

# Modelos predictivos sobre la capacidad de pago aplicados en la originación y la cobranza



**Diego Corzo**  
Director de  
Analítica de Datos  
*Mareigua*

# Agenda

- 1 | Antecedentes: algo de literatura
- 2 | El riesgo de crédito en el ciclo de vida del cliente
- 3 | Desafíos & Oportunidades
- 4 | Casos de éxito

## De qué hablaremos?

*Los expertos en el mercado ven una gran importancia al respecto del uso de la información y los datos asociados a la capacidad de pago en el desarrollo de modelos predictivos en el proceso del crédito.*

*La relación de los datos y los modelos predictivos asociados a la información de las condiciones laborales y el historial del salario en el ciclo de crédito y en el ciclo de vida del cliente como factores de innovación disruptiva.*

*Ante la necesidad y llegada de la información que se asocia a la evaluación de la solvencia, el mercado crediticio se encuentra con desafíos y oportunidades en su uso.*

*Hay entidades que ya están trabajando con esta información, generando valor a través del uso de información de capacidad de pago e ingresos, en todas las etapas del ciclo de crédito (originación, mantenimiento y cobranzas), obteniendo excelentes resultados.*

*«Cuando era joven pensaba que el dinero era lo más importante en la vida, ahora que soy mayor sé que lo es»  
– Oscar Wilde, dramaturgo irlandés*

## 1 | Antecedentes: algo de literatura

Se está retomando la importancia de conocer información que avale la solvencia de un cliente

*"(...) la necesidad de más datos para comprender la solvencia crediticia de un solicitante nunca ha sido tan grande, ya que se ha demostrado una y otra vez que los puntajes crediticios por sí solos son una evaluación poco confiable de la salud financiera"*



**Ronan Burke**

Forbes Councils Member | COUNCIL POST | Membership (fee-based)

Ronan Burke. Forbes Councils Member. "How To Use Alternative Credit Data For Smarter, More Inclusive Lending Decisions" (Nov 28, 2022)

Fuente: <https://www.forbes.com/sites/forbestechcouncil/2022/11/28/how-to-use-alternative-credit-data-for-smarter-more-inclusive-lending-decisions/?sh=3833c88334fd>



Cada vez es más importante el uso de datos asociados a las condiciones laborales en el desarrollo de modelos predictivos

*Las herramientas tradicionales de calificación crediticia analizan principalmente el historial de pago de un consumidor, los montos que debe, la duración de su historial crediticio, el crédito nuevo y los tipos de crédito que usa, mientras omite factores como el historial laboral, el salario y otros, elementos que podrían sugerir solvencia (Mikella Hurley & Julius Adebayo. “Credit scoring in the era of big data”. 18 YALE J.L. & TECH. 148. 2016. pág. 156).*

*Se han desarrollado modelos predictivos de gastos y sobreendeudamiento que pueden usarse junto con medidas de riesgo para rechazar solicitudes de personas que probablemente ya estén sobreendeudadas, o para restringir el tamaño del crédito a lo que el solicitante puede pagar (Finlay, Steven. (2006). Predictive models of expenditure and over-indebtedness for assessing the affordability of new consumer credit applications. Journal of the Operational Research Society. 57. 655-669. 10.1057/palgrave.jors.2602030).*



## Temas claves y realidades intrínsecas en las diferentes etapas del ciclo de crédito

**Originación:** De acuerdo con Makuch (citado por Mays, 2001, pág. 8): *"Se estima que hasta el 80% del riesgo total medible y controlable es observable en el momento de suscribir la solicitud de crédito. No hay otro punto en el ciclo de vida del crédito en el que las decisiones afecten más a la rentabilidad que en la suscripción"* (Mays, E. (Ed.). (2001). *Handbook of Credit Scoring*. Broadway, New York, USA. Glenlake Publishing Company, Limited).

**Mantenimiento:** De acuerdo con Rosenberg & Czepiel (1983, pág. 47): *"Se has encontrado que el costo de atraer nuevos consumidores es seis veces mayor que el costo de retener a los actuales"* (Rosenberg, L. J., & Czepiel, J. A. (1983). *A Marketing Approach to Customer Retention*. *Journal of Consumer Marketing*, Vol. 2, pp. 45-51).

