</li> </ul>	<ul style="list-style-type: none"> <li>▪ Muy complejo de aplicar.</li> </ul>

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

### 5.3. Maximización del margen de ganancia de un préstamo

La literatura de maximización del margen de ganancia está relacionada a lo que se conoce como maximización de los beneficios y es transversal en el princig de cualquier bien o servicio (Phillips, 2005).

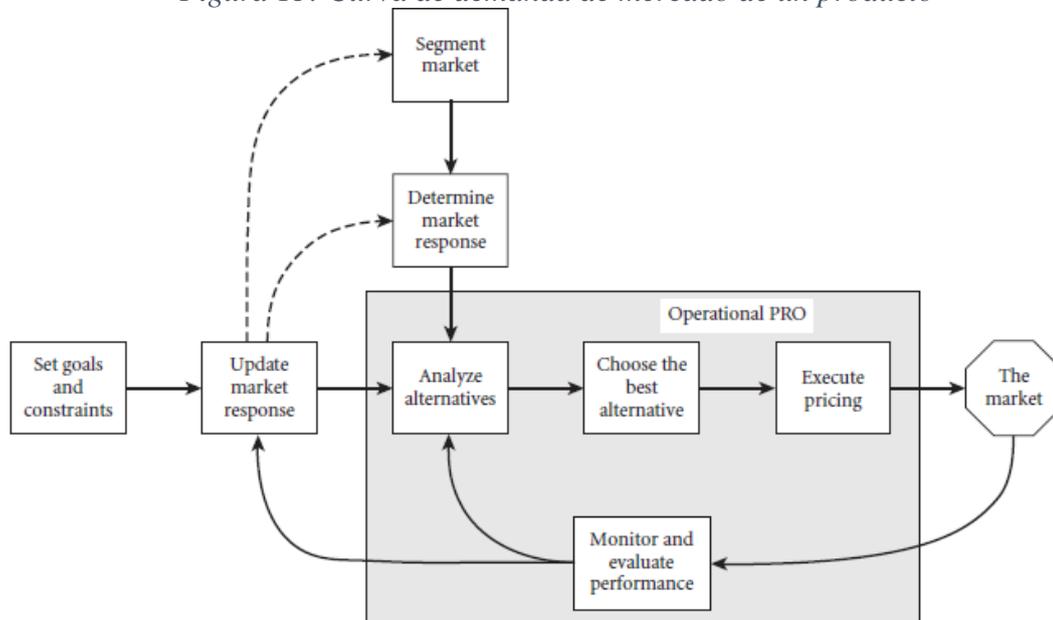
Phillips (2005) considera que el pricing debe incorporar los costos, la disposición a pagar del cliente (*willingness-to-pay*) y el ambiente competitivo. Adicionalmente, considera que las estrategias de precios deben ser diseñadas teniendo una visión completa de los precios desplegados en el mercado y la manera en que fueron fijados.

El objetivo de esta metodología es proveer los precios correctos considerando tres dimensiones del negocio: el precio correcto para cada producto, para los segmentos objetivos y de acuerdo a los canales que se despliegan. Además, estos precios deben

actualizarse de forma dinámica en respuesta a los cambios en las condiciones de mercado. Si bien este método descansa sobre profundos análisis matemáticos y análisis cuantitativos, para poder alcanzar una mejora sostenida en las estrategias de pricing éste debe de estar inmerso dentro de un proceso de fijación de precios adecuado. Si esto último se da, entonces el proceso hará que la fijación de precios sea dinámica. Phillips (2005) menciona que:

*“un exitoso pricing y optimización de ingresos involucra dos componentes: i) un consistente proceso de negocios focalizado sobre el pricing como un conjunto de decisiones críticas, y ii) las capacidades analíticas y de software requeridas para soportar el proceso”* (Phillips, 2005: 29). Este proceso es presentado en la figura 13.

Figura 13: Curva de demanda de mercado de un producto



Fuente: Phillips (2005).  
Elaboración: Autor de esta tesis.

La optimización es la piedra angular de este método, donde el pricing es considerado como un problema de optimización con restricciones. La solución involucra técnicas de estadística, investigación de operaciones y ciencia de gestión.

### 5.3.1. Problema de optimización

El objetivo del problema de optimización a resolver es maximizar el margen de contribución (ingresos totales menos el total de los costos incrementales). Es decir,

maximizar el margen de contribución de un préstamo adicional: total ingresos financieros menos sus costos variables. Los costos variables están compuestos por: el costo financiero, la pérdida esperada, la exigencia de capital regulatorio y los costos de eficiencia. En esta investigación el costo variable de un crédito es llamado tasa costo. Por lo tanto, el problema de maximización puede ser planteado de la siguiente manera:

$$\text{Max: Tasa Desembolso}_i - \text{Tasa costo} \quad (2)$$

$$\text{s. a.: Probabilidad(Acepte Tasa Desembolso}_i | \text{Competencia)}$$

Este problema de maximización es similar al problema de maximización de beneficios de una empresa que enfrenta una curva de demanda de mercado. Sin embargo, existen diferencias que deben de considerarse.

En este problema de optimización tiene especial relevancia la función precio-respuesta y los costos incrementales de las ventas. La función precio-respuesta es la demanda para el producto de un único vendedor como una función del precio de venta de este vendedor. Es decir, no es la curva de demanda de mercado. Por lo tanto, se interpreta que cada empresa que participa en el mercado tendrá su propia función precio-respuesta.

Los vendedores o empresas enfrentan diferentes curvas de precio-respuesta debido a diversos factores tales como: la efectividad de sus campañas de marketing, las diferencias que perciben los clientes sobre los productos en cuanto a su calidad, diferencias entre los productos ubicación geográfica, entre otros factores.

La función precio-respuesta que se considera en estos modelos es una con pendiente negativa con las siguientes propiedades: no negativas, continuas y diferenciables. Es decir, a medida que aumenta el precio la demanda disminuye hasta llegar a cero a un precio determinado. Además, esta función tiene una dimensión de temporalidad asociada. Esto implica que la fijación de precios no es perpetua, sino que cambiará o deberá actualizarse cada cierto tiempo, que podría ser horas, días, semanas, meses o un periodo de tiempo mayor. Por lo tanto, la cantidad demandada a un precio determinado dependerá del espacio de tiempo en que el precio estará vigente. Así, la función precio-

respuesta para un bien o servicio estará vigente durante una semana o más de un mes, pero sin un intervalo de tiempo asociado no existirá una función única de precio-respuesta.

### 5.3.2. La función respuesta al precio y el problema de optimización

El problema de maximización de las empresas se basa en la existencia de la curva de demanda de mercado y su elasticidad precio. La curva de demanda presenta la combinación de diferentes cantidades demandadas con diferentes niveles de precios. Por ejemplo, en la figura 14 el par ordenado  $(P_1, Q_1)$  dice que: para el precio  $P_1$  la cantidad demandada será de  $Q_1$ , si el precio sube a  $P_2$  la cantidad demandada disminuirá hasta  $Q_2$  y si el precio disminuye hasta  $P_3$  la cantidad demandada aumentará hasta  $Q_3$ .

Luego, en la parte inferior de la figura 13 se presentan los ingresos para todos los pares ordenados  $(P_i, Q_i)$  de la curva de demanda. Se observa que, el nivel máximo de los ingresos se logra para el nivel de precios  $P_1$ . Mientras que el nivel de ingresos es menor para el nivel de precios  $P_2$  y  $P_3$ , aunque es igual para estos dos niveles de precios.

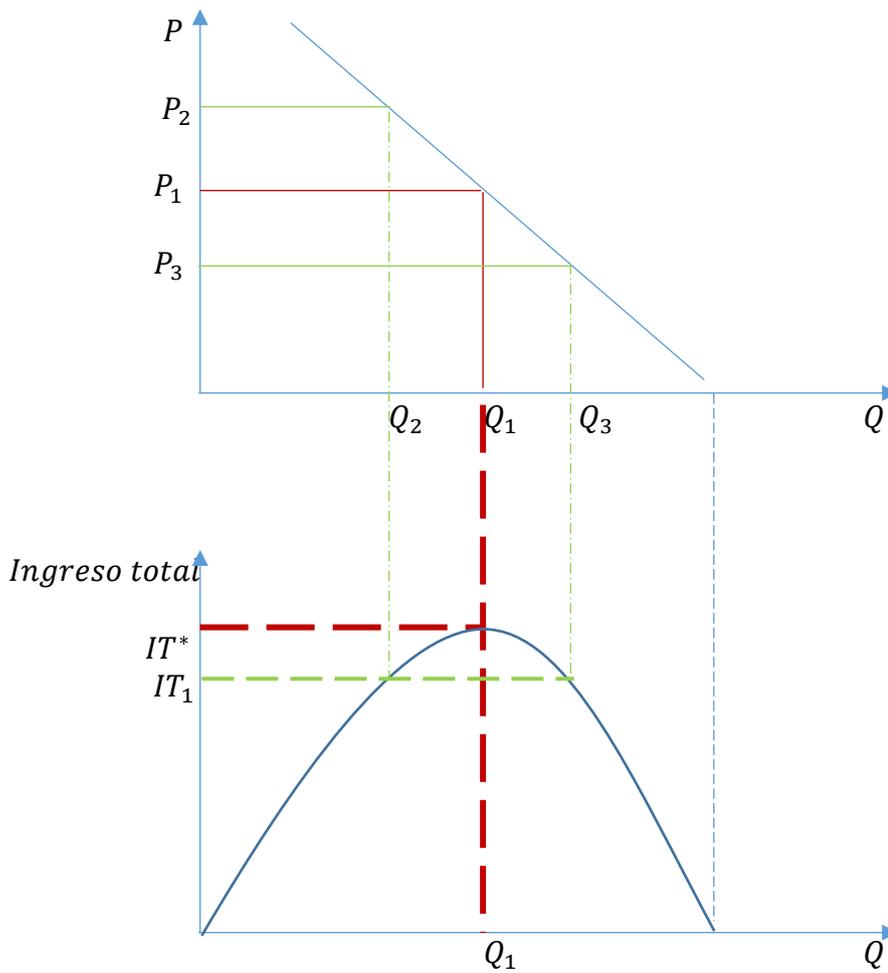
Es decir, la curva de ingresos es una función cóncava con un punto de maximización. Esta forma se da por la existencia de la elasticidad precio de la curva de demanda. En la parte donde la curva de demanda es inelástica los incrementos en los precios aumentan los ingresos totales, mientras en la zona donde la demanda es elástica los incrementos en los precios reducen los ingresos totales. Por lo tanto, el nivel máximo de ingresos se alcanza en el punto donde la curva de demanda tiene una elasticidad precio unitaria, en la figura es en el nivel de precios  $P_1$ .

La elasticidad precio de la demanda mide el cambio porcentual en la cantidad demandada ante un incremento en los precios, y es escrita de la siguiente manera:

$$\varepsilon_d = \left| \frac{\text{Variación porcentual de } Q_d}{\text{Variación porcentual de } P} \right| \quad (3)$$

Existen otras medidas de elasticidad, pero no se presenta su conceptualización al no ser tema de esta investigación. Sin embargo, en la tabla 4 se hace un resumen de los tipos de elasticidad. Para mayor detalle, ver Nicholson, (2008).

Figura 14: Curva de demanda de mercado de un producto y la función de ingresos



Fuente: Autor de esta tesis.  
 Elaboración: Autor de esta tesis.

Tabla 4: Tipos de elasticidad

Tipo	Formula
Elasticidad precio de la demanda	$\epsilon_d = \left  \frac{\text{Variación \% de } Q_d}{\text{Variación \% de } P} \right $
Elasticidad precio cruzada de la demanda	$\epsilon_{cd} = \left  \frac{\text{Variación \% de } Q_x}{\text{Variación \% de } P_y} \right $
Elasticidad ingreso de la demanda	$\epsilon_I = \left  \frac{\text{Variación \% de } Q_d}{\text{Variación \% de } I} \right $
Elasticidad precio de la oferta	$\epsilon_o = \left  \frac{\text{Variación \% de } Q_{oferta}}{\text{Variación \% de } P} \right $

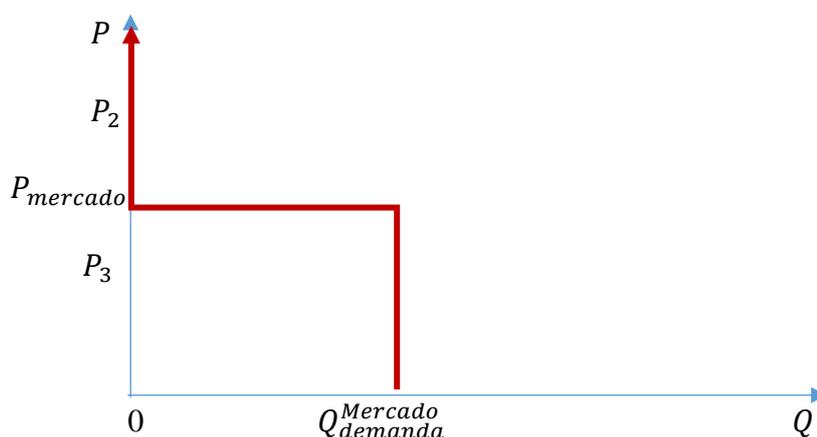
Fuente: Autor de esta tesis.  
 Elaboración: Autor de esta tesis.

La curva relevante para el problema de maximización de un banco es la función de respuesta al precio, la cual es similar a la curva de demanda de mercado mencionada

anteriormente. Sin embargo, hay una diferencia importante. La función de respuesta al precio representa la demanda de un préstamo de un banco en particular como una función de la tasa de interés que este pide. Por otro lado, la curva de demanda de mercado representa como el mercado total responde a los cambios en los precios. Tener en cuenta esta distinción es relevante, ya que existen muchos bancos compitiendo en el mercado de préstamos. Por lo tanto, cada banco tendrá su propia función de respuesta al precio de cada tipo de préstamo que ofertan. Es decir, la función de respuesta al precio para los préstamos de consumo del BBVA será diferente a la del BCP. La diferencia entre las funciones de respuesta al precio que encara cada banco es el resultado de muchos factores, tales como: acciones de marketing, propuesta de valor alrededor del préstamo, localización de oficinas, número de oficinas, entre otros.

Para lograr un mejor entendimiento de esta diferencia en la figura 15 se presenta la forma de la demanda de una empresa bajo competencia perfecta. La razón de esta forma es el supuesto que las empresas de manera individual no tienen influencia sobre el precio de mercado. Por lo tanto, si el precio de la empresa está por encima del precio de mercado la cantidad demandada será cero; si el precio está por debajo del precio de mercado la cantidad demandada será el total del mercado.

*Figura 15: Curva de demanda de una empresa bajo competencia perfecta*



Fuente: Autor de esta tesis.  
Elaboración: Autor de esta tesis.

En contraste, la función de respuesta al precio de esta misma empresa siempre tiene pendiente negativa.

La curva de demanda de la figura 15 sólo se cumple para bienes que son “commodities”. Sin embargo, la existencia de estos productos es rara y la mayoría de empresas enfrentan a una función de respuesta al precio negativa.

La función de respuesta al precio es similar a la curva de demanda de un monopolio examinada en la literatura microeconómica. Sin embargo, esto no significa que los bancos sean un monopolio.

Al igual que la curva de demanda del mercado la función de respuesta al precio tiene características que deben tenerse en cuenta. Estas características son:

- Tiene un espacio temporal de vigencia. Es decir, la relación entre las tasas de interés y la cantidad demandada de préstamos cambiará cada cierto tiempo. Este espacio temporal puede ser día, semanas, meses, etc. La vigencia dependerá de los cambios en las preferencias del consumidor y de las acciones de los bancos competidores. Por lo tanto, las estrategias diseñadas sobre la base de una función de respuesta al precio no son perpetuas.
- Tiene pendiente negativa.
- Es no negativa.
- Es continua.

La función respuesta al precio que enfrenta cada banco tiene las mismas propiedades que la elasticidad precio de la curva de mercado. Sin embargo, es importante explicar que la elasticidad precio dependerá del periodo de evaluación. Así, hay que distinguir entre la elasticidad precio en el corto plazo que la de largo plazo. En general, la elasticidad precio de largo plazo será mayor a la de corto plazo. Un cliente que trabaja con un único banco (le podrían pagar su salario en este banco) y que tiene una necesidad rápida de dinero podría tomar un crédito con su banco, aunque este haya incrementado la tasa de interés. Sin embargo, si considera que la tasa es muy alta empezará a trabajar con otros bancos en mediano y largo plazo. Por lo tanto, el banco podría pensar que la elasticidad precio es baja en las primeras semanas desde que se dio el aumento de tasas de interés, pero en el mediano largo plazo la elasticidad será mayor.

#### 5.4. La función respuesta al precio y la disposición a pagar del cliente

En el apartado anterior se conceptualizó el problema de optimización del margen en base a la función respuesta al precio y a su elasticidad precio. Ahora, se explicará cómo se construye la función de respuesta al precio para poder estimarla empíricamente.

Todas las personas que tienen una necesidad de financiamiento son potenciales clientes de un banco. Por ello, la curva de demanda de préstamos es el resultado de miles o millones de decisiones individuales de estos potenciales clientes. Cuando un potencial cliente observa la tasa de interés que le ofrece un banco en particular decidirá si acepta su oferta de préstamo o no. En caso no acepté el cliente evaluará si es que toma el préstamo con un banco competidor o puede decidir no tomar ninguno.

La curva de respuesta al precio muestra cuántos más de los potenciales clientes de aquel banco en particular aceptaran su oferta de préstamos si es que este disminuye su tasa de interés, y cuántos más no aceptarán su oferta de préstamos si es que decide aumentar su tasa de interés. Es decir, la curva de demanda de préstamos depende del comportamiento de los potenciales clientes. Por lo tanto, su estimación empírica dependerá de los supuestos que se realicen sobre este comportamiento.

Las características y estimaciones de las curvas de demanda se basan principalmente en el concepto de disposición a pagar (*willingness to pay*) (Phillips, 2005).