**Cobranza/Recuperación:** De acuerdo con Anderson (2007) *"Las cobranzas exitosas dependen no solo de la voluntad y la capacidad de pago del cliente, sino también de la capacidad y determinación del cobrador para cobrar"* (Raymond Anderson (2007) *The Credit Scoring Toolkit, Theory and Practice for Retail Credit Risk Management and Decision Automation*; ISBN: 9780199226405).

*Cómo mejorar la originación y aumentar la rentabilidad?*

*Cómo atender mejor a mis clientes actuales?*

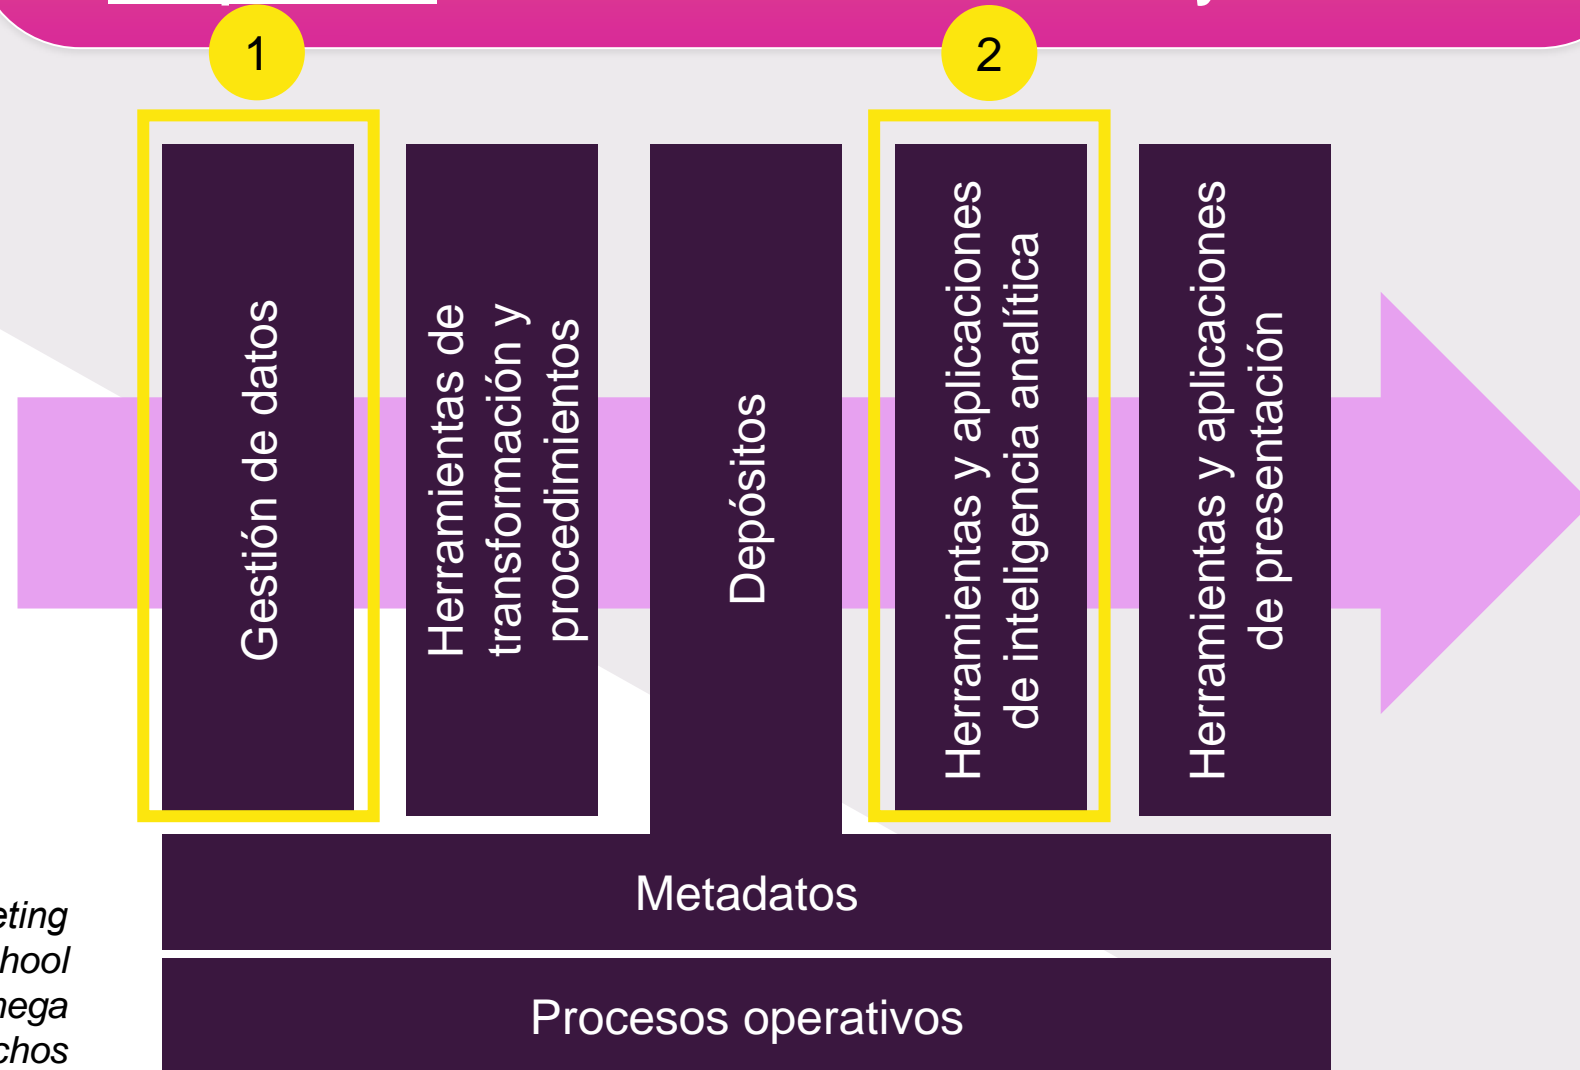
*Cómo aumentar mis capacidades para cobrar mejor?*

## Los pilares de la competitividad analítica



Davenport, T. H. & Harris, J. G. (2007). "Competing On Analytics". Harvard Business Review School Publishing. Primera edición español: Alfaomega Grupo Editor, México, abril 2009. Derechos reservados ©Profit Editorial. Pp. 221

En la actualidad se ha vuelto muy relevante llegar a ser competitivos a través del uso de los datos y la analítica

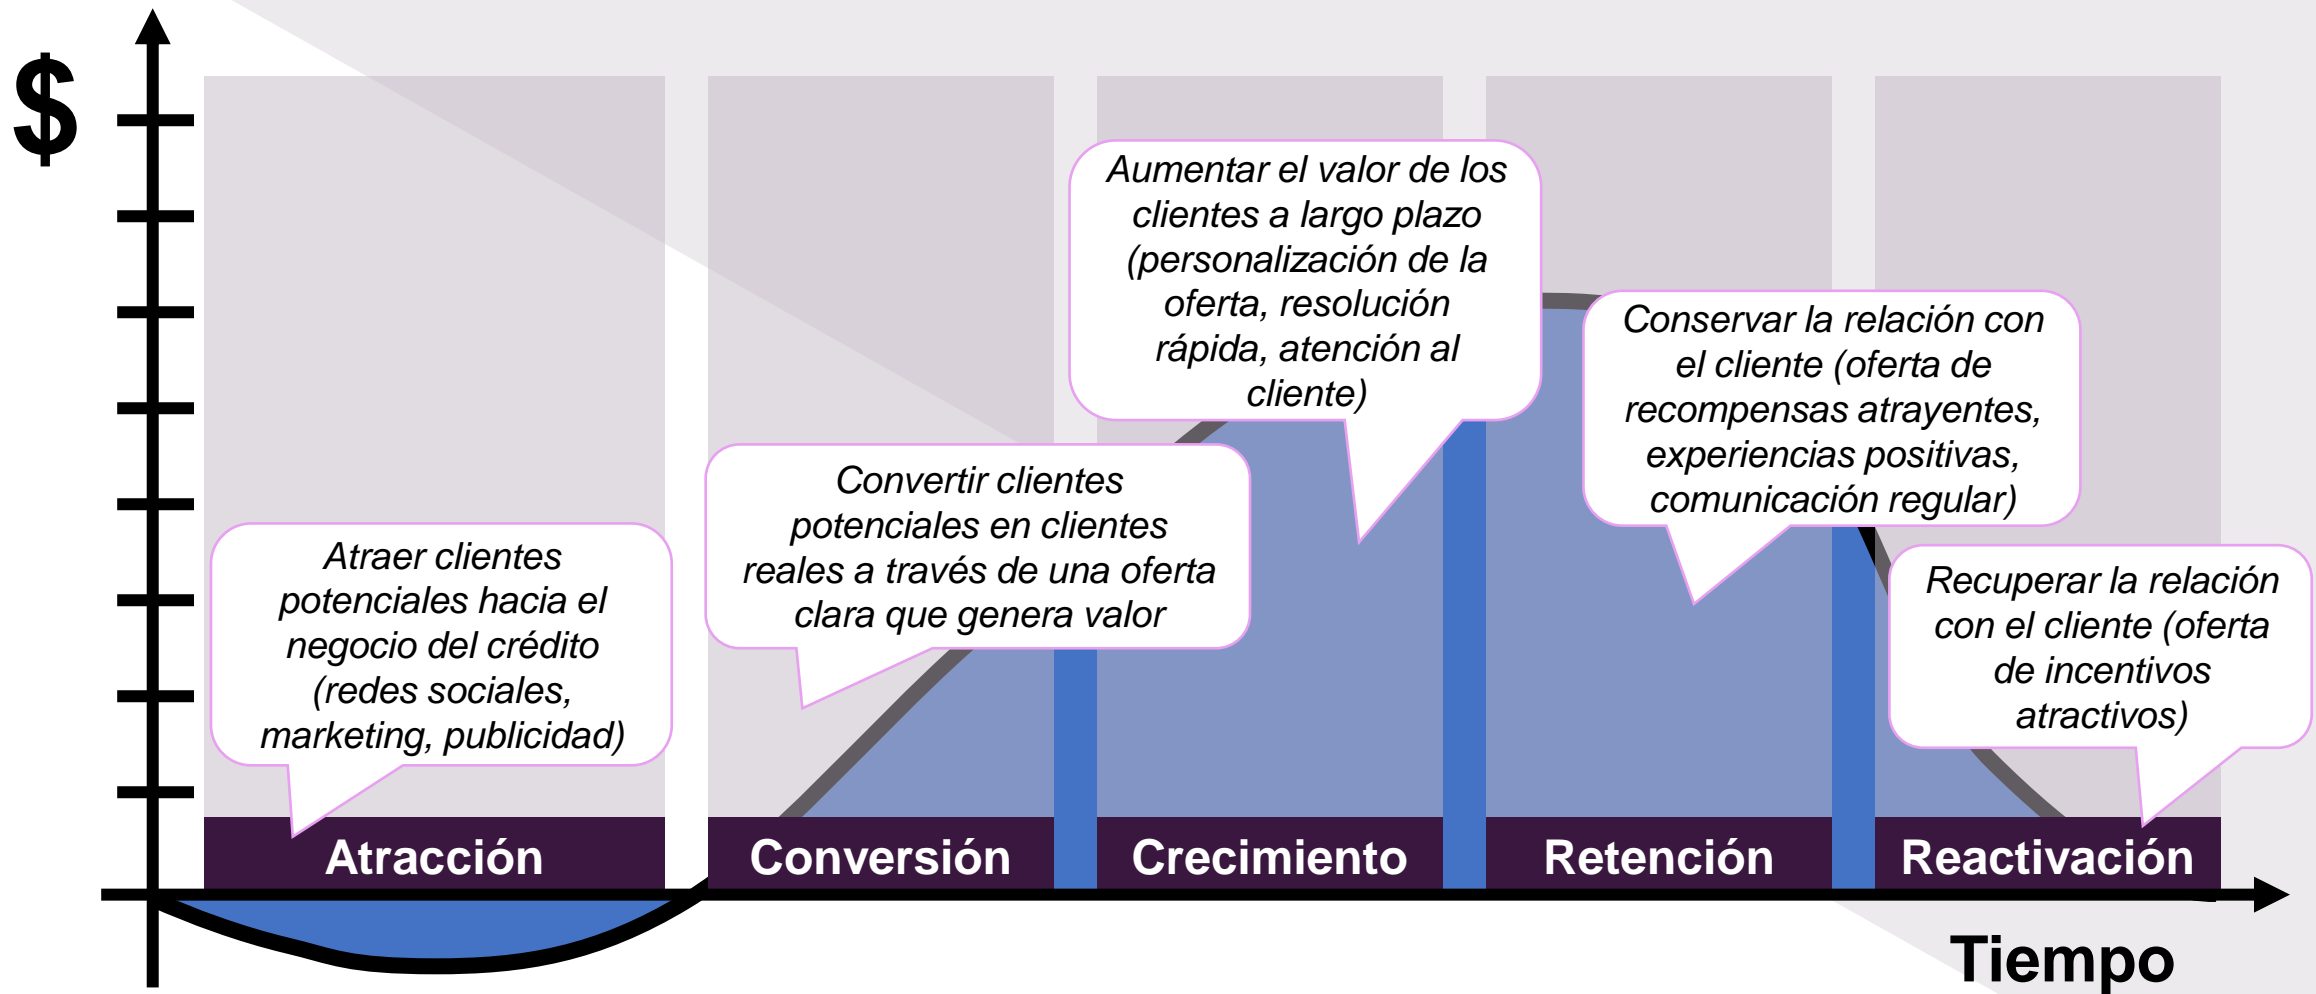