Por otro lado, el concepto de disposición a pagar asume que cada potencial cliente tiene una disposición a pagar máxima. En la literatura microeconómica este concepto es conocido como precio de reserva (*reservation price*). Por lo tanto, el cliente tomará un préstamo si la tasa de interés ofertada por el banco es menor o igual a la tasa de interés máxima que está dispuesto a pagar. En esta investigación el concepto de disposición a pagar será utilizado indistintamente que el concepto de disposición máxima a pagar.

Desde un punto de vista matemático-estadístico la distribución de la disposición a pagar de la población para cualquier valor de precios  $0 \leq p_1 < p_2$  puede ser escrita como sigue:

$$\int_{p_1}^{p_2} w(x) dx \quad (4)$$

Es decir, para todos los valores no negativos de  $x$  la distribución  $w(x)$  está entre cero y uno. Luego, si definimos la máxima demanda alcanzable como  $D = d(0)$  es posible derivar la función de respuesta al precio  $d(p)$  a partir de la función de distribución  $w(x)$ , de la siguiente manera:

$$d(p) = D \int_p^{\infty} w(x) dx \quad (5)$$

De la función de respuesta al precio es posible obtener su derivada:

$$d'(p) = -Dw(p) \quad (6)$$

Finalmente, es posible derivar la disposición a pagar del cliente si es que se estima la función de respuesta al precio según:

$$w(x) = -\frac{d'(x)}{d(0)} \quad (7)$$

Desde un punto aplicativo existen diversas funciones de respuesta al precio teniendo cada una de ellas sus respectivas propiedades. En la tabla 4 se muestran las más comunes que se utilizan en los trabajos empíricos. En esta investigación se utiliza la función de respuesta al precio logística, su definición matemática y sus características se presentan en la tabla 5.

Tabla 5: Funciones de demanda y sus propiedades

Funciones de demanda comunes						
	$d(p)$	$p(d)$	$r(d)$	$J(d)$	$\ \varepsilon(p)\ $	$p^0$
Lineal	$a - bp$	$\frac{1}{b}(a - d)$	$\frac{d}{b}(a - d)$	$\frac{1}{b}(a - 2d)$	$\frac{pb}{a - bp}$	$\frac{a}{2b}$
Log-lineal (exponencial)	$e^{a-bp}$	$\frac{1}{b}(a - \ln(d))$	$\frac{d}{b}(a - \ln(d))$	$\frac{1}{b}(a - 1 - \ln(d))$	$pb$	$\frac{1}{b}$
Elasticidad constante	$ap^{-b}$	$\left(\frac{a}{b}\right)^{1/b}$	$a^{1/b}d^{1-1/b}$	$\left(1 - \frac{1}{b}\right)\left(\frac{a}{d}\right)^{1/b}$	$b$	$\begin{cases} 0 & b > 1 \\ +\infty & b < 1 \\ \text{all } p \geq 0 & b = 1 \end{cases}$
Logit	$N \frac{e^{-bp}}{1 + e^{-bp}}$	$\frac{1}{b} \ln\left(\frac{N}{d} - 1\right)$	$\frac{d}{Nb} \ln\left(\frac{N}{d} - 1\right)$	$\frac{1}{b} \left( \ln\left(\frac{N}{d} - 1\right) - \frac{N}{d - N} \right)$	$\frac{e^{-bp}}{1 + e^{-bp}}$	Sin fórmula de forma cercana
Definiciones: $d(p)$ = función de demanda, $p(d)$ = función de demanda inversa, $r(d)$ = función de ingresos ( $r(d) = dp(d)$ ), $J(d)$ = ingreso marginal ( $J(d) = \partial r(d)/\partial(d)$ ), $\ \varepsilon(p)\ $ = elasticidad ( $\ \varepsilon(p)\  = \left\  \frac{p}{d} \frac{\partial p(d)}{\partial d} \right\ $ ), $p_0$ es el precio que maximiza los ingresos.						

Fuente: The Oxford Handbook of Pricing Management (2012), Chapter 18. Garrett J. Van Ryzin: Models of Demand.

Elaboración: Autor de esta tesis.

## CAPÍTULO VI : MODELOS ECONOMETRÍCOS Y DE INTELIGENCIA ARTIFICIAL PARA CONSTRUIR EL ALGORITMO DE OPTIMIZACIÓN

En la primera parte de este capítulo se revisa la literatura relacionada con los métodos de aprendizaje supervisado que se utiliza para segmentar los grupos homogéneos. Cabe mencionar que estas técnicas asumen una forma estructurada para una función de regresión desconocida, y con ello se reduce el problema de la dimensionalidad. De forma general, existen diversos métodos de aprendizaje supervisado entre los cuales están: los modelos aditivos generalizados, árboles, splines de regresión adaptativa multivariada, método de introducción de reglas y mezclas jerárquicas de expertos. En la segunda parte, se da una descripción del método econométrico logit. Este es utilizado para estimar la disposición a pagar del cliente.

### 6.1. Métodos de segmentación con árboles - machine learning

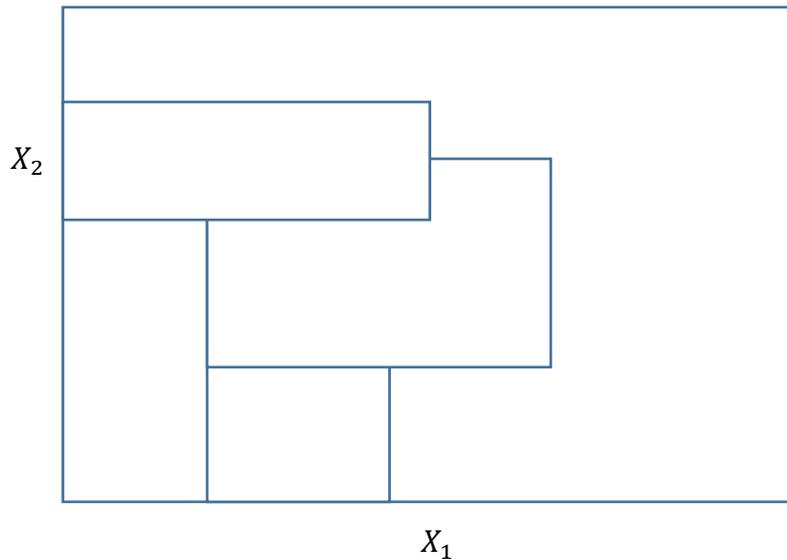
#### 6.1.1. Introducción a los métodos de árboles

Estos métodos han sido presentados en el libro de Hastie, Tibshirani y Friedman (2017).

Los métodos de árboles dividen el espacio de características en un conjunto de rectángulos y luego estiman un modelo simple (como una constante) en cada uno. Por ejemplo, si consideramos a  $Y$  como una variable continua dependiente y  $X_1$  y  $X_2$  como variables que representan características de la variable dependiente. Luego, es posible formar el espacio característico de estas dos variables explicativas. En la figura 16 se muestra una partición del espacio característico que forman estas dos variables.

Luego, en cada partición es posible establecer un modelo para  $Y$  con una constante diferente. Aunque esta idea es intuitiva resulta difícil de implementar debido a que esta forma de particionamiento deja zonas que pueden ser complicadas de describir. Por el contrario, si se realiza una partición como la mostrada en la figura 16 esta es más directa. En este caso, es más fácil desarrollar un modelo de regresión para cada rectángulo del espacio característico. Esta forma de partición es llamada partición recursiva binaria.

Figura 16: Partición y CART – Paso 1



Fuente: Hastie, Tibshirani y Friedman (2017).  
Elaboración: Autor de esta tesis.

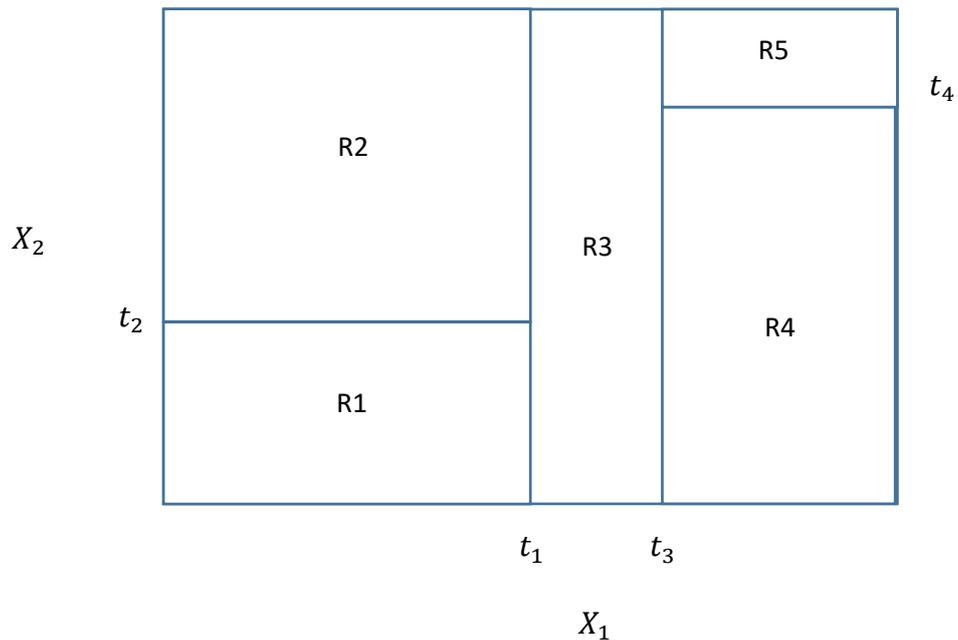
La partición recursiva binaria se realiza de la siguiente manera. Primero se parte el espacio característico en dos regiones y se estima un modelo para la media de  $Y$  en cada región. El procedimiento busca encontrar la variable y el punto de corte que permita que los modelos estimados tengan el mejor ajuste.

Luego, una o ambas regiones son divididas en dos regiones nuevamente y así el proceso continúa hasta que alguna regla de “stop” es aplicada. En la figura 16, el procedimiento aplicado fue:

- 1) Se dividió la variable  $X_1$  en el valor  $t_1$ . Así, se tiene dos regiones en esta variable.
- 2) La región para  $X_1 \leq t_1$  es dividida en el valor de  $X_2 = t_2$  y la región  $X_1 > t_1$  es dividida en  $X_1 = t_3$ .
- 3) La región  $X_1 > t_3$  es dividida en el valor de  $X_2 = t_4$ .

El resultado de este proceso de partición es dividir el espacio característico en cinco regiones: R1, R2, R3, R4 y R5, que se muestran en la figura 17.

Figura 17: Partición y CART – Paso 2



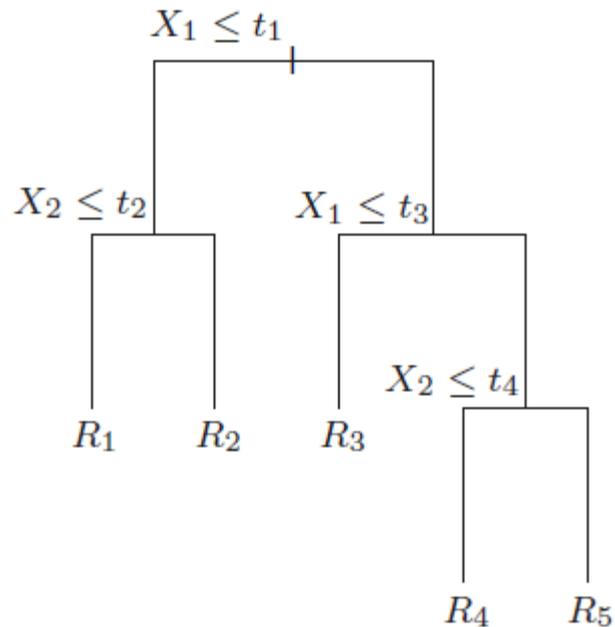
Fuente: Hastie, Tibshirani y Friedman (2017).  
Elaboración: Autor de esta tesis.

Como se mencionó anteriormente, para cada una de estas regiones se establece una regresión con una constante diferente. Esto puede ser escrito matemáticamente de la siguiente manera:

$$\hat{f}(X) = \sum_{m=1}^5 c_m I\{(X_1, X_2) \in R_m\} \quad (8)$$

Una forma de expresar este particionamiento es a través de un gráfico de nodos, de ahí el nombre de modelos de árboles. Una ventaja clave de este método es su facilidad en la interpretación. Para el ejemplo descrito el árbol de decisión se presenta en la figura 18.

Figura 18: Partición y CART – Paso 3



Fuente: Hastie, Tibshirani y Friedman (2017).

Elaboración: Autor de esta tesis.

### 6.1.2. Árboles de Clasificación (Classification trees)

Existen diferentes métodos de árboles de clasificación. Sin embargo, en términos generales estos se basan en el particionamiento recursivo de un conjunto de datos, lo que a su vez implica el particionamiento de las variables explicativas (*input variables*). El problema del particionamiento es resuelto usando un criterio estadístico que cuantifica la relación entre las variables explicativas y la variable dependiente (usualmente categórica).

Estos métodos buscan resolver el problema de encontrar segmentos homogéneos que a su vez tengan un comportamiento diferenciado respecto a la variable explicada. En esta investigación, esto implica encontrar grupos homogéneos de potenciales clientes que desean un préstamo, pero entre estos grupos homogéneos se tenga un comportamiento diferente respecto de su disposición a pagar.

Si bien existen diferentes métodos para establecer los árboles de clasificación, en esta investigación se utilizan dos: i) el método de clasificación y regresión de árboles

(*classification and regression tree*, CART), y ii) el método de árbol de inferencia condicional (*conditional inference tree*, CTREE).

Bibliografía en que se explican estos métodos incluyen: L. Breiman, J. Friedman, R. Olshen, C. Stone (1984); T. Hothorn, K. Hornik, A. Zeileis (2006); y W.-Y. Loh (2014). A continuación, se presenta un breve resumen de estos dos métodos.

### a) Método “Classification and regression tree” - CART

Para entender este método primero se realiza una explicación matemática del método *regression trees*. Para ello, considere el siguiente vector de datos de la variable resultado  $Y$  y la matriz de datos  $X$  conocida como espacio característico.

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad X = \begin{bmatrix} x_{11} & x_{12} & x_{13} & \cdots & x_{1p} \\ x_{21} & x_{22} & x_{23} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ x_{n1} & x_{n2} & x_{n3} & \cdots & x_{np} \end{bmatrix} \quad (9)$$

Seguidamente, el algoritmo debe permitir decidir sobre: i) variable de partición, ii) el valor de partición y iii) que forma debería tener el árbol. Para ello, usualmente se supone que el espacio de características es dividido en  $M$  regiones y en cada una de estas regiones se modela la variable  $Y$  en función de una constante  $c_m$ . Matemáticamente esto puede ser escrito como:

$$f(x) = \sum_{m=1}^M c_m I(x \in R_m) \quad (10)$$

Si se utiliza el método de mínimos cuadrados ordinarios para estimar la constante en cada rectángulo, su fórmula será:

$$\hat{c}_m = \text{ave}(y_i | x_i \in R_m) \quad (11)$$

Para estimar la mejor partición binaria se utiliza un algoritmo de gradiente. Comenzando con todos los datos, se considera una variable de división  $j$  y un punto de división  $s$ , y con estos se define el par de semiplanos.

$$R_1(j, s) = \{X|X_j \leq s\} \text{ y } R_2(j, s) = \{X|X_j > s\} \quad (12)$$

Luego, se busca la variable de división  $j$  y el punto de división  $s$  que resuelve el siguiente problema de minimización:

$$\min_{j,s} \left[ \min_{c_1} \sum_{x_i \in R_1(j,s)} (y_i - c_1)^2 + \min_{c_2} \sum_{x_i \in R_2(j,s)} (y_i - c_2)^2 \right] \quad (13)$$

En este proceso, para cualquier elección de  $j$  y  $s$  la minimización interna es resuelta por:

$$\hat{c}_1 = ave(y_i | x_i \in R_1(j, s)) \quad (14)$$

$$\hat{c}_2 = ave(y_i | x_i \in R_2(j, s)) \quad (15)$$

Para cualquier variable de división se procede a encontrar el punto de división  $s$ . Así, se obtiene el mejor par ordenado  $(j, s)$ . Con este par ordenado se procede a dividir la información en dos regiones. Luego, el proceso es repetido sobre cada una de las regiones resultantes.

La cuestión es ¿qué tanto debería crecer el árbol? Desde un punto de vista estadístico un árbol muy grande traería como consecuencia un sobre ajuste de los datos, mientras que con un árbol muy pequeño podría no ajustar de manera adecuada a la estructura de los datos (proceso generador de datos).

En consecuencia, definir el tamaño adecuado del árbol es un aspecto que vuelve complejo esta metodología. Lo que se recomienda es que el tamaño óptimo del árbol debería responder a los datos que se disponen. La estrategia para definir el tamaño del árbol es dejarlo crecer tan grande como sea posible  $T_0$ , deteniendo su crecimiento (dejar de dividir los datos y con ello dejar de crear más regiones) cuando se alcance un tamaño mínimo de nodos. Luego, este árbol es reducido utilizando el procedimiento *cost-complexity pruning*.

La reducción o poda del árbol sigue el siguiente procedimiento. Considere al sub-árbol  $T \subset T_0$ , el cual es cualquier árbol obtenido al podar el árbol  $T_0$ . Se indexa el nodo terminal con el subíndice  $m$ , con el nodo  $m$  representando la región  $R_m$ . Además, se define a  $|T|$  como el número de nodo terminal en  $T$ . Luego, se definen las siguientes ecuaciones matemáticas:

$$N_m = \# \{x_i \in R_m\} \quad (16)$$

$$\hat{c}_m = \frac{1}{N_m} \sum_{x_i \in R_m} y_i \quad (17)$$

$$Q_m(T) = \frac{1}{N_m} \sum_{x_i \in R_m} (y_i - \hat{c}_m)^2 \quad (18)$$

Con esto se define el criterio estadístico llamado “*cost complexity*”:

$$C_\alpha(T) = \sum_{m=1}^{|T|} N_m Q_m(T) + \alpha |T| \quad (19)$$

La idea general es encontrar, para cada  $\alpha$ , el sub-árbol  $T \subseteq T_0$  tal que minimice  $C_\alpha(T)$ . En este criterio el parámetro  $\alpha \geq 0$  gobierna el *trade-off* entre el tamaño del árbol y la bondad de ajuste de los datos. Es importante entender que, valores grandes  $\alpha$  resulta en un tamaño de árbol menor  $T_\alpha$ , y lo inverso para valores pequeños de  $\alpha$ . Obsérvese que, si  $\alpha = 0$  la solución es el árbol completo  $T_0$ .

## b) Método CTREE

Seguidamente se explica de forma general el método de árboles de clasificación. Este método responde al objetivo de clasificar el resultado tomando valores que va desde 1 hasta  $K$ . Para alcanzar este objetivo, el cambio en el algoritmo se da en el método de partición y el método de reducción del árbol.

El método de partición es cambiado por el que tiene la siguiente expresión matemática:

$$\hat{p}_{mk} = \frac{1}{N_m} \sum_{x_i \in R_m} I(y_i = k) \quad (20)$$

Esta expresión matemática indica que el nodo  $m$ , que representa a la región  $R_m$  con  $N_m$  observaciones, la expresión  $\hat{p}_{mk}$  representa la proporción de las observaciones de clase  $k$  en el nodo  $m$ .

## 6.2. Modelo de regresión logística

El modelo de regresión lineal con variable dependiente binaria es llamado modelo de probabilidad lineal. Aunque es simple de estimar, este modelo tiene dos desventajas importantes: i) las probabilidades ajustadas pueden ser menores que cero o mayores que uno, y ii) el efecto parcial de cualquier variable explicativa es constante. Estas limitaciones se superan si se usan modelos de respuesta binaria más sofisticados como son los modelos logit y probit.

Los modelos logit y probit son modelos de respuesta binaria cuyo objetivo principal es la probabilidad de respuesta, que puede ser especificada de la siguiente manera

$$P(y = 1|x) = P(y = 1|x_1, x_2, \dots, x_k), \quad (21)$$

En la ecuación 21  $x$  es un vector de variables explicativas. Por ejemplo, cuando  $y$  es un indicador de si el cliente paga o no paga un crédito, el vector  $x$  podría contener variables tales como su nivel de educación, la edad del cliente, su estado civil, su nivel de ingreso, el número de hijos, su nivel de deuda en el sistema financiero, entre otras.

### Especificaciones de modelos logit y probit

El modelo de probabilidad lineal supone que la probabilidad de respuesta es lineal con respecto a un conjunto de parámetros. Para evitar esta limitación es posible considerar un modelo de respuesta binaria de la forma:

$$P(y = 1|x) = G(\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k) = G(\beta_0 + x\beta) \quad (22)$$

En este modelo el símbolo  $G$  representa a una función con valores estrictamente entre cero y uno:  $0 < G(z) < 1$ , para todos los números reales  $z$ . Esta propiedad permite que las probabilidades de respuesta estimada sean estrictamente entre cero y uno. Es decir, el valor estimado de  $y$  sólo tomarán valores entre cero y uno. Con la finalidad de simplificar la exposición se considerará que  $x\beta = \beta_1x_1 + \dots + \beta_kx_k$ .

La cuestión es establecer que funciones no lineales pueden tomar la función  $G$  tal que las probabilidades estimadas estén entre cero y uno.

El modelo logit  $G$  es la función logística y su resultado está siempre entre cero y uno para todos los números reales  $z$ . Es decir,  $G$  es la función de distribución acumulada (fda) para una variable aleatoria logística estándar.

$$G(z) = \exp(z) / [1 + \exp(z)] = \Lambda(z) \quad (23)$$

Luego, en el caso del modelo probit,  $G$  es la función de distribución acumulada normal estándar, que se expresa como una integral, ver ecuación 24 Además,  $\phi(z)$  es la función de densidad normal estándar que corresponde

$$G(z) = \Phi(z) \equiv \int_{-\infty}^z \phi(v)dv, \quad (24)$$

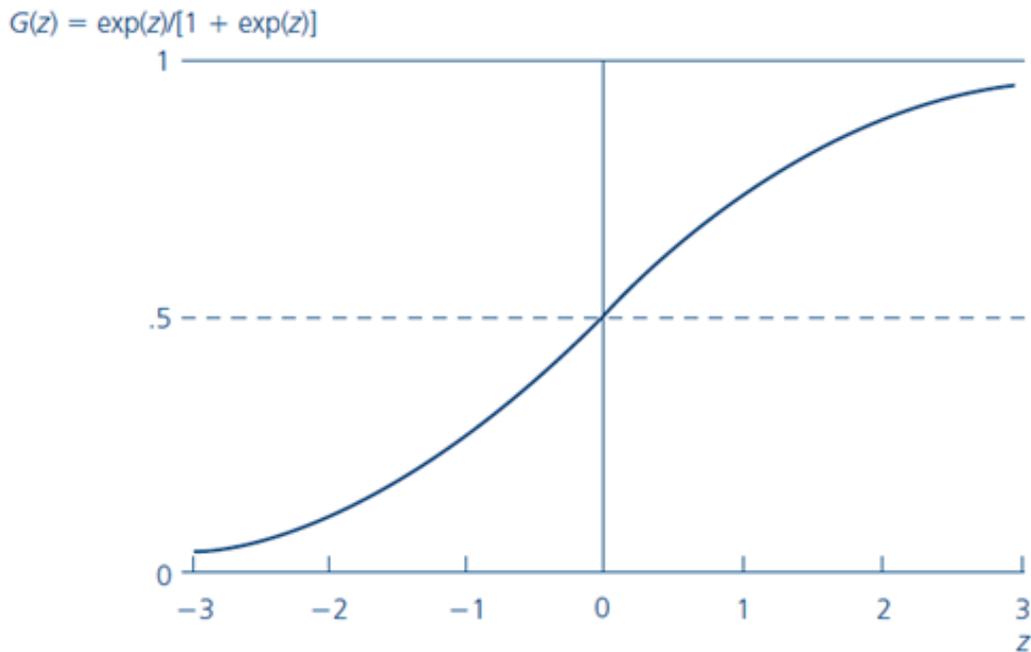
$$\phi(z) = (2\pi)^{-1/2} \exp(-z^2/2). \quad (25)$$

En el modelo probit  $G$  asegura que los valores estimados de  $y$  estén estrictamente entre cero y uno para todos los valores de los parámetros y las  $x_j$ .

Cabe mencionar que las funciones  $G$  para el caso de los modelos logit y probit son funciones crecientes. Cada una aumenta con más rapidez con respecto al punto donde  $z = 0$ . Se tiene que  $G(z) \rightarrow 0$  a medida que  $z \rightarrow -\infty$ , y  $G(z) \rightarrow 1$  a medida que  $z \rightarrow \infty$ .

La función logística está graficada en la figura 19. Es necesario anotar que la fda normal estándar tiene una forma muy similar a la de la fda logística.

Figura 19. Función logística



Fuente: Wooldridge (2009). Capítulo 17 - Pagina 576.

Elaboración: Autor de esta tesis.

La teoría estadística demuestra que los modelos logit y probit pueden ser derivados a partir de modelos de variable latente subyacentes. Asimismo, se considera  $y^*$ , una variable inobservable, o latente, que toma la siguiente forma

$$y^* = \beta_0 + x\beta + e, \quad y = 1[y^* > 0], \quad (26)$$

donde en la ecuación 26 se introduce la notación  $1[\cdot]$  para definir un resultado binario (función de indicador, valor de uno si el evento dentro de los corchetes es verdadero y cero si no lo es). Es decir, uno si  $y^* > 0$  y  $y$  es cero si  $y^* \leq 0$ . Un supuesto importante es que  $e$  es independiente de  $x$  y sigue una distribución logística estándar o la distribución normal estándar.

En cualquier caso,  $e$  se distribuye simétricamente en torno a cero, lo cual significa que  $1 - G(-z) = G(z)$  para todos los números reales  $z$ .

A partir de (26) y de los supuestos establecidos, se puede calcular la probabilidad de respuesta para la variable dependiente binaria  $y$ :

$$\begin{aligned} P(y = 1|x) &= P(y^* > 0|x) = P[e > -(\beta_0 + x\beta)|x] \\ &= 1 - G[-(\beta_0 + x\beta)] = G(\beta_0 + x\beta) \end{aligned} \quad (27)$$

lo cual es exactamente lo mismo que la ecuación (22).

En esta investigación como en la mayoría de las aplicaciones de estos modelos, el objetivo es explicar los efectos de las variables explicativas  $x_j$  sobre la probabilidad de respuesta  $P(y = 1|x)$ .

### **Estimación de máxima verosimilitud de los modelos logit y probit**

Ahora cabe la pregunta: ¿Cómo se deben estimar los modelos no lineales de respuesta binaria? Debido a la naturaleza no lineal de  $E(y|x)$ , los métodos de mínimos cuadrados ordinarios y mínimos cuadrados ponderados no son aplicables. Diversa literatura muestra que los métodos de máxima verosimilitud son los adecuados para realizar estas estimaciones. Desde un punto de vista estadístico, como la estimación de máxima verosimilitud toma como base la distribución de  $y$  dada  $x$ , la heterocedasticidad en  $Var(y|x)$  automáticamente se toma en cuenta.

## **PARTE 3**

### **APLICACIÓN DEL MODELO DE OPTIMIZACIÓN DEL MARGEN A CRÉDITOS DE CONSUMO**

*En esta parte se divide en 5 capítulos. En el capítulo 7 se presenta una estructura de modelo de pricing llamado PriceESAN®. Esta estructura es la que se incorpora el algoritmo de optimización del margen comercial de los préstamos de consumo. En el capítulo 8 se utilizan las técnicas de machine learning para estimar la función respuesta al precio. En el capítulo 9 se presentan los resultados de un piloto, en el cual se aplicó el algoritmo de optimización. Finalmente, en el capítulo 10 y 11 se dan las conclusiones y recomendaciones, respectivamente.*

## CAPÍTULO VII MODELO DE OPTIMIZACIÓN DEL MARGEN APLICADO A CRÉDITOS DE CONSUMO

Se presenta el modelo de fijación de precios para créditos de consumo llamado PriceESAN®. En este modelo se incorpora el algoritmo de optimización del margen comercial. Se presentan los componentes del pricing en una estructura de flujo de caja estocástico. Es una visión general y resumida de cómo se incorporaría el algoritmo de optimización.

### 7.1. Esquema del modelo de optimización PriceESAN®

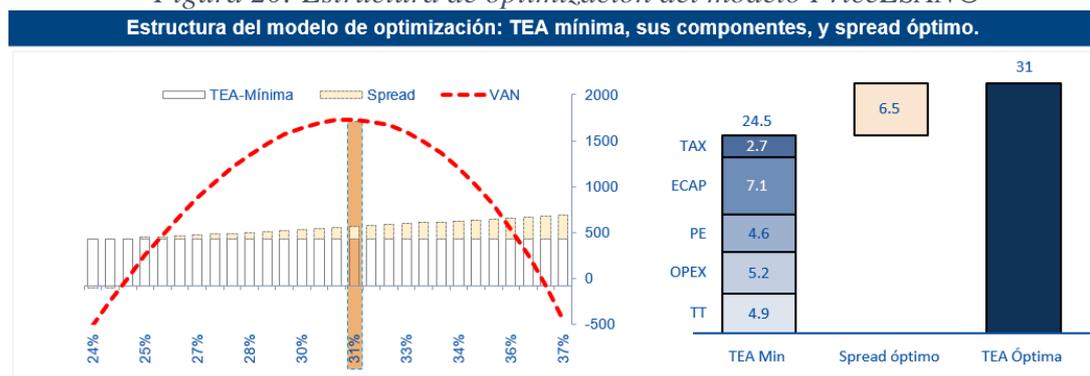
El modelo de optimización para créditos de consumo es llamado PriceESAN®. Aunque la lógica de optimización es sencilla de entender su construcción involucra grandes desafíos técnicos y metodológicos.

En una primera etapa y bajo la lógica de la metodología *risk-based-pricing* se estima la tasa mínima de equilibrio del préstamo. Es decir, la tasa que cubre todos los costos y asegura una rentabilidad exigida por el accionista. En la segunda etapa se utiliza el modelo de elasticidad para estimar el máximo spread comercial que se podría agregar a la tasa mínima. Obviamente, este spread máximo será condicionado a una probabilidad.

En la figura 20 se presenta una ilustración del proceso de optimización. Obsérvese que, en el ejemplo, la tasa mínima es de 24.5 por ciento. Esta tasa mínima está compuesta de 4.9 por ciento de costo de fondeo (TT), 5.2 de costos (OPEX), 4.6 de gastos por pérdida esperada neta de prepagos y cancelaciones (PE), 7.1 de capital (ECAP) y 2.7 de impuestos (TAX).

También se muestra que el spread máximo que se podría cobrar a este cliente, dada una probabilidad, es de 6.5 por ciento. Por lo tanto, la tasa que se le ofertará al cliente es de 31 por ciento.

Figura 20: Estructura de optimización del modelo PriceESAN®



Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

## 7.2. Visualización de la lógica de optimización y resultados del modelo PriceESAN®

El uso de grandes volúmenes de información es una característica distintiva del modelo de optimización. Esto permite que las tasas de interés sean a nivel de micro-segmentos; es decir, una aproximación a una fijación de tasas de interés *one-to-one*.

La información que utilizará el modelo se divide en tres grupos: i) la información de la operación de crédito, ii) información propia del cliente (datos demográficos, conductuales, psicográficos y financieros), iii) información del entorno macroeconómico, e iv) información financiera del banco (costos, tasas de descuento, comisiones, etc.). Un ejemplo de esta información se muestra en la figura 21.

Luego, con la información y métodos estadísticos se obtienen los inputs determinísticos y los inputs estocásticos del modelo. Entre los inputs estocásticos se tienen la curva de probabilidad de default, la curva de probabilidad de attrition, la curva de prepagos, la curva de loss given default, las curvas de roll rates y la de capital económico. En la tabla 6 se hace un listado de los inputs determinísticos y de los inputs estocásticos. Adicionalmente, en la figura 22 se da una representación gráfica de los inputs estocásticos que producirán los modelos econométricos.

Figura 21: Tipos de datos del modelo PriceESAN®

**es**an GRADUATE SCHOOL OF BUSINESS **PriceESAN® Loan PLD**

**DATOS DE SOLICITUD DEL PRÉSTAMO**

Datos de la operación

Alejandro La Torre

Importe: S/. 50,000 | Plazo: 28 | Región: Trujillo

Score: Bajo riesgo | Segmento: VIP | Canal: Plataform

Datos personales

Genero: M | Edad: 33 | Estado civil: Casado

N° Dependientes: 1 | Vivienda: Propia | Años de residencia: 5

Datos profesionales

Educación: Magister | Ocupación: Economista | Situación laboral: Estable

Años en la empresa: 7 | Cargo: Gerente | Sector económico: Telecom

Información Financiera

Ingresos: S/. 25,000 | Otros ingresos: S/0,0 | Total deuda SF: S/. 250,000

Hipotecario: S/. 225,000 | PLD: S/. 0,0 | Vehicular: S/. 0,0

Tarjetas: S/. 25,000 | CTS: S/. 200,000 | Ahorros: S/. 0,0

**INFORMACIÓN MACROECONÓMICA**

Variables macroeconómicas

**Producto Bruto Interno**

Año	2015	2016	2017	2018	2019
Valor	3.3	4	2.7	4.2	4.2

**Términos de Intercambio**

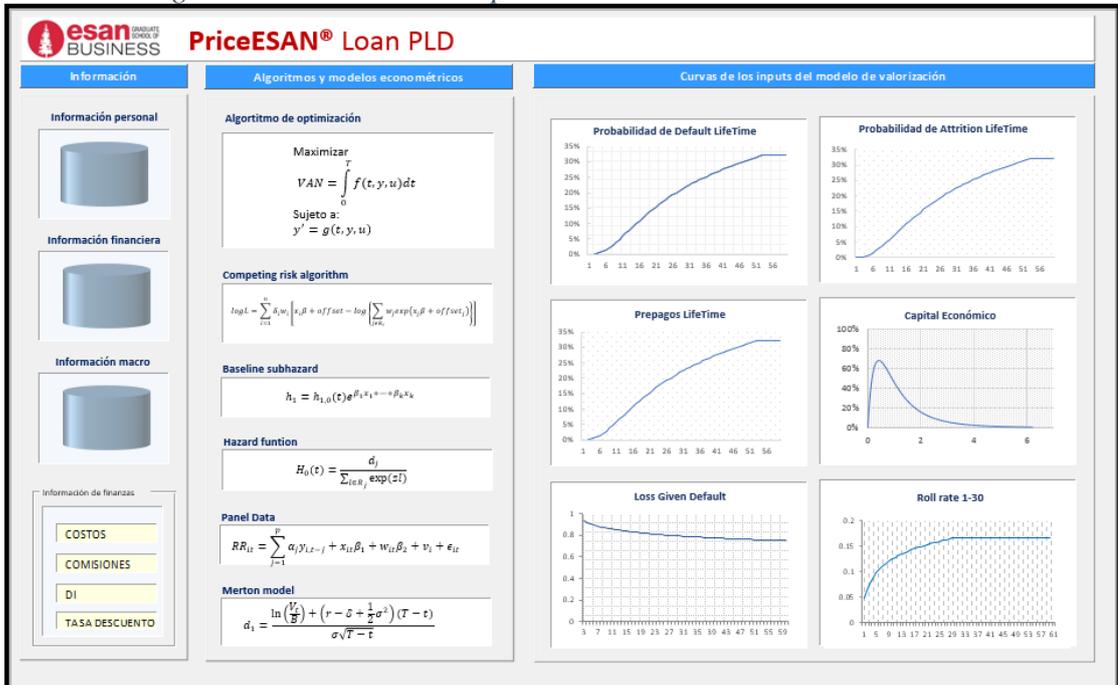
Año	2015	2016	2017	2018	2019
Valor	-6.4	-0.7	8.2	2.8	0.0

**Tipo de Cambio (Var%)**

Año	2015	2016	2017	2018	2019
Valor	2.9	1.1	2.2	4.4	4.3

Fuente: Autor de esta tesis.  
Elaboración: Autor de esta tesis.

Figura 22: Curvas de Comportamiento del Modelo PriceESAN®



Fuente: Autor de esta tesis.  
Elaboración: Autor de esta tesis.

Tabla 6: Inputs determinísticos y estocásticos del modelo PriceESAN®

Inputs determinísticos	Inputs Estocásticos
<ul style="list-style-type: none"> <li>▪ Curva de costos.</li> <li>▪ Tasa de descuento.</li> <li>▪ Costo de Oportunidad del accionista.</li> <li>▪ Curva de ingresos no financieros.</li> </ul>	<ul style="list-style-type: none"> <li>▪ Curva de probabilidad de default.</li> <li>▪ Curva de Attrition.</li> <li>▪ Curva de loss given default.</li> <li>▪ Curva de prepagos y cancelaciones.</li> <li>▪ Curva de roll rates.</li> <li>▪ Capital económico.</li> </ul>

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

La estimación de los inputs estocásticos constituye uno de los principales desafíos en el pricing de la banca. Algo relevante es la elección adecuada de las metodologías estadísticas o econométricas que se usaran penara la estimación de estos inputs.

Uno de los mayores errores que se cometen en el mundo analítico aplicado se da al elegir el método estadístico. Es usual que las personas encargadas de la estimación de los modelos usen aquellos que están dentro de su conocimiento y no realizan una investigación sobre el método más adecuado. Por ejemplo, para realizar una proyección de las colocaciones bancarias existen muchos métodos, tales como: modelos univariados de series de tiempo (ARMA), modelos multivariados de series de tiempo (Vectores Autorregresivos), modelos de regresión lineal múltiple, modelos con cambio de régimen, etc. En este ejemplo surge la pregunta ¿cuál de estos métodos debería usar el analista para proyectar las colocaciones bancarias? Se puede decir que el método a usar debe de estar alineado al objetivo de la necesidad de la proyección. Si se usará un modelo de series de tiempo univariado es posible realizar una proyección adecuada del crecimiento de las colocaciones, pero no podría contar una historia de porqué crecerían, o reducirían, las colocaciones. Sin embargo, si se usará un modelo de regresión línea múltiple o un modelo de Vectores Autorregresivos Estructural se podría proyectar las colocaciones en función de variables tales como el PBI, el desempleo, los términos de intercambio, entre otros y conocer que estaría impulsado el crecimiento de las colocaciones.

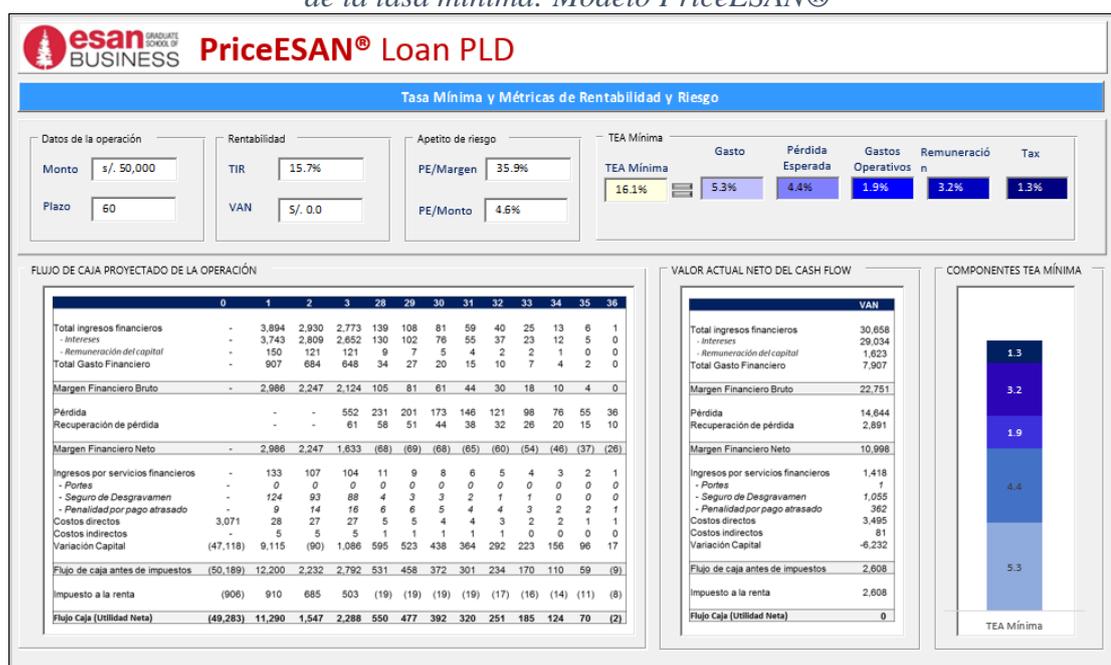
Luego, la interacción de los inputs estocásticos con los determinísticos bajo la metodología de customer lifetime value permite estimar un flujo de caja estocástico. Al descontar este flujo de caja se puede estimar la tasa mínima que se debe de cobrar por el crédito según la metodología risk-based-pricing. Es decir, se encontrará la tasa que

hace que el valor actual neto de este flujo de caja sea cero. Adicionalmente, es posible descomponer la tasa mínima en sus componentes de costos.

En la figura 23 se presenta una ilustración del flujo de caja estocástico y de los componentes de la tasa mínima. Adicionalmente, se presentan algunas métricas de rentabilidad y de exposición al riesgo de crédito de la operación que se está cotizando.

Finalmente, el modelo se completa con la maximización del margen de contribución del préstamo. Para poder realizar esta optimización es necesario construir un modelo de disposición a pagar del cliente o curva de demanda. El modelo de demanda permitirá estimar la tasa máxima que estará dispuesto a pagar el cliente dada una probabilidad. Es decir, dada una probabilidad se estimará el máximo spread comercial que se podría cobrar al cliente (figura 24).

Figura 23: Flujo Customer Lifetime Value, indicadores de rentabilidad y componentes de la tasa mínima: Modelo PriceESAN®



Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Figura 24: Modelo de Willingness-to-pay del Modelo PriceESAN®



**PriceESAN® Loan PLD**

---

DATOS DE SOLICITUD DEL PRÉSTAMO

**Datos generales del cliente**



Tipo Documento:

N° de Documento:

Nombre/Razón Social del Cliente:

**Datos personales**

Genero:  Edad:  Estado civil:

N° Dependientes:  Vivienda:  Años de residencia:

**Datos profesionales**

Educación:  Ocupación:  Situación laboral:

Años en la empresa:  Cargo:  Sector económico:

**Financiera**

Ingresos:  Otros ingresos:  Total deuda SF:

Hipotecario:  PLD:  Vehicular:

Tarjetas:  CTS:  Ahorros:

**Banca**

Score:

Segmento comerc.:

Estrategia:

MODELO DE ELASTICIDAD

**Modelos de WTP**

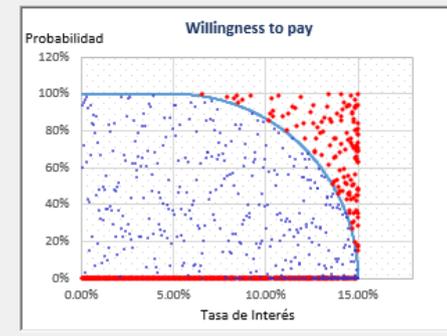
Logit demand:  $d(p) = N \frac{e^{-bp}}{1 + e^{-bp}}$

Additive uncertainty:  $\epsilon(p, \xi) = \frac{p}{D(p, \xi)} \frac{\partial D(p, \xi)}{\partial p} = \frac{\epsilon(p)}{1 + \xi/d(p)}$

Estimation methods:

$$l = \prod_{k=1}^N \left[ \frac{e^{\beta^T C_i(k)}}{\sum_{j \in S} e^{\beta^T Y_j} + 1} \right] \max_{\beta} \ln l$$

**Figura Willingness to pay**



Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

## CAPÍTULO VIII : ESTIMACIÓN DEL MODELO DE OPTIMIZACIÓN DEL MARGEN DE GANANCIA DE PRÉSTAMOS BANCARIOS

En el capítulo 5 se expuso la lógica del algoritmo de optimización del margen comercial de los préstamos bancarios. Este algoritmo se basa en el problema de optimización de los ingresos de la teoría del consumidor y de las firmas, que incorpora los conceptos de elasticidad precio y la disposición a pagar de los clientes. Luego en el capítulo 6 se expusieron los métodos de inteligencia artificial y el modelo econométrico logit que servirán para estimar la función de respuesta al precio de los potenciales clientes de préstamos.

En este capítulo se utiliza información de créditos de consumo de un banco de Perú para poner en práctica el algoritmo de maximización planteado en esta tesis.

### 8.1. Definición de los datos y fuente de información

Los datos fueron facilitados por una entidad bancaria que por temas de confidencialidad de la información se mantiene en reserva su nombre, de acá en adelante a esta institución se le llamará el “banco”.

La información es de 3 meses del año 2019 y es la siguiente:

- Información demográfica de los clientes que cotizaron un crédito de consumo: Edad, estado civil, número de hijos, nivel de educación, nivel de ingresos, genero.
- Información financiera de los clientes que cotizaron un crédito de consumo: nivel de deuda en el sistema financiero, nivel de pasivos en el sistema financiero, posición de activos y pasivos en el banco.
- Información de la solicitud del crédito que se cotizó: monto, plazo, tipo de moneda.
- Información de métricas de riesgo del cliente que cotizó el préstamo de consumo: score, calificación de riesgo según SBS.
- Se incluyó la variable de aceptación del crédito. Esta es una variable dummy con dos valores: 1 si después de cotizar y negociar aceptó el préstamos y 0 si después de cotizar no aceptó el préstamos.

## 8.2. Recolección de datos y su preparación

### 8.2.1. Análisis exploratorio de los datos

El banco cuenta con 7 tipos de préstamos de consumo. Las tasas para cada uno de estos préstamos se muestran en la tabla 7. Los montos mínimos, máximos y promedio del préstamo se muestran en la tabla 8.

*Tabla 7: Tasas mínimas, promedio y máximas por tipo de préstamo de consumo*

PRODUCTO	Tasa Mínima	Tasa Promedio	Tasa Máxima
Préstamo Tipo 1	10.5%	10.5%	10.5%
Préstamo Tipo 2	7.7%	11.0%	19.7%
Préstamo Tipo 3	9.0%	16.3%	34.5%
Préstamo Tipo 4	5.3%	19.0%	39.8%
Préstamo Tipo 5	10.0%	20.8%	37.5%
Préstamo Tipo 6	4.9%	22.8%	40.0%
Préstamo Tipo 7	6.5%	25.4%	36.5%
Promedio	7.3%	18.0%	31.2%

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

*Tabla 8: Montos de préstamos mínimos, promedio y máximo por tipo de préstamo*

PRODUCTO	Monto Mínimo Préstamo	Monto Préstamo Promedio	Monto de Préstamo Máximo
Préstamo Tipo 1	250,000	250,000	250,000
Préstamo Tipo 2	44,000	290,000	1,300,000
Préstamo Tipo 3	2,000	90,000	894,00
Préstamo Tipo 4	2,000	75,000	4,000,000
Préstamo Tipo 5	1,500	48,000	753,000
Préstamo Tipo 6	1,500	70,000	7,000,000
Préstamo Tipo 7	1,500	50,000	680,000
Promedio	43,000	124,000	2,330,000

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

En las tablas 9 y 10 se presentan los descriptivos de las tasas y montos por segmento comercial del banco. Este segmento va desde el mayor valor hasta el menor valor para el banco.

*Tabla 9: Tasas mínimas, promedio y máximas por tipo de segmento comercial*

SEGMENTO	Tasa Mínima	Tasa Promedio	Tasa Máxima
Segmento 1	4.9%	9.5%	19.5%
Segmento 2	5.3%	13.3%	33.9%
Segmento 3	6.7%	16.9%	35.5%
Segmento 4	6.0%	20.6%	40.0%
Segmento 5	10.0%	18.6%	30.0%
Promedio	7.6%	16.8%	30.6%

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Tabla 10: Montos de préstamos mínimos, promedio y máximo por segmento comercial

SEGMENTO	Monto Mínimo Préstamo	Monto Préstamo Promedio	Monto Máximo de Préstamo
Segmento 1	1,500	573,000	7,500,000
Segmento 2	1,500	125,000	2,600,000
Segmento 3	1,500	60,000	1,000,000
Segmento 4	1,500	75,000	986,000
Segmento 5	1,500	68,000	476,000
Promedio	1,500	138,000	1,700,00

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

### 8.2.2. Limpieza de los datos

El modelo de optimización sólo se aplicará para los créditos de consumo con la modalidad “nuevo crédito de consumo”. Es decir, no se está tomando los créditos de consumo de otra modalidad, por ejemplo, la modalidad “compra de deuda”.

De la modalidad “nuevo crédito de consumo” se recibieron un total de 63,457 cotizaciones, cada una de estas cotizaciones contenía la información que se mencionó anteriormente. Sin embargo, se encontró cotizaciones en las que no se tenía la información completa de alguna de las características deseadas. Por lo tanto, se procedió a eliminar estas observaciones. Por ejemplo 4,768 cotizaciones no tenían el dato de Buro (métrica de riesgo).

### 8.2.3. Resultado de la estimación del modelo de *Machine Learning*

La estimación y construcción del algoritmo se realizó en 4 etapas, estas son:

1. Etapa 1: Estimación de grupos homogéneos de acuerdo a si aceptó o no la oferta del préstamo condicionado a la tasa que se le ofreció. La variable a explicar es la aceptación o rechazo de la oferta del préstamo, el nombre de esta variable es “DESEMBOLSO” y es una variable *dummy*:

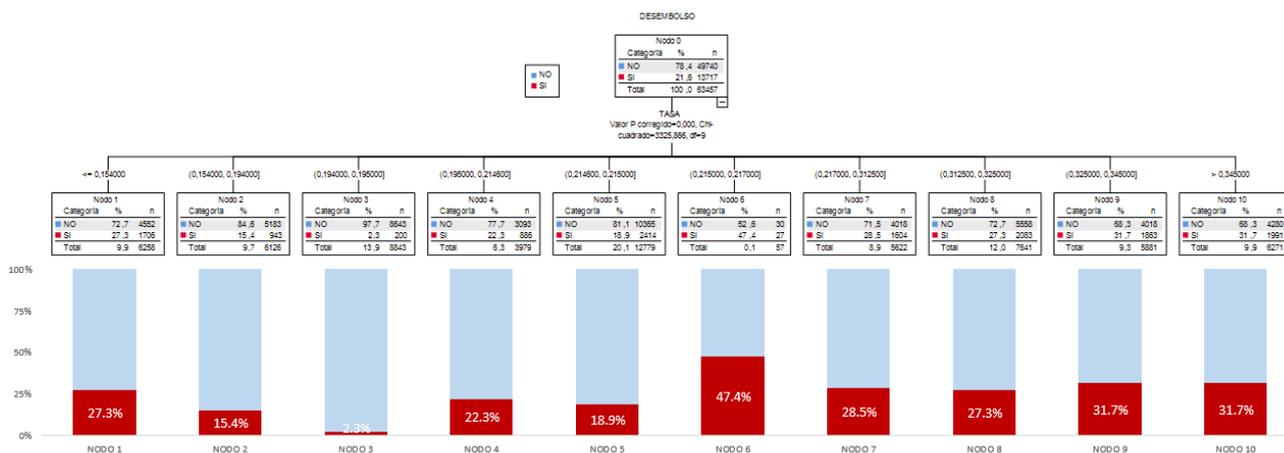
1 = “SI” aceptó la oferta del crédito

0 = “NO” aceptó la oferta del crédito.

La variable explicativa donde se determinan los grupos homogéneos es la tasa de interés (TASA) y es una variable continua.

Los resultados muestran la existencia de DIEZ grupos homogéneos. Para la definición de estos nodos se han tomado los valores de corte del árbol en sus ramas finales, ver figura 25.

Figura 25: Modelo CTREE de “DESEMBOLSO” vs “TASA”



Fuente: resultados de software SPSS.  
Elaboración: Autor de esta tesis.

Los resultados están conformes lo predice la ley de la demanda: los préstamos aceptados disminuyen cuando la tasa de interés ofertada se incrementa. Adicionalmente, sugieren la existencia de cuatro grupos:

- a. Grupo 1: está formado por la unión de los préstamos de los nodos NODO1, NODO2 y NODO3.
  - b. Grupo 2: está formado por la unión de los préstamos de los nodos NODO4 y NODO5.
  - c. Grupo 3: está formado por la unión de los préstamos de los nodos NODO6, NODO7 y NODO8.
  - d. Grupo 4. Está formado por la unión de los préstamos de los nodos NODO9 y NODO10.
2. Etapa 2: en esta se definen las variables de control de cada grupo definidos en la etapa 1. Desde que cada grupo tiene su propia función de respuesta al precio es necesario encontrar las variables que explican la demanda (llamadas variables de control) además de la tasa de interés



importe desembolsado. Para este grupo las variables de control elegidas, con el método *regression tree*, son: i) monto desembolsado, plazo del préstamo, el nivel de riesgo del cliente.

3. Etapa 3: se estima la función de respuesta al precio. Se utiliza un modelo de regresión logística. El signo del coeficiente de la tasa de interés es negativo, nuevamente reforzando la idea que se cumple la ley de la demanda (ver tabla 11). Por motivos de confidencialidad solicitada por el banco. No se presenta la regresión con las variables de control.

Tabla 11: Regresión logística para el grupo 1

		Variables en la ecuación					
		B	Error estándar	Wald	gl	Sig.	Exp(B)
Paso 1 <sup>a</sup>	TASA	-,241	,006	1394,499	1	,000	,786
	Constante	1,971	,100	386,962	1	,000	7,179

a. Variables especificadas en el paso 1: TASA.

Fuente: resultados de software SPSS.

Elaboración: Autor de esta tesis.

Tabla 12: Tabla de clasificación para el grupo 1

		Pronosticado			Porcentaje correcto
		ALTA			
Observado		NO	SI		
Paso 1	ALTA	18285	93	99,5	
	SI	2821	28	1,0	
Porcentaje global				86,3	

a. El valor de corte es ,500

Fuente: resultados de software SPSS.

Elaboración: Autor de esta tesis.

Tabla 13: Prueba de Hosmer y Lemeshow

Prueba de Hosmer y Lemeshow			
Paso	Chi-cuadrado	gl	Sig.
1	1106,392	5	,000

Fuente: resultados de software SPSS.

Elaboración: Autor de esta tesis.



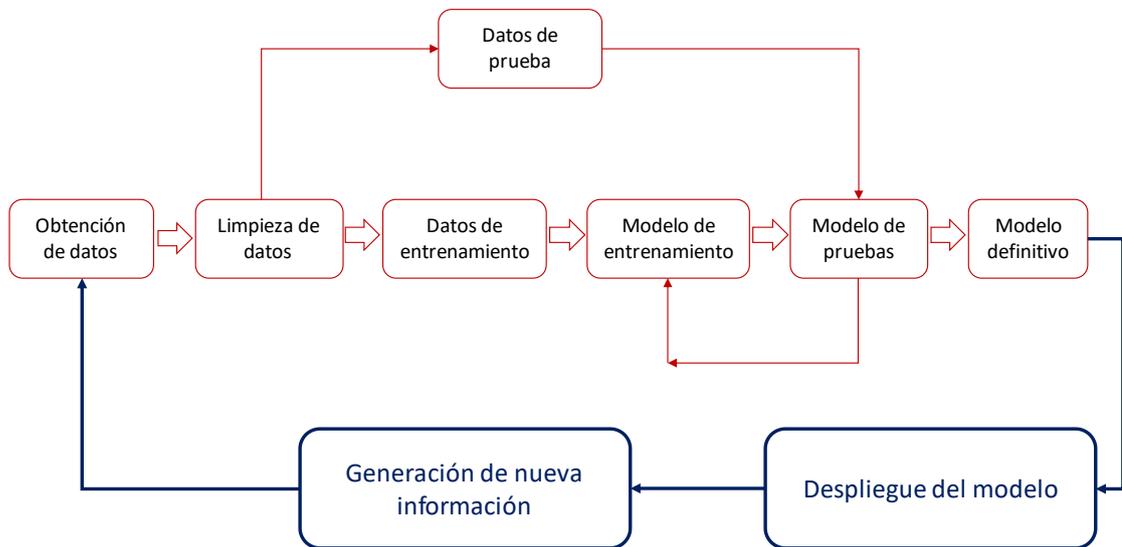
#### 8.2.4. Esquema de Machine Learning del algoritmo de optimización

En esta parte se explica el flujo del proceso de machine learning del algoritmo de maximización del margen financiero. El proceso tiene nueve actividades que forman un flujo circular. Es decir, el modelo se actualiza de forma continua de acuerdo al ingreso de nueva información. La puesta en marcha de este modelo y su actualización se puede hacer con el programa Python. Por lo tanto, se hace mención de las librerías y los comandos que generalmente pueden ser utilizados. El flujo se presenta en la figura 28.

1. Obtención de los datos. - la información procede de las tablas de operaciones del modelo de datos (data warehouse) de la entidad financiera. Se recibió un archivo en formato txt.
2. Limpieza de datos. - en la limpieza de datos se han tomado los siguientes criterios:
  - a. Descartar las observaciones con valores null en una o más variables de las características del cliente o de la operación.
  - b. Eliminar valores extremos. Se eliminó el 2% de valores extremos.
3. Datos de entrenamiento. - se utilizó el 70 por ciento de los datos para el entrenamiento del modelo. Esta elección se hizo de manera aleatoria utilizando la librería “sklearn” y su comando “train\_test\_split”.
4. Modelo de entrenamiento. - este corresponde al modelo logit presentado en la ecuación xx. Cabe mencionar que, se generaron alrededor de 10 modelos de pruebas.
5. Modelos de pruebas y uso de datos de prueba. En esta etapa se ponen a competir los 10 modelos de prueba utilizando los datos de prueba. Para elegir el modelo ganador se compararon las curvas ROC de cada uno de los modelos. El modelo ganador pasó a ser el modelo definitivo.
6. Modelo definitivo. - el modelo definitivo pasa a operar en el proceso de captación de clientes con el objetivo de maximizar el margen.
7. Despliegue del modelo. - el despliegue del modelo se realiza en la plataforma que disponga la entidad financiera.
8. Generación de nueva información. - El despliegue del modelo significa que está siendo utilizado para otorgar operaciones de crédito lo cual genera nueva

información que complementa la información inicial y empieza el flujo de actualización del modelo.

Figura 28: Esquema de Machine Learning del flujo de estimación de los modelos de optimización



Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Para modelos de demanda de créditos se recomienda re-estimar el modelo con una frecuencia mensual. Para otros tipos de bienes o servicios la frecuencia de actualización puede ser diferente. La actualización con frecuencia mensual es opinión del autor de la presente investigación.

El modelo de optimización puede ser estimado e implementado utilizando el programa Python. Este programa puede ser utilizado a través de la plataforma “Anaconda” y su notebook “Jupyter”. Las librerías que se utilizan para este modelo son las siguientes:

- Numpy
- Pandas
- Matplotlib
- Seaborn
- Plotly
- Scikit-learn.

## CAPÍTULO IX PILOTO DEL ALGORITMO DE MAXIMIZACIÓN DEL MARGEN DE COMERCIAL

En esta parte se presenta el despliegue y los resultados de una prueba piloto del algoritmo de optimización; pero como se explicará más adelante su aplicación es parcial. **La aplicación es para las ofertas de crédito de consumo de un banco del sistema bancario peruano.** Por ser información confidencial en los datos del piloto se colocan etiquetas y nombres genéricos.

Como se explicó en el marco teórico la variación de la tasa de interés puede incrementar o disminuir el margen comercial. Esto dependerá del tramo en que se encuentre el precio de partida en la función de reacción al precio. Claramente, un impacto negativo reducirá inmediatamente la cuenta de resultados del banco y tendrá un impacto político negativo para el decisor de la aprobación de este piloto.

Desde un punto de vista operativo el piloto puede realizarse en las ofertas proactivas o reactivas del banco. La oferta reactiva es cuando un cliente se acerca a una oficina a solicitar un préstamo y el banco le da las condiciones del préstamo. De otro lado, las proactivas son cuando el banco busca a clientes potenciales y les ofrece un préstamo de consumo bajo ciertas condiciones. Las búsquedas de clientes potenciales son realizadas a través de oficinas, fuerza de venta presencial, fuerza de venta por teléfono, a través de emails.

En el banco en un mes cualquiera los préstamos colocados a través de ofertas proactivas representan el 40 por ciento de las colocaciones y 15 por ciento corresponde a la fuerza de ventas. Por lo tanto, si el piloto es aplicado a todas las ofertas proactivas su impacto será relevante tanto en las colocaciones como en el margen comercial. Pero, como se mencionó anteriormente el impacto podría ser negativo.

Por lo tanto, con el objetivo de reducir las posibles pérdidas, en caso el piloto tenga un efecto negativo, se decidió aplicarlo sólo en las ofertas proactivas de la fuerza de venta. Claramente, si los resultados del piloto fueran positivos en los meses siguientes se ampliaría al resto de canales de venta.

## 9.1. Situación inicial de las ofertas proactivas sin aplicación del algoritmo

Se describe el total de la base de ofertas proactivas, luego se mencionará que parte de esta base será destinada al piloto. Estas ofertas son llamadas leads, término que se utilizará de acá en adelante para referirnos a las ofertas proactivas.

Para el mes de julio hay alrededor de 900 mil leads que equivalen a una oferta de 15 mil millones, estos están destinados para ofrecer compra de deuda o un préstamo de consumo nuevo. Las características de los leads son las siguientes.

- El 7 por ciento de leads son destinados a compra de deuda, que en millones corresponde al 9 por ciento del monto total.
- Las ofertas están divididas en 5 segmentos comerciales. El segmento de mayor valor es el segmento 1, luego sigue el segmento 2 y así hasta llegar al segmento 5 de menor valor. El 58 por ciento de leads son del segmento 4, que representan el 55 por ciento de oferta en millones.
- Cada cliente del segmento 1 tiene una oferta promedio de S/. 85 mil soles, mientras que los clientes potenciales del segmento 4 tienen una oferta promedio de S/. 15 mil soles. La tasa de interés promedio para el segmento de mayor valor es de 13 por ciento, y para el segmento cuatro es de 24 por ciento.
- El plazo promedio de las ofertas es de 48 meses.

La distribución de leads en cada segmento en número y millones de nuevos soles para el mes de julio de 2019 se presentan en la tabla 14.

*Tabla 14: Distribución de leads por segmento comercial*

	LEADs_N°	LEADs Millones PEN	Monto Promedio Ofertado en PEN	Tasa Promedio de la oferta
SEGMENTO1	0.1%	0.4%	85,000	13%
SEGMENTO2	1.5%	7.1%	80,000	14%
SEGMENTO3	5.6%	15.4%	45,000	19%
SEGMENTO4	58.7%	54.8%	15,000	24%
SEGMENTO5	34.2%	22.3%	10,000	26%
TOTAL	100%	100%	16,000	23%

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Para tener un punto de comparación se toma como referencia los resultados de la campaña del mes de junio del 2019. Los resultados de esta campaña muestran una efectividad promedio de 0.6% en montos y tasas diferentes a las del punto de partida de la campaña. Cuantificado en términos de margen financiero se generó 12.88 millones de soles (ver tabla 15).

*Tabla 15: Resultados de la campaña del mes de junio*

	LEADs_N°	LEADs Millones PEN	Efectividad de la campaña	Tasa de desembolso	Margen Real Millones PEN
SEGMETO1	0.1%	0.01%	2%	11.3%	0.14
SEGMETO2	1.5%	0.1%	2%	11.3%	2.29
SEGMETO3	5.5%	0.3%	1%	14.4%	2.92
SEGMETO4	90.7%	1.2%	0.3%	20.6%	7.02
SEGMETO5	2.2%	0.023%	1.3%	20.5%	0.5
<b>TOTAL</b>	<b>100%</b>	<b>100%</b>	<b>0.6%</b>	<b>17.57%</b>	<b>12.88</b>

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

## 9.2. Impacto esperado de utilizar el algoritmo de optimización

La aplicación del algoritmo de optimización se realiza para la campaña del mes de julio de 2019, aún vigente al cierre de esta investigación. Por lo que se presentaran resultados obtenidos al 24 de julio. Desde que el piloto es real e implica un impacto monetario sobre la cuenta de resultados del banco se decidió realizar una aplicación parcial del algoritmo y sólo en una parte de los leads. A continuación, se describe la forma de implementación.

De manera general se espera que la nueva propuesta de tasas generé un incremento en la facturación por S/. 30 millones y un margen financiero adicional de S/. 4.9 millones. Estos resultados esperados se presentan en la tabla 16.

Tabla 16: Resultados esperados de la campaña del mes de julio con algoritmo parcial

	LEADs Millones PEN	Efectividad actual campaña	Efectividad con algoritmo	Ganancia adicional en saldo Millones PEN	Ganancia adicional en margen Millones PEN
SEGMETO1	0.5%	2%	2.0%	0.12	0.008
SEGMETO2	7.7%	2%	2.2%	2.017	0.135
SEGMETO3	15.7%	1%	1.3%	6.161	0.746
SEGMETO4	74.7%	0.3%	0.57%	21.445	3.771
SEGMETO5	1.4%	1.3%	1.51%	0.370	0.260
<b>TOTAL</b>	<b>100%</b>	<b>0.6%</b>	<b>0.83%</b>	<b>30.113</b>	<b>4.920</b>

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

### 9.3. Estrategia de implementación del algoritmo de optimización

En el diseño de la estrategia se utilizó tres conductores claves: el segmento, el rango de oferta del préstamo y el nivel de riesgo. A continuación, se presentan los resultados de la aplicación del algoritmo de acuerdo a estos conductores de estrategia.

Tabla 17: Estrategia de optimización de margen para el segmento 1

	N° Leads	Leads Monto Millones PEN	Promedio de oferta	TEA OFERTADA SIN ALGORITMO	TEA OFERTADA CON ALGORITMO
<b>SEGMENTO1</b>	<b>711</b>	<b>59,818,000</b>	<b>84,132</b>	<b>13.21%</b>	<b>12.29%</b>
<b>RANGO 4</b>	<b>513</b>	<b>53,728,400</b>	<b>104,734</b>	<b>12.69%</b>	<b>12.09%</b>
RIESGO1	76	8,406,300	110,609	12.34%	10.75%
RIESGO2	143	15,212,200	106,379	12.44%	11.33%
RIESGO3	193	20,244,100	104,892	12.60%	12.31%
RIESGO4	69	7,145,800	103,562	13.19%	13.68%
RIESGO5	19	1,775,600	93,453	14.04%	14.20%
SIN RIESGO	13	944,400	72,646	15.23%	15.55%
<b>RANGO 3</b>	<b>136</b>	<b>5,009,500</b>	<b>36,835</b>	<b>17.74%</b>	<b>13.41%</b>
RIESGO1	22	815,900	37,086	16.82%	11.59%
RIESGO2	35	1,329,400	37,983	17.16%	12.32%
RIESGO3	40	1,471,000	36,775	17.41%	13.09%
RIESGO4	19	717,600	37,768	17.98%	14.34%
RIESGO5	3	92,700	30,900	18.70%	15.33%
SIN RIESGO	17	582,900	34,288	20.77%	17.81%
<b>RANGO 2</b>	<b>43</b>	<b>840,000</b>	<b>19,535</b>	<b>18.53%</b>	<b>15.92%</b>
RIESGO1	2	44,600	22,300	16.46%	12.26%
RIESGO2	3	54,500	18,167	16.59%	12.47%
RIESGO3	14	294,300	21,021	16.72%	13.07%
RIESGO4	5	88,000	17,600	18.03%	16.08%
SIN RIESGO	19	358,600	18,874	20.67%	19.19%
<b>RANGO 1</b>	<b>19</b>	<b>240,100</b>	<b>12,637</b>	<b>17.84%</b>	<b>20.51%</b>
RIESGO1	2	26,800	13,400	16.46%	16.18%
RIESGO2	2	22,600	11,300	17.53%	19.43%
RIESGO3	7	91,000	13,000	17.56%	20.10%
RIESGO4	5	63,300	12,660	18.47%	22.21%
RIESGO5	2	25,300	12,650	18.51%	22.51%
SIN RIESGO	1	11,100	11,100	19.00%	22.33%

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Tabla 18: Estrategia de optimización de margen para el segmento 2

	N° Leads	Leads Monto Millones PEN	Promedio de oferta	TEA OFERTADA SIN ALGORITMO	TEA OFERTADA CON ALGORITMO
<b>SEGMENTO2</b>	<b>12,381</b>	<b>1,008,336,000</b>	<b>81,442</b>	<b>14.38%</b>	<b>12.31%</b>
<b>RANGO 4</b>	<b>8,418</b>	<b>892,318,100</b>	<b>106,001</b>	<b>14.07%</b>	<b>11.99%</b>
RIESGO1	2,331	259,856,700	111,479	14.04%	10.83%
RIESGO2	2,162	230,978,300	106,835	14.04%	11.41%
RIESGO3	2,258	239,535,400	106,083	14.06%	12.42%
RIESGO4	1,103	115,473,000	104,690	14.05%	13.64%
RIESGO5	267	26,956,300	100,960	14.09%	14.39%
SIN RIESGO	297	19,518,400	65,719	15.04%	15.82%
<b>RANGO 3</b>	<b>2,434</b>	<b>90,212,300</b>	<b>37,063</b>	<b>16.67%</b>	<b>14.18%</b>
RIESGO1	440	16,549,600	37,613	16.48%	12.04%
RIESGO2	468	17,484,500	37,360	16.57%	12.62%
RIESGO3	572	21,129,200	36,939	16.67%	13.54%
RIESGO4	370	13,752,400	37,169	16.52%	14.83%
RIESGO5	62	2,250,900	36,305	16.52%	15.46%
SIN RIESGO	522	19,045,700	36,486	17.08%	17.56%
<b>RANGO 2</b>	<b>988</b>	<b>19,728,400</b>	<b>19,968</b>	<b>16.95%</b>	<b>15.64%</b>
RIESGO1	168	3,414,600	20,325	16.54%	12.74%
RIESGO2	194	3,837,100	19,779	16.80%	13.44%
RIESGO3	214	4,234,500	19,787	16.94%	14.62%
RIESGO4	139	2,755,600	19,824	16.71%	15.62%
RIESGO5	27	545,400	20,200	17.02%	17.63%
SIN RIESGO	246	4,941,200	20,086	17.49%	20.04%
<b>RANGO 1</b>	<b>541</b>	<b>6,077,200</b>	<b>11,233</b>	<b>17.39%</b>	<b>20.19%</b>
RIESGO1	107	1,126,000	10,523	17.29%	17.19%
RIESGO2	119	1,292,200	10,859	17.38%	18.08%
RIESGO3	146	1,721,900	11,794	17.18%	19.65%
RIESGO4	84	941,800	11,212	17.54%	21.17%
RIESGO5	22	235,600	10,709	17.55%	24.80%
SIN RIESGO	63	759,700	12,059	17.82%	26.79%

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Tabla 19: Estrategia de optimización de margen para el segmento 3

	N° Leads	Leads Monto Millones PEN	Promedio de oferta	TEA OFERTADA SIN ALGORITMO	TEA OFERTADA CON ALGORITMO
<b>SEGMENTO3</b>	<b>44,628</b>	<b>2,053,615,500</b>	<b>46,016</b>	<b>19.23%</b>	<b>15.60%</b>
<b>RANGO 4</b>	<b>15,706</b>	<b>1,424,665,200</b>	<b>90,708</b>	<b>18.85%</b>	<b>14.16%</b>
RIESGO1	3,130	290,268,300	92,737	18.89%	12.55%
RIESGO2	3,795	345,459,400	91,030	18.87%	13.23%
RIESGO3	4,979	464,434,100	93,279	18.83%	14.31%
RIESGO4	2,673	239,099,700	89,450	18.82%	15.71%
RIESGO5	618	55,262,900	89,422	18.85%	17.46%
SIN RIESGO	511	30,140,800	58,984	19.00%	19.46%
<b>RANGO 3</b>	<b>10,881</b>	<b>386,553,400</b>	<b>35,526</b>	<b>19.00%</b>	<b>17.35%</b>
RIESGO1	1,323	47,303,200	35,754	19.00%	14.63%
RIESGO2	2,014	71,212,800	35,359	19.00%	15.45%
RIESGO3	3,340	114,711,300	34,345	19.00%	16.62%
RIESGO4	1,791	62,297,600	34,784	19.00%	18.09%
RIESGO5	434	14,740,500	33,964	19.00%	18.66%
SIN RIESGO	1,979	76,288,000	38,549	19.01%	21.04%
<b>RANGO 2</b>	<b>7,702</b>	<b>151,028,200</b>	<b>19,609</b>	<b>20.00%</b>	<b>18.64%</b>
RIESGO1	887	17,455,100	19,679	20.00%	15.51%
RIESGO2	1,294	25,386,600	19,619	20.00%	16.45%
RIESGO3	2,471	48,932,600	19,803	20.00%	17.81%
RIESGO4	1,581	31,140,300	19,697	20.00%	19.24%
RIESGO5	342	6,736,400	19,697	20.00%	20.95%
SIN RIESGO	1,127	21,377,200	18,968	20.02%	24.08%
<b>RANGO 1</b>	<b>10,339</b>	<b>91,368,700</b>	<b>8,837</b>	<b>24.73%</b>	<b>25.79%</b>
RIESGO1	1,120	9,373,800	8,369	25.02%	20.71%
RIESGO2	1,886	15,741,400	8,346	25.11%	21.68%
RIESGO3	3,261	27,561,700	8,452	25.00%	23.83%
RIESGO4	1,800	15,314,000	8,508	25.08%	25.60%
RIESGO5	363	3,169,600	8,732	24.73%	29.56%
SIN RIESGO	1,909	20,208,200	10,586	23.69%	33.56%

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Tabla 20: Estrategia de optimización de margen para el segmento 4

	N° Leads	Leads Monto Millones PEN	Promedio de oferta	TEA OFERTADA SIN ALGORITMO	TEA OFERTADA CON ALGORITMO
<b>SEGMENTO 4</b>	<b>740,198</b>	<b>9,747,862,800</b>	<b>13,169</b>	<b>24.03%</b>	<b>21.84%</b>
<b>RANGO 4</b>	<b>14,567</b>	<b>1,100,503,200</b>	<b>75,548</b>	<b>20.00%</b>	<b>14.84%</b>
RIESGO1	2,288	182,421,900	79,730	20.00%	13.24%
RIESGO2	3,461	274,036,500	79,178	20.00%	14.08%
RIESGO3	4,733	358,232,300	75,688	20.00%	14.83%
RIESGO4	2,998	207,320,900	69,153	20.00%	15.98%
RIESGO5	1,022	72,976,600	71,406	20.00%	18.13%
SIN RIESGO	65	5,515,000	84,846	20.15%	20.37%
<b>RANGO 3</b>	<b>51,749</b>	<b>1,616,405,800</b>	<b>31,235</b>	<b>20.00%</b>	<b>16.91%</b>
RIESGO1	3,488	115,790,000	33,197	20.00%	14.26%
RIESGO2	7,707	247,409,100	32,102	20.00%	15.11%
RIESGO3	20,681	633,686,700	30,641	20.00%	16.45%
RIESGO4	13,218	408,535,900	30,908	20.00%	17.59%
RIESGO5	4,170	129,360,400	31,022	20.00%	19.87%
SIN RIESGO	2,485	81,623,700	32,847	20.05%	21.60%
<b>RANGO 2</b>	<b>141,269</b>	<b>2,731,390,100</b>	<b>19,335</b>	<b>21.00%</b>	<b>19.37%</b>
RIESGO1	6,851	131,194,800	19,150	21.00%	15.87%
RIESGO2	15,694	303,853,000	19,361	21.00%	17.00%
RIESGO3	47,411	928,063,000	19,575	21.00%	18.48%
RIESGO4	50,550	973,834,900	19,265	21.00%	20.02%
RIESGO5	17,742	339,903,800	19,158	21.00%	22.75%
SIN RIESGO	3,021	54,540,600	18,054	21.07%	23.43%
<b>RANGO 1</b>	<b>532,613</b>	<b>4,299,563,700</b>	<b>8,073</b>	<b>28.49%</b>	<b>27.06%</b>
RIESGO1	18,366	164,983,700	8,983	26.53%	21.24%
RIESGO2	118,795	826,949,900	6,961	30.13%	22.68%
RIESGO3	146,605	1,137,425,200	7,758	28.68%	24.92%
RIESGO4	141,052	1,280,019,300	9,075	27.38%	27.39%
RIESGO5	58,246	490,422,900	8,420	27.85%	34.51%
SIN RIESGO	49,549	399,762,700	8,068	29.69%	34.45%

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Tabla 21: Estrategia de optimización de margen para el segmento 5

	N° Leads	Leads Monto Millones PEN	Promedio de oferta	TEA OFERTADA SIN ALGORITMO	TEA OFERTADA CON ALGORITMO
<b>SEGMENTO 5</b>	<b>18,100</b>	<b>185,191,700</b>	<b>10,232</b>	<b>26.70%</b>	<b>30.43%</b>
<b>RANGO 4</b>	<b>169</b>	<b>12,699,500</b>	<b>75,145</b>	<b>20.00%</b>	<b>20.43%</b>
RIESGO1	51	3,963,800	77,722	20.00%	18.62%
RIESGO2	59	4,690,000	79,492	20.00%	19.76%
RIESGO3	30	2,205,500	73,517	20.00%	21.73%
RIESGO4	18	1,162,100	64,561	20.00%	23.59%
RIESGO5	10	626,700	62,670	20.00%	25.80%
SIN RIESGO	1	51,400	51,400	20.00%	28.64%
<b>RANGO 3</b>	<b>432</b>	<b>14,717,100</b>	<b>34,067</b>	<b>20.00%</b>	<b>24.21%</b>
RIESGO1	62	2,052,000	33,097	20.00%	22.36%
RIESGO2	130	4,328,800	33,298	20.00%	21.45%
RIESGO3	101	3,468,500	34,342	20.00%	24.11%
RIESGO4	86	2,975,600	34,600	20.00%	26.06%
RIESGO5	29	973,000	33,552	20.00%	28.78%
SIN RIESGO	24	919,200	38,300	20.00%	30.86%
<b>RANGO 2</b>	<b>1,667</b>	<b>31,381,200</b>	<b>18,825</b>	<b>21.00%</b>	<b>28.57%</b>
RIESGO1	189	3,631,700	19,215	21.00%	24.82%
RIESGO2	319	5,960,800	18,686	21.00%	25.72%
RIESGO3	492	9,172,300	18,643	21.00%	27.99%
RIESGO4	448	8,417,400	18,789	21.00%	30.63%
RIESGO5	191	3,657,600	19,150	21.00%	32.73%
SIN RIESGO	28	541,400	19,336	21.25%	34.65%
<b>RANGO 1</b>	<b>15,832</b>	<b>126,393,900</b>	<b>7,983</b>	<b>29.57%</b>	<b>32.63%</b>
RIESGO1	827	7,424,500	8,978	27.33%	28.25%
RIESGO2	5,596	41,540,500	7,423	30.58%	29.57%
RIESGO3	4,843	38,173,700	7,882	29.45%	32.02%
RIESGO4	3,713	31,766,600	8,556	29.22%	34.88%
RIESGO5	513	4,838,500	9,432	27.73%	46.52%
SIN RIESGO	340	2,650,100	7,794	29.10%	49.14%

Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

#### 9.4. Resultados del piloto del algoritmo de optimización

Desde que este piloto iba a tener un impacto real en la cuenta de resultados del banco se decidió aplicar de manera parcial (se aplicó sólo en los leads de la fuerza de ventas). Sin embargo, luego de que en la primera semana se dieron resultados positivos se decidió expandir el piloto a las ofertas reactivas.

Al 24 de julio de 2019 la fuerza de ventas alcanzó un volumen de ventas de S/. 31.2 millones lo que implica un incremento de S/. 11.1 millones con respecto a los resultados del mes de junio de 2019 (ver tabla 22).

Tabla 22: Resultados al 24 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO												
Canal 1	146	S/2.342.070	213	S/2.958.550	218	S/2.499.400	327	S/3.210.800	595	S/5.615.235	581	S/4.525.550	646	S/5.508.226
Canal 2	360	S/4.589.822	420	S/5.990.650	298	S/5.404.100	320	S/4.528.624	338	S/5.384.700	326	S/3.971.500	594	S/8.852.400
Canal 3	288	S/2.319.609	329	S/3.441.595	345	S/3.623.400	256	S/2.508.950	258	S/2.870.550	315	S/3.693.530	363	S/4.396.751
Canal 4											33	S/289.100	80	S/736.000
Canal 5	48	S/589.700	112	S/1.050.500	106	S/1.126.700	82	S/858.800	85	S/828.100	128	S/1.096.500	183	S/1.495.000
Canal 6	315	S/4.257.298	437	S/6.039.640	289	S/3.915.194	359	S/4.754.247	587	S/6.022.289	423	S/4.534.300	574	S/7.052.306
Canal 7			15	S/166.000	32	S/676.300	61	S/767.300	86	S/695.700	98	S/884.300	162	S/1.349.800
Canal 8											143	S/1.161.800	243	S/1.903.300
Total	1157	S/14.098.499	1526	S/19.646.935	1288	S/17.245.094	1405	S/16.628.721	1949	S/21.416.574	2047	S/20.156.580	2845	S/31.293.783

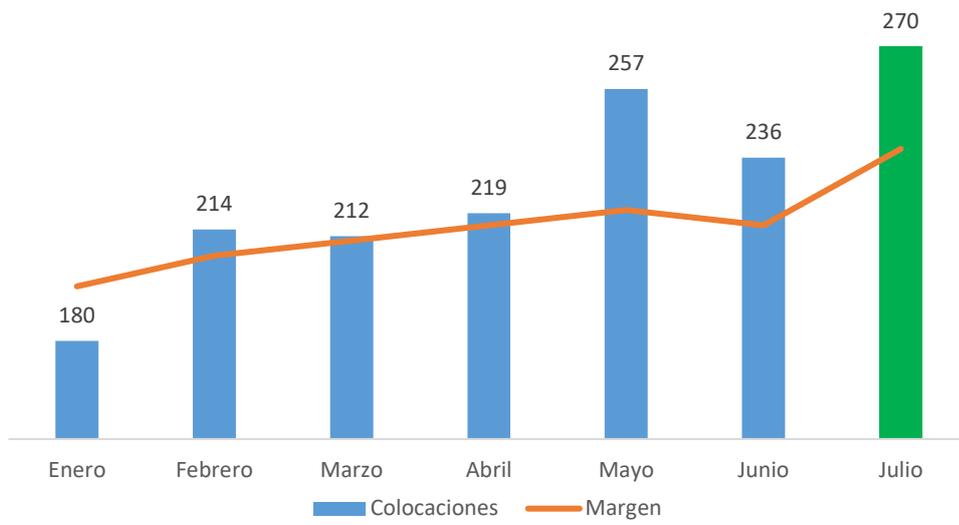
Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

Al 31 de Julio terminó el piloto lográndose incrementar las colocaciones de los créditos de consumo en 33 millones con un margen de utilidad de 5.1 millones adicional (figura 29).

Por lo tanto, los resultados son concluyentes: el algoritmo de optimización del margen comercial cumple con su objetivo. Ha incrementado las ventas y el margen comercial, teniendo un impacto directo en la cuenta de resultados del producto de préstamos de consumo.

Figura 29: Resultados del Piloto



Fuente: Autor de esta tesis.

Elaboración: Autor de esta tesis.

## CAPÍTULO X : CONCLUSIONES

Los desarrollos tecnológicos, el deterioro de la actividad económica y la entrada de nuevos competidores han reducido el margen de ganancia de los bancos. En este contexto, una gestión de pricing soportado por algoritmos de optimización surgen como una solución para que la banca maximice su margen de ganancia.

En esta investigación se ha diseñado un modelo de optimización del margen comercial de los bancos. Este modelo se base en la disposición a pagar de los clientes que desde una visión empírica puede ser estimada a través de una curva de respuesta al precio.

El modelo de optimización es resuelto aplicando técnicas de inteligencia artificial y de una regresión logística. El modelo de machine learnig permite encontrar grupos homogéneos con distintas disposiciones a pagar. Mientras que el modelo logit permite estimar una curva de demanda en cada grupo homogéneo.

El algoritmo de optimización es estimado utilizando datos de un banco. Se encuentra que los grupos homogéneos se forman de acuerdo a su riesgo, el monto de préstamo que solicitan, su deuda total en el sistema financiero y sus ingresos.

Finalmente, se realiza un piloto en las ofertas del banco del mes de julio. Se planteó un objetivo de incremento de ventas en 30 millones y mayor margen en 4.9 millones. Los resultados del piloto fueron exitosos y se alcanzó un incremento en ventas de S/. 33 millones y S/. 5.1 millones adicionales de margen.

## CAPÍTULO XI : RECOMENDACIONES

Desde que la disposición a pagar es dinámica es necesario que este modelo de optimización sea actualizado cada cierto tiempo. La frecuencia mínima de actualización debería ser mensual.

Es decir, es necesario que el modelo de *machine learning* sea automatizado para recibir información al cierre de cada mes. Sin esto, el algoritmo de optimización perdería su potencia y llevaría a resultados que pueden deteriorar la rentabilidad del banco.

## ANEXOS

### I. Resultados al 1 de Julio de 2019

Comparativo Canales										
MES	201902		201903		201904		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1			19	S/146.000	2	S/23.100			13	S/96.600
Canal 2			20	S/177.800	2	S/21.600	2	S/35.200	16	S/167.200
Canal 3			1	S/10.300	3	S/17.600	1	S/10.600		
Canal 4			12	S/115.400	3	S/36.900			3	S/19.400
Canal 5	7	S/80.300	13	S/167.000	5	S/50.100			23	S/251.500
Canal 6			3	S/78.900	2	S/43.300			3	S/36.300
Canal 7									2	S/22.800
<b>Total</b>	<b>7</b>	<b>S/80.300</b>	<b>68</b>	<b>S/695.400</b>	<b>17</b>	<b>S/192.600</b>	<b>3</b>	<b>S/45.800</b>	<b>60</b>	<b>S/593.800</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

### II. Resultados al 2 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	1	S/2.500			19	S/146.000	5	S/74.100	10	S/91.300			24	S/180.800
Canal 2	2	S/12.500	1	S/14.600	21	S/194.200	7	S/100.200			2	S/35.200	31	S/468.300
Canal 3	1	S/22.000	2	S/12.500	1	S/10.300	8	S/62.100	1	S/20.800	1	S/10.600	5	S/22.400
Canal 4													1	S/9.200
Canal 5					12	S/115.400	4	S/55.800	4	S/45.400			9	S/61.700
Canal 6			9	S/127.100	14	S/180.000	11	S/152.300	1	S/18.600			34	S/354.350
Canal 7					3	S/78.900	4	S/68.400					6	S/75.400
Canal 8													8	S/50.100
<b>Total</b>	<b>4</b>	<b>S/37.000</b>	<b>12</b>	<b>S/154.200</b>	<b>70</b>	<b>S/724.800</b>	<b>39</b>	<b>S/512.900</b>	<b>16</b>	<b>S/176.100</b>	<b>3</b>	<b>S/45.800</b>	<b>118</b>	<b>S/1.222.250</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

### III. Resultados al 3 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	1	S/2.500			19	S/146.000	14	S/206.100	20	S/196.800	1	S/6.000	59	S/452.000
Canal 2	2	S/12.500	1	S/14.600	21	S/194.200	18	S/233.500	3	S/43.000	4	S/56.300	54	S/663.000
Canal 3	6	S/66.600	2	S/12.500	1	S/10.300	20	S/151.400	1	S/20.800	1	S/10.600	14	S/98.600
Canal 4													7	S/41.400
Canal 5					12	S/115.400	8	S/89.200	6	S/64.900			20	S/176.800
Canal 6	3	S/26.800	9	S/127.100	14	S/180.000	32	S/395.600	17	S/156.200			58	S/553.850
Canal 7					3	S/78.900	7	S/106.500	2	S/8.300			13	S/145.500
Canal 8													15	S/103.600
<b>Total</b>	<b>12</b>	<b>S/108.400</b>	<b>12</b>	<b>S/154.200</b>	<b>70</b>	<b>S/724.800</b>	<b>99</b>	<b>S/1.182.300</b>	<b>49</b>	<b>S/490.000</b>	<b>6</b>	<b>S/72.900</b>	<b>240</b>	<b>S/2.234.750</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

#### IV. Resultados al 4 de Julio de 2019

Comparativo Canales															
MES	201901		201902		201903		201904		201905		201906		201907		
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	
Canal 1	2	S/15.300	12	S/159.400	26	S/271.200	27	S/327.100	20	S/196.800	19	S/142.400	99	S/773.800	
Canal 2	7	S/46.500	20	S/168.400	22	S/204.200	24	S/331.900	3	S/43.000	17	S/197.300	84	S/1.159.000	
Canal 3	16	S/144.000	19	S/127.100	15	S/110.700	24	S/246.800	1	S/20.800	3	S/39.000	26	S/226.900	
Canal 4													10	S/82.900	
Canal 5					20	S/177.100	10	S/114.600	6	S/64.900				28	S/240.900
Canal 6	6	S/80.900	38	S/404.800	21	S/262.800	52	S/742.900	18	S/162.200	7	S/68.200	80	S/743.850	
Canal 7					3	S/78.900	8	S/118.200	2	S/8.300	5	S/29.100	17	S/171.900	
Canal 8													28	S/230.100	
<b>Total</b>	<b>31</b>	<b>S/286.700</b>	<b>89</b>	<b>S/859.700</b>	<b>107</b>	<b>S/1.104.900</b>	<b>145</b>	<b>S/1.881.500</b>	<b>50</b>	<b>S/496.000</b>	<b>51</b>	<b>S/476.000</b>	<b>372</b>	<b>S/3.629.350</b>	

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

#### V. Resultados al 5 de Julio de 2019

Comparativo Canales															
MES	201901		201902		201903		201904		201905		201906		201907		
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	
Canal 1	2	S/15.300	14	S/187.600	29	S/291.500	40	S/444.300	20	S/196.800	26	S/203.100	149	S/1.143.000	
Canal 2	7	S/46.500	21	S/174.400	26	S/253.000	32	S/453.924	3	S/43.000	21	S/230.300	107	S/1.373.100	
Canal 3	18	S/162.000	32	S/217.100	19	S/141.000	34	S/321.900	1	S/20.800	4	S/41.600	31	S/277.900	
Canal 4													13	S/106.100	
Canal 5					23	S/201.500	15	S/160.300	6	S/64.900				35	S/306.400
Canal 6	7	S/105.200	57	S/590.400	31	S/417.480	80	S/1.128.200	18	S/162.200	13	S/127.900	107	S/1.014.850	
Canal 7					5	S/109.400	15	S/183.100	2	S/8.300	6	S/30.300	21	S/219.900	
Canal 8													34	S/303.300	
<b>Total</b>	<b>34</b>	<b>S/329.000</b>	<b>124</b>	<b>S/1.169.500</b>	<b>133</b>	<b>S/1.413.880</b>	<b>216</b>	<b>S/2.691.724</b>	<b>50</b>	<b>S/496.000</b>	<b>70</b>	<b>S/633.200</b>	<b>497</b>	<b>S/4.744.550</b>	

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

#### VI. Resultados al 6 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	2	S/15.300	24	S/347.800	35	S/358.300	42	S/485.600	53	S/412.900	54	S/373.900	149	S/1.143.000
Canal 2	7	S/46.500	48	S/483.900	39	S/530.800	35	S/510.424	17	S/168.300	39	S/444.100	109	S/1.421.000
Canal 3	18	S/162.000	49	S/363.940	30	S/282.400	34	S/321.900	3	S/30.200	8	S/87.400	33	S/313.100
Canal 4													13	S/106.100
Canal 5			1	S/7.900	25	S/219.000	15	S/160.300	7	S/79.100	8	S/79.900	35	S/306.400
Canal 6	7	S/105.200	75	S/853.600	40	S/523.280	82	S/1.151.800	70	S/675.300	36	S/351.900	111	S/1.078.750
Canal 7					6	S/119.900	15	S/183.100	10	S/61.600	11	S/63.300	21	S/219.900
Canal 8													34	S/303.300
<b>Total</b>	<b>34</b>	<b>S/329.000</b>	<b>197</b>	<b>S/2.057.140</b>	<b>175</b>	<b>S/2.033.680</b>	<b>223</b>	<b>S/2.813.124</b>	<b>160</b>	<b>S/1.427.400</b>	<b>156</b>	<b>S/1.400.500</b>	<b>505</b>	<b>S/4.891.550</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

## VII. Resultados al 7 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	8	S/70.700	36	S/558.850	35	S/358.300	42	S/485.600	91	S/733.300	61	S/442.800	149	S/1.143.000
Canal 2	23	S/139.000	62	S/629.600	43	S/597.200	35	S/510.424	47	S/771.700	42	S/482.500	109	S/1.421.000
Canal 3	29	S/223.550	71	S/645.090	35	S/330.100	34	S/321.900	8	S/69.600	8	S/87.400	33	S/313.100
Canal 4													13	S/106.100
Canal 5			6	S/59.700	27	S/248.800	15	S/160.300	10	S/117.700	10	S/92.500	35	S/306.400
Canal 6	30	S/373.700	103	S/1.171.300	44	S/561.680	82	S/1.151.800	95	S/915.400	46	S/479.600	111	S/1.078.750
Canal 7					7	S/148.100	15	S/183.100	16	S/104.200	12	S/74.300	21	S/219.900
Canal 8											2	S/14.800	34	S/303.300
<b>Total</b>	<b>90</b>	<b>S/806.950</b>	<b>278</b>	<b>S/3.064.540</b>	<b>191</b>	<b>S/2.244.180</b>	<b>223</b>	<b>S/2.813.124</b>	<b>267</b>	<b>S/2.711.900</b>	<b>181</b>	<b>S/1.673.900</b>	<b>505</b>	<b>S/4.891.550</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

## VIII. Resultados al 8 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO												
Canal 1	9	S/89.900	56	S/873.550	39	S/425.900	68	S/700.700	120	S/956.200	64	S/473.300	178	S/1.440.300
Canal 2	32	S/201.700	87	S/909.600	50	S/664.600	52	S/740.924	65	S/1.271.500	45	S/520.700	148	S/1.928.700
Canal 3	54	S/450.149	86	S/768.790	45	S/462.300	49	S/434.800	12	S/90.850	8	S/87.400	41	S/444.400
Canal 4													26	S/206.000
Canal 5			18	S/152.300	30	S/291.100	23	S/226.700	11	S/125.300	10	S/92.500	51	S/436.900
Canal 6	46	S/554.200	136	S/1.661.300	56	S/706.080	108	S/1.428.900	120	S/1.213.800	51	S/532.800	161	S/1.516.750
Canal 7					7	S/148.100	17	S/209.600	20	S/149.100	14	S/113.200	45	S/423.000
Canal 8											2	S/14.800	53	S/577.200
<b>Total</b>	<b>141</b>	<b>S/1.295.949</b>	<b>383</b>	<b>S/4.365.540</b>	<b>227</b>	<b>S/2.698.080</b>	<b>317</b>	<b>S/3.741.624</b>	<b>348</b>	<b>S/3.806.750</b>	<b>194</b>	<b>S/1.834.700</b>	<b>703</b>	<b>S/6.973.250</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

## IX. Resultados al 9 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO												
Canal 1	16	S/255.700	59	S/906.650	40	S/426.900	89	S/929.100	152	S/1.203.900	64	S/473.300	215	S/1.699.500
Canal 2	50	S/380.600	93	S/974.400	57	S/761.300	67	S/979.424	89	S/1.726.400	45	S/520.700	176	S/2.275.700
Canal 3	82	S/636.049	87	S/771.990	53	S/546.600	70	S/587.000	19	S/179.850	8	S/87.400	81	S/789.000
Canal 4													30	S/247.000
Canal 5			18	S/152.300	30	S/291.100	26	S/266.100	14	S/150.400	10	S/92.500	70	S/592.800
Canal 6	60	S/709.700	148	S/1.831.000	59	S/772.180	133	S/1.745.800	162	S/1.638.200	51	S/532.800	201	S/1.939.350
Canal 7					9	S/199.400	20	S/238.000	27	S/185.500	14	S/113.200	59	S/530.400
Canal 8											2	S/14.800	68	S/698.400
<b>Total</b>	<b>208</b>	<b>S/1.982.049</b>	<b>405</b>	<b>S/4.636.340</b>	<b>248</b>	<b>S/2.997.480</b>	<b>405</b>	<b>S/4.745.424</b>	<b>463</b>	<b>S/5.084.250</b>	<b>194</b>	<b>S/1.834.700</b>	<b>900</b>	<b>S/8.772.150</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

## X. Resultados al 10 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO										
Canal 1	22	S/387.300	59	S/906.650	40	S/426.900	106	S/1.080.800	192	S/1.528.700	93	S/646.500	258	S/2.035.700
Canal 2	64	S/538.400	93	S/974.400	57	S/761.300	83	S/1.153.824	115	S/1.999.200	61	S/675.900	222	S/3.036.900
Canal 3	92	S/690.849	87	S/771.990	53	S/546.600	86	S/747.000	29	S/262.750	26	S/324.000	108	S/1.112.700
Canal 4													33	S/279.500
Canal 5			18	S/152.300	30	S/291.100	32	S/310.700	19	S/207.200	19	S/150.200	82	S/698.500
Canal 6	79	S/886.900	148	S/1.831.000	59	S/772.180	162	S/2.180.647	217	S/2.149.800	69	S/711.500	247	S/2.454.550
Canal 7					9	S/199.400	24	S/287.900	31	S/207.900	18	S/155.500	71	S/609.700
Canal 8											7	S/65.600	82	S/776.900
<b>Total</b>	<b>257</b>	<b>S/2.503.449</b>	<b>405</b>	<b>S/4.636.340</b>	<b>248</b>	<b>S/2.997.480</b>	<b>493</b>	<b>S/5.760.871</b>	<b>603</b>	<b>S/6.355.550</b>	<b>293</b>	<b>S/2.729.200</b>	<b>1103</b>	<b>S/11.004.450</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

## XI. Resultados al 11 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO										
Canal 1	37	S/607.300	74	S/1.136.650	59	S/641.500	124	S/1.241.500	201	S/1.591.900	169	S/1.177.100	298	S/2.394.800
Canal 2	85	S/741.600	117	S/1.418.800	78	S/1.090.100	118	S/1.680.224	118	S/2.030.500	103	S/1.044.900	242	S/3.497.700
Canal 3	104	S/771.049	118	S/1.099.390	79	S/859.300	98	S/870.200	30	S/276.050	48	S/626.250	118	S/1.216.800
Canal 4											3	S/19.200	34	S/292.400
Canal 5			28	S/262.500	36	S/336.200	37	S/376.600	21	S/220.700	42	S/317.800	89	S/742.000
Canal 6	100	S/1.139.300	175	S/2.104.200	79	S/1.062.980	183	S/2.429.047	226	S/2.207.700	135	S/1.509.000	269	S/2.690.350
Canal 7					10	S/221.400	28	S/331.700	32	S/210.900	33	S/301.200	78	S/668.200
Canal 8											37	S/274.500	90	S/839.000
<b>Total</b>	<b>326</b>	<b>S/3.259.249</b>	<b>512</b>	<b>S/6.021.540</b>	<b>341</b>	<b>S/4.211.480</b>	<b>588</b>	<b>S/6.929.271</b>	<b>628</b>	<b>S/6.537.750</b>	<b>570</b>	<b>S/5.269.950</b>	<b>1218</b>	<b>S/12.341.250</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

## XII. Resultados al 12 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO										
Canal 1	37	S/607.300	98	S/1.545.050	79	S/919.000	138	S/1.339.600	201	S/1.591.900	237	S/1.778.800	333	S/2.687.400
Canal 2	90	S/828.700	145	S/1.896.400	100	S/1.347.200	142	S/1.911.424	118	S/2.030.500	146	S/1.399.000	277	S/4.092.600
Canal 3	106	S/784.649	147	S/1.557.490	113	S/1.253.900	120	S/1.088.400	30	S/276.050	81	S/1.082.650	151	S/1.606.100
Canal 4											6	S/47.600	36	S/301.200
Canal 5			39	S/356.200	40	S/407.700	42	S/421.600	21	S/220.700	67	S/543.300	96	S/794.700
Canal 6	103	S/1.172.999	206	S/2.507.300	96	S/1.288.480	208	S/2.781.347	226	S/2.207.700	204	S/2.187.200	303	S/3.113.450
Canal 7					16	S/359.500	29	S/336.700	32	S/210.900	43	S/409.900	82	S/715.700
Canal 8											53	S/393.100	102	S/969.900
<b>Total</b>	<b>336</b>	<b>S/3.393.648</b>	<b>635</b>	<b>S/7.862.440</b>	<b>444</b>	<b>S/5.575.780</b>	<b>679</b>	<b>S/7.879.071</b>	<b>628</b>	<b>S/6.537.750</b>	<b>837</b>	<b>S/7.841.550</b>	<b>1380</b>	<b>S/14.281.050</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

### XIII. Resultados al 13 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO										
Canal 1	37	S/607.300	103	S/1.640.650	94	S/1.090.800	153	S/1.467.100	266	S/2.045.700	272	S/2.077.800	333	S/2.687.400
Canal 2	90	S/828.700	164	S/2.276.100	121	S/1.757.700	145	S/1.942.724	132	S/2.214.800	166	S/1.614.900	279	S/4.103.400
Canal 3	106	S/784.649	169	S/1.791.790	131	S/1.381.600	122	S/1.116.700	48	S/483.550	104	S/1.269.450	154	S/1.643.600
Canal 4											7	S/58.100	36	S/301.200
Canal 5			46	S/444.700	49	S/485.800	45	S/471.500	23	S/236.100	75	S/606.700	96	S/794.700
Canal 6	103	S/1.172.999	225	S/2.684.600	123	S/1.588.780	219	S/2.894.147	249	S/2.438.900	223	S/2.450.300	308	S/3.201.050
Canal 7			1	S/5.300	16	S/359.500	31	S/358.100	36	S/254.700	50	S/463.800	82	S/715.700
Canal 8											54	S/398.500	102	S/969.900
<b>Total</b>	<b>336</b>	<b>S/3.393.648</b>	<b>708</b>	<b>S/8.843.140</b>	<b>534</b>	<b>S/6.664.180</b>	<b>715</b>	<b>S/8.250.271</b>	<b>754</b>	<b>S/7.673.750</b>	<b>951</b>	<b>S/8.939.550</b>	<b>1390</b>	<b>S/14.416.950</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

### XIV. Resultados al 14 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	41	S/683.300	123	S/1.880.750	106	S/1.224.100	153	S/1.467.100	298	S/2.403.400	327	S/2.572.500	333	S/2.687.400
Canal 2	120	S/1.158.400	206	S/2.931.600	149	S/2.459.800	145	S/1.942.724	163	S/2.910.500	196	S/2.083.800	279	S/4.103.400
Canal 3	119	S/871.509	185	S/1.933.890	169	S/1.710.500	122	S/1.116.700	63	S/611.050	135	S/1.591.890	154	S/1.643.600
Canal 4											10	S/80.700	36	S/301.200
Canal 5			60	S/585.900	54	S/519.000	45	S/471.500	24	S/248.700	82	S/671.600	96	S/794.700
Canal 6	118	S/1.362.499	252	S/3.025.500	140	S/1.794.280	219	S/2.894.147	295	S/3.079.100	264	S/2.862.900	308	S/3.201.050
Canal 7			4	S/45.000	19	S/421.800	31	S/358.100	44	S/337.200	58	S/531.000	82	S/715.700
Canal 8											65	S/482.100	102	S/969.900
<b>Total</b>	<b>398</b>	<b>S/4.075.708</b>	<b>830</b>	<b>S/10.402.640</b>	<b>637</b>	<b>S/8.129.480</b>	<b>715</b>	<b>S/8.250.271</b>	<b>887</b>	<b>S/9.589.950</b>	<b>1137</b>	<b>S/10.876.490</b>	<b>1390</b>	<b>S/14.416.950</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

### XV. Resultados al 15 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	53	S/817.400	129	S/1.943.350	129	S/1.445.900	186	S/1.720.900	338	S/2.794.850	333	S/2.621.000	393	S/3.237.300
Canal 2	162	S/1.776.000	233	S/3.316.350	165	S/2.858.000	175	S/2.256.524	172	S/3.022.800	198	S/2.100.700	308	S/4.621.000
Canal 3	143	S/1.111.809	202	S/2.092.790	184	S/1.833.300	148	S/1.392.900	87	S/815.050	140	S/1.648.890	178	S/2.141.700
Canal 4											10	S/80.700	36	S/301.200
Canal 5			62	S/608.000	56	S/531.000	47	S/498.300	36	S/366.700	82	S/671.600	109	S/881.000
Canal 6	136	S/1.605.199	268	S/3.267.300	160	S/2.090.680	243	S/3.284.347	328	S/3.464.249	271	S/2.927.900	346	S/3.654.150
Canal 7			6	S/52.100	22	S/470.200	36	S/411.600	47	S/362.800	58	S/531.000	90	S/770.200
Canal 8											66	S/504.000	121	S/1.092.000
<b>Total</b>	<b>494</b>	<b>S/5.310.408</b>	<b>900</b>	<b>S/11.279.890</b>	<b>716</b>	<b>S/9.229.080</b>	<b>835</b>	<b>S/9.564.571</b>	<b>1008</b>	<b>S/10.826.449</b>	<b>1158</b>	<b>S/11.085.790</b>	<b>1581</b>	<b>S/16.698.550</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

## XVI. Resultados al 16 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	58	S/889.300	129	S/1.943.350	133	S/1.507.500	221	S/2.030.600	374	S/3.223.450	333	S/2.621.000	422	S/3.479.350
Canal 2	203	S/2.312.300	233	S/3.316.350	175	S/3.080.100	208	S/2.718.324	194	S/3.246.900	198	S/2.100.700	336	S/5.048.000
Canal 3	159	S/1.197.609	202	S/2.092.790	189	S/1.868.700	180	S/1.667.000	111	S/1.131.150	140	S/1.648.890	210	S/2.634.601
Canal 4											10	S/80.700	42	S/350.500
Canal 5			62	S/608.000	57	S/546.200	58	S/590.400	54	S/538.900	82	S/671.600	116	S/963.700
Canal 6	154	S/1.793.899	269	S/3.270.300	170	S/2.240.380	279	S/3.700.347	371	S/3.881.349	271	S/2.927.900	381	S/4.112.150
Canal 7			6	S/52.100	22	S/470.200	42	S/493.400	54	S/422.500	58	S/531.000	100	S/824.600
Canal 8											66	S/504.000	134	S/1.175.300
<b>Total</b>	<b>574</b>	<b>S/6.193.108</b>	<b>901</b>	<b>S/11.282.890</b>	<b>746</b>	<b>S/9.713.080</b>	<b>988</b>	<b>S/11.200.071</b>	<b>1158</b>	<b>S/12.444.249</b>	<b>1158</b>	<b>S/11.085.790</b>	<b>1741</b>	<b>S/18.588.201</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

## XVII. Resultados al 17 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	76	S/1.195.400	129	S/1.943.350	133	S/1.507.500	250	S/2.288.300	411	S/3.654.150	381	S/2.975.700	450	S/3.829.950
Canal 2	226	S/2.556.400	233	S/3.316.350	175	S/3.080.100	235	S/3.286.324	208	S/3.396.900	218	S/2.672.100	367	S/5.573.300
Canal 3	172	S/1.265.009	202	S/2.092.790	189	S/1.868.700	194	S/1.812.200	136	S/1.420.650	173	S/2.069.990	232	S/2.895.301
Canal 4											15	S/126.100	46	S/449.100
Canal 5	4	S/56.700	62	S/608.000	57	S/546.200	65	S/670.500	60	S/597.900	89	S/725.600	120	S/992.600
Canal 6	172	S/2.029.698	269	S/3.270.300	170	S/2.240.380	301	S/3.988.647	418	S/4.348.949	296	S/3.213.000	402	S/4.301.650
Canal 7			6	S/52.100	22	S/470.200	45	S/533.900	57	S/445.600	63	S/582.500	108	S/909.100
Canal 8											81	S/642.500	151	S/1.257.700
<b>Total</b>	<b>650</b>	<b>S/7.103.207</b>	<b>901</b>	<b>S/11.282.890</b>	<b>746</b>	<b>S/9.713.080</b>	<b>1090</b>	<b>S/12.579.871</b>	<b>1290</b>	<b>S/13.864.149</b>	<b>1316</b>	<b>S/13.007.490</b>	<b>1876</b>	<b>S/20.208.701</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

## XVIII. Resultados al 18 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	78	S/1.209.200	141	S/2.073.350	151	S/1.688.000	250	S/2.288.300	412	S/3.655.150	423	S/3.312.600	478	S/4.038.950
Canal 2	246	S/2.860.722	268	S/3.820.550	193	S/3.548.000	235	S/3.286.324	208	S/3.396.900	243	S/3.002.600	410	S/6.187.900
Canal 3	179	S/1.306.309	224	S/2.271.590	206	S/2.017.300	194	S/1.812.200	140	S/1.455.150	191	S/2.231.690	262	S/3.245.101
Canal 4											17	S/146.200	56	S/524.500
Canal 5	5	S/62.500	67	S/667.500	66	S/607.000	65	S/670.500	60	S/597.900	98	S/806.100	128	S/1.077.800
Canal 6	203	S/2.480.198	297	S/3.852.200	190	S/2.532.480	301	S/3.988.647	423	S/4.386.149	313	S/3.392.200	433	S/4.743.050
Canal 7			6	S/52.100	22	S/470.200	45	S/533.900	58	S/465.300	77	S/693.800	117	S/981.600
Canal 8											98	S/772.900	165	S/1.343.000
<b>Total</b>	<b>711</b>	<b>S/7.918.929</b>	<b>1003</b>	<b>S/12.737.290</b>	<b>828</b>	<b>S/10.862.980</b>	<b>1090</b>	<b>S/12.579.871</b>	<b>1301</b>	<b>S/13.956.549</b>	<b>1460</b>	<b>S/14.358.090</b>	<b>2049</b>	<b>S/22.141.901</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

## XIX. Resultados al 19 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	79	S/1.212.500	170	S/2.434.150	160	S/1.774.100	250	S/2.288.300	412	S/3.655.150	458	S/3.598.650	508	S/4.301.950
Canal 2	258	S/3.038.322	300	S/4.317.150	216	S/4.059.000	235	S/3.286.324	208	S/3.396.900	265	S/3.384.000	448	S/6.712.500
Canal 3	183	S/1.335.609	247	S/2.590.895	236	S/2.353.800	194	S/1.812.200	140	S/1.455.150	212	S/2.568.640	274	S/3.341.701
Canal 4											19	S/164.100	59	S/545.900
Canal 5	8	S/103.400	80	S/779.800	75	S/701.400	65	S/670.500	60	S/597.900	108	S/912.600	144	S/1.183.800
Canal 6	218	S/2.668.198	329	S/4.416.600	214	S/2.864.880	301	S/3.988.647	423	S/4.386.149	340	S/3.746.500	463	S/5.132.150
Canal 7			8	S/103.500	24	S/518.100	45	S/533.900	58	S/465.300	79	S/709.500	129	S/1.084.700
Canal 8											109	S/863.100	182	S/1.480.400
<b>Total</b>	<b>746</b>	<b>S/8.358.029</b>	<b>1134</b>	<b>S/14.642.095</b>	<b>925</b>	<b>S/12.271.280</b>	<b>1090</b>	<b>S/12.579.871</b>	<b>1301</b>	<b>S/13.956.549</b>	<b>1590</b>	<b>S/15.947.090</b>	<b>2207</b>	<b>S/23.783.101</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

## XX. Resultados al 20 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	79	S/1.212.500	175	S/2.476.050	186	S/2.093.400	250	S/2.288.300	445	S/3.963.450	499	S/3.869.250	509	S/4.311.950
Canal 2	258	S/3.038.322	323	S/4.686.350	253	S/4.556.600	236	S/3.300.724	239	S/3.728.900	288	S/3.613.100	453	S/6.815.400
Canal 3	183	S/1.335.609	280	S/2.929.995	275	S/2.708.200	194	S/1.812.200	162	S/1.822.650	248	S/3.006.040	276	S/3.378.001
Canal 4											23	S/197.000	59	S/545.900
Canal 5	8	S/103.400	85	S/812.300	88	S/861.400	65	S/670.500	66	S/668.100	114	S/962.000	144	S/1.183.800
Canal 6	218	S/2.668.198	360	S/4.883.190	249	S/3.403.780	301	S/3.988.647	456	S/4.683.549	365	S/3.973.100	467	S/5.209.050
Canal 7			10	S/114.800	27	S/568.200	45	S/533.900	59	S/472.000	82	S/748.000	129	S/1.084.700
Canal 8											121	S/982.400	182	S/1.480.400
<b>Total</b>	<b>746</b>	<b>S/8.358.029</b>	<b>1233</b>	<b>S/15.902.685</b>	<b>1078</b>	<b>S/14.191.580</b>	<b>1091</b>	<b>S/12.594.271</b>	<b>1427</b>	<b>S/15.338.649</b>	<b>1740</b>	<b>S/17.350.890</b>	<b>2219</b>	<b>S/24.009.201</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

## XXI. Resultados al 21 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	90	S/1.439.900	184	S/2.628.050	205	S/2.310.500	250	S/2.288.300	473	S/4.203.250	529	S/4.101.450	509	S/4.311.950
Canal 2	280	S/3.369.722	361	S/5.319.550	277	S/5.022.300	236	S/3.300.724	256	S/4.087.300	303	S/3.779.700	453	S/6.815.400
Canal 3	213	S/1.694.109	300	S/3.214.395	307	S/3.039.100	194	S/1.812.200	194	S/2.116.550	267	S/3.196.740	276	S/3.378.001
Canal 4											29	S/250.200	59	S/545.900
Canal 5	18	S/227.700	95	S/895.600	96	S/997.500	65	S/670.500	68	S/676.800	118	S/1.005.400	144	S/1.183.800
Canal 6	241	S/3.125.398	396	S/5.475.940	270	S/3.659.980	301	S/3.988.647	478	S/4.886.549	389	S/4.231.800	467	S/5.209.050
Canal 7			11	S/125.300	31	S/652.900	45	S/533.900	66	S/531.900	87	S/773.800	129	S/1.084.700
Canal 8											129	S/1.026.300	182	S/1.480.400
<b>Total</b>	<b>842</b>	<b>S/9.856.829</b>	<b>1347</b>	<b>S/17.658.835</b>	<b>1186</b>	<b>S/15.682.280</b>	<b>1091</b>	<b>S/12.594.271</b>	<b>1535</b>	<b>S/16.502.349</b>	<b>1851</b>	<b>S/18.365.390</b>	<b>2219</b>	<b>S/24.009.201</b>

Fuente: resultados del piloto.

Elaboración: Autor de esta tesis.

XXII.Resultados al 22 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO	ITEM	MONTO
Canal 1	108	S/1.701.600	201	S/2.805.350	218	S/2.499.400	290	S/2.654.900	514	S/4.912.435	537	S/4.155.350	547	S/4.616.650
Canal 2	310	S/3.767.122	385	S/5.706.950	296	S/5.353.800	266	S/3.708.324	286	S/4.600.300	303	S/3.779.700	503	S/7.377.000
Canal 3	239	S/1.904.509	311	S/3.301.395	342	S/3.599.200	217	S/2.069.150	213	S/2.392.350	277	S/3.273.040	304	S/3.685.701
Canal 4											29	S/250.200	67	S/623.600
Canal 5	31	S/420.800	97	S/908.900	106	S/1.126.700	71	S/746.300	79	S/780.800	119	S/1.018.700	157	S/1.275.700
Canal 6	261	S/3.567.198	411	S/5.756.740	288	S/3.912.194	316	S/4.188.447	521	S/5.282.749	392	S/4.257.800	502	S/5.797.350
Canal 7			15	S/166.000	32	S/676.300	53	S/664.000	72	S/594.800	88	S/780.500	140	S/1.187.800
Canal 8											129	S/1.026.300	200	S/1.592.100
<b>Total</b>	<b>949</b>	<b>S/11.361.229</b>	<b>1420</b>	<b>S/18.645.335</b>	<b>1282</b>	<b>S/17.167.594</b>	<b>1213</b>	<b>S/14.031.121</b>	<b>1685</b>	<b>S/18.563.434</b>	<b>1874</b>	<b>S/18.541.590</b>	<b>2420</b>	<b>S/26.155.901</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

XXIII. Resultados al 23 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO												
Canal 1	128	S/2.068.170	213	S/2.958.550	218	S/2.499.400	314	S/3.033.500	568	S/5.364.535	537	S/4.155.350	601	S/5.131.026
Canal 2	344	S/4.331.422	420	S/5.990.650	298	S/5.404.100	298	S/4.164.924	316	S/4.962.400	303	S/3.779.700	563	S/8.412.200
Canal 3	272	S/2.208.809	329	S/3.441.595	345	S/3.623.400	243	S/2.272.050	231	S/2.578.250	277	S/3.273.040	336	S/4.129.651
Canal 4											29	S/250.200	74	S/677.000
Canal 5	37	S/471.900	112	S/1.050.500	106	S/1.126.700	79	S/839.100	85	S/828.100	119	S/1.018.700	174	S/1.435.200
Canal 6	289	S/3.917.798	437	S/6.039.640	289	S/3.915.194	349	S/4.626.547	561	S/5.687.299	392	S/4.257.800	539	S/6.321.006
Canal 7			15	S/166.000	32	S/676.300	61	S/767.300	78	S/637.900	88	S/780.500	155	S/1.284.800
Canal 8											129	S/1.026.300	228	S/1.787.900
<b>Total</b>	<b>1070</b>	<b>S/12.998.099</b>	<b>1526</b>	<b>S/19.646.935</b>	<b>1288</b>	<b>S/17.245.094</b>	<b>1344</b>	<b>S/15.703.421</b>	<b>1839</b>	<b>S/20.058.484</b>	<b>1874</b>	<b>S/18.541.590</b>	<b>2670</b>	<b>S/29.178.783</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

XXIV. Resultados al 24 de Julio de 2019

Comparativo Canales														
MES	201901		201902		201903		201904		201905		201906		201907	
CANAL	ITEM	MONTO												
Canal 1	146	S/2.342.070	213	S/2.958.550	218	S/2.499.400	327	S/3.210.800	595	S/5.615.235	581	S/4.525.550	646	S/5.508.226
Canal 2	360	S/4.589.822	420	S/5.990.650	298	S/5.404.100	320	S/4.528.624	338	S/5.384.700	326	S/3.971.500	594	S/8.852.400
Canal 3	288	S/2.319.609	329	S/3.441.595	345	S/3.623.400	256	S/2.508.950	258	S/2.870.550	315	S/3.693.530	363	S/4.396.751
Canal 4											33	S/289.100	80	S/736.000
Canal 5	48	S/589.700	112	S/1.050.500	106	S/1.126.700	82	S/858.800	85	S/828.100	128	S/1.096.500	183	S/1.495.000
Canal 6	315	S/4.257.298	437	S/6.039.640	289	S/3.915.194	359	S/4.754.247	587	S/6.022.289	423	S/4.534.300	574	S/7.052.306
Canal 7			15	S/166.000	32	S/676.300	61	S/767.300	86	S/695.700	98	S/884.300	162	S/1.349.800
Canal 8											143	S/1.161.800	243	S/1.903.300
<b>Total</b>	<b>1157</b>	<b>S/14.098.499</b>	<b>1526</b>	<b>S/19.646.935</b>	<b>1288</b>	<b>S/17.245.094</b>	<b>1405</b>	<b>S/16.628.721</b>	<b>1949</b>	<b>S/21.416.574</b>	<b>2047</b>	<b>S/20.156.580</b>	<b>2845</b>	<b>S/31.293.783</b>

Fuente: resultados del piloto.  
Elaboración: Autor de esta tesis.

## BIBLIOGRAFÍA

1. Argandoña, A., Gámez, C. y Mochón, F. “Macroeconomía Avanzada I y II”. Mc Graw Hill, 1997.
2. Baker W., Marn M., Zawada C. (2010). The Price Advantage. Jhon Wiley & Sons, Inc.
3. Jeffrey M. Wooldridge (2010). Introducción a la Econometría, un enfoque moderno. Cengage Learning.
4. Blanchard, Oliver (2017). Macroeconomics. 7<sup>a</sup> ed. : Pearson.
5. Bijak, Katarzyna & C. Thomas, Lyn & Mues, Christophe. (2014). Dynamic affordability assessment: Predicting an applicant’s ability to repay over the life of the loan. Journal of Credit Risk. 10. 3-32.
6. Dey, S. (2010). Modeling the Combined Effects of Credit Limit Management and Pricing Actions on Profitability of Credit Card Operations. International Journal of Business and Management, vol. 5 N° 4, 168-177.
7. Financial Stability Board (febrero 2019). FinTech and market structure in financial services: Market developments and potential financial stability implications.  
<https://www.fsb.org/wp-content/uploads/P140219.pdf>
8. Jain, Dipak C. and Siddhartha S. Singh. 2002. Customer Lifetime Value Research in Marketing: A Review and Future Directions. Journal of Interactive Marketing. Volume 16, No. 2, Spring.
9. Kotler, Philip, Hermawan Kartajaya and Iwan Setiawan. 2010. *Marketing 3.0: From Products to Customers to the Human Spirit*. Hoboken: NJ: John Wiley and Sons, Inc..
10. Larraín, F., Sachs, J. D., & Sachs, J. (2002). Macroeconomía en la economía global (2da Ed.). Pearson Educación.
11. Luc Ngai, J. Qu John, Yung W., Tan Cha., Chen H., Aquino M., Salatiello G. (2016). Price to Win Create value through smarter pricing in a competitive interest rate environment . Recuperado de  
<https://www.mckinsey.com/~media/mckinsey/industries/financial%20services/our%20insights/price%20to%20win%20under%20interest%20rate%20liberalization%20at%20chinas%20banks/price%20to%20win%20create%20value%20through%20smarter%20pricing%20in%20a%20competitive%20interest%20rate%20environment.ashx>

12. L. Breiman, J. Friedman, R. Olshen, C. Stone, *Classification and Regression Trees*, Wadsworth and Brooks, Monterey, CA, 1984.
13. Laeven, Luc and Fabian Valencia, 2010, “Resolution of Banking Crises: The Good, the Bad, and the Ugly,” IMF Working Paper No. 10/44.
14. Laeven, Luc and Fabian Valencia, 2008, “Systemic Banking Crises: A New Database,” IMF Working Paper No. 08/224.
15. Levine, R. (2005), “Finance and growth: theory and evidence”, *Handbook of economic growth*.
16. Lyn C. Thomas (2009). *Consumer Credit Models: Pricing, Profit and Portfolios*. New York, Oxford University Press
17. Xavier Freixas, Jean-Charles Rochet (1999), *Economía Bancaria*. Madrid. Antoni Bosch.
18. T. Hothorn, K. Hornik, A. Zeileis, Unbiased recursive partitioning: a conditional inference framework, *J. Comput. Graph. Statist.* 15 (3) (2006) 651–674.
19. Nicholson, W. (2008). *Teoría Microeconómica: Principios básicos y ampliaciones* (9ª ed.). México: Cengage Learning.
20. Özalp Ozer y Robert Phillips (2012). *The Oxford Handbook of Pricing Management*. Oxford University Press.
21. Paul Hunt & Jim Saunders (2013). *World Class Pricing: The Journey*. Bloomington, iUniverse, Inc.
22. Philip Kotler, Hermawan Kartajaya, y Iwan Setiawan (2010). *Marketing 3.0: from products to customers to the human spirit*. New Jersey: John Wiley.
23. Philip Kotler, Hermawan Kartajaya, y Iwan Setiawan (2017). *Marketing 4.0: moving from traditional to digital*. New Jersey: John Wiley.
24. Rault, C., Sova, A., Sova, R., Maria Caporale, G., 2014. *Financial Development and its Effects on Economic Growth: A Dynamic Analysis, Emerging Markets and the Global*
25. Robert L. Phillips (2005). *Pricing and Revenue Optimization*. Stanford University Press.
26. Romer, D. “Advanced Macroeconomics”. Fourth Edition. McGraw Hill. 2012.
27. Stepanova M., Thomas, L.C (2002). Survival analysis methods for personal loan data. *Operations Research*, 50, 277-289.
28. Stepanova M. and Thomas, L.C., (2001). PHAB scores: Proportional hazards analysis behavioural scores. *J. Operational Research Society*, 52, 1007-16.

29. So, Kyong and Yonghan (2014). Optimization strategy of credit line management for credit card business. *Computers & Operations Research*, Volume 48, 81–88.
30. Tim J. Smith, (2016). *Price Done Right*. Canada, Wiley.
31. Tong, Edward N.C. & Mues, Christophe & Brown, Iain & Thomas, Lyn C., 2016. "Exposure at default models with and without the credit conversion factor," *European Journal of Operational Research*, Elsevier, vol. 252(3), pages 910-920.
32. Trevor Hastie, Robert Tibshirani, Jerome H. Friedman (2017). *The Elements of Statistical Learning*. Segunda edición. New York. Springer.
33. Varian, H. R. (2015). *Microeconomía intermedia: Un enfoque actual* (9ª ed.). Barcelona: Antoni Bosh Editores.
34. W.-Y. Loh, Fifty years of classification and regression trees, *Internat. Statist. Rev.* 82 (3) (2014) 329–348.