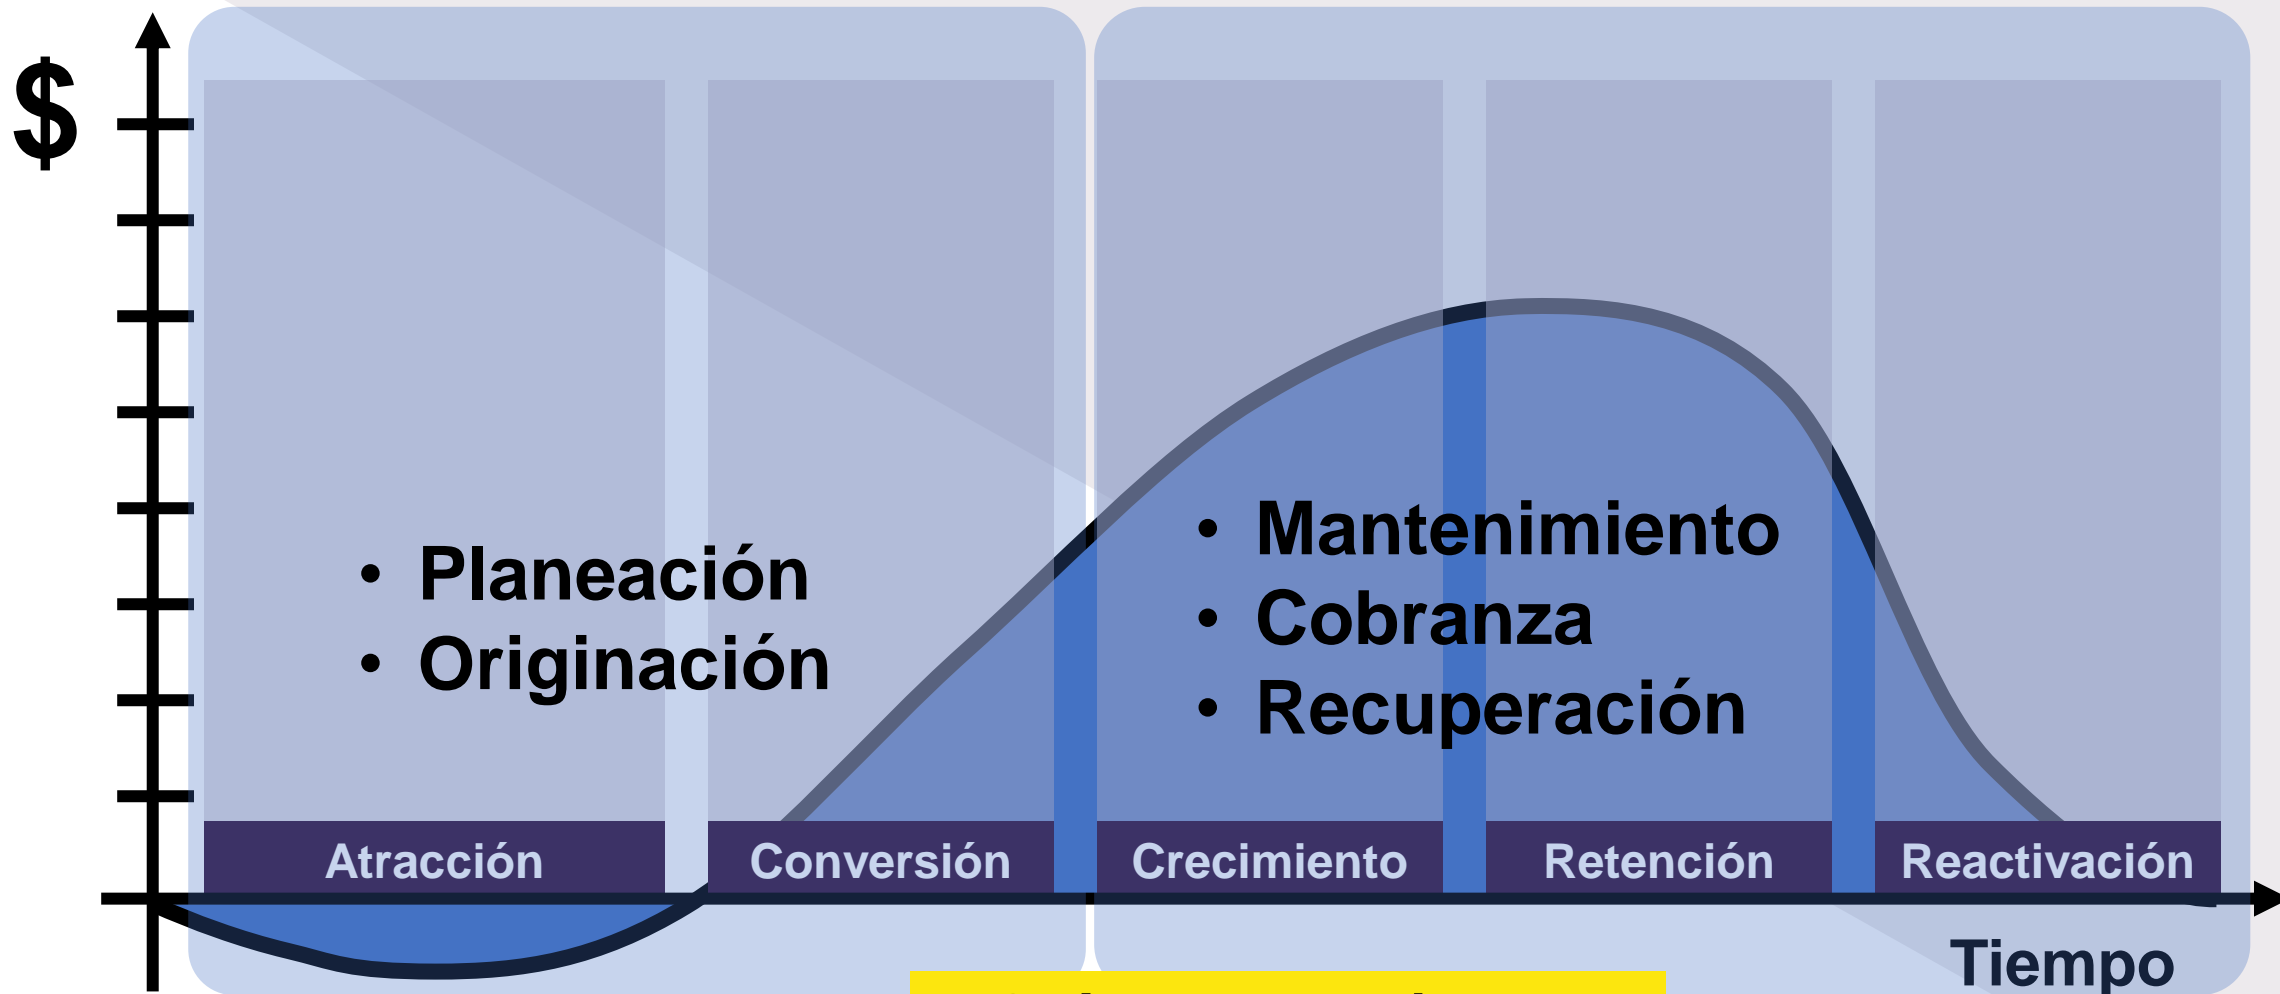


*«No vigiles el ciclo de vida del producto, vigila  
el ciclo de vida del mercado»  
– Philip Kotler, economista estadounidense*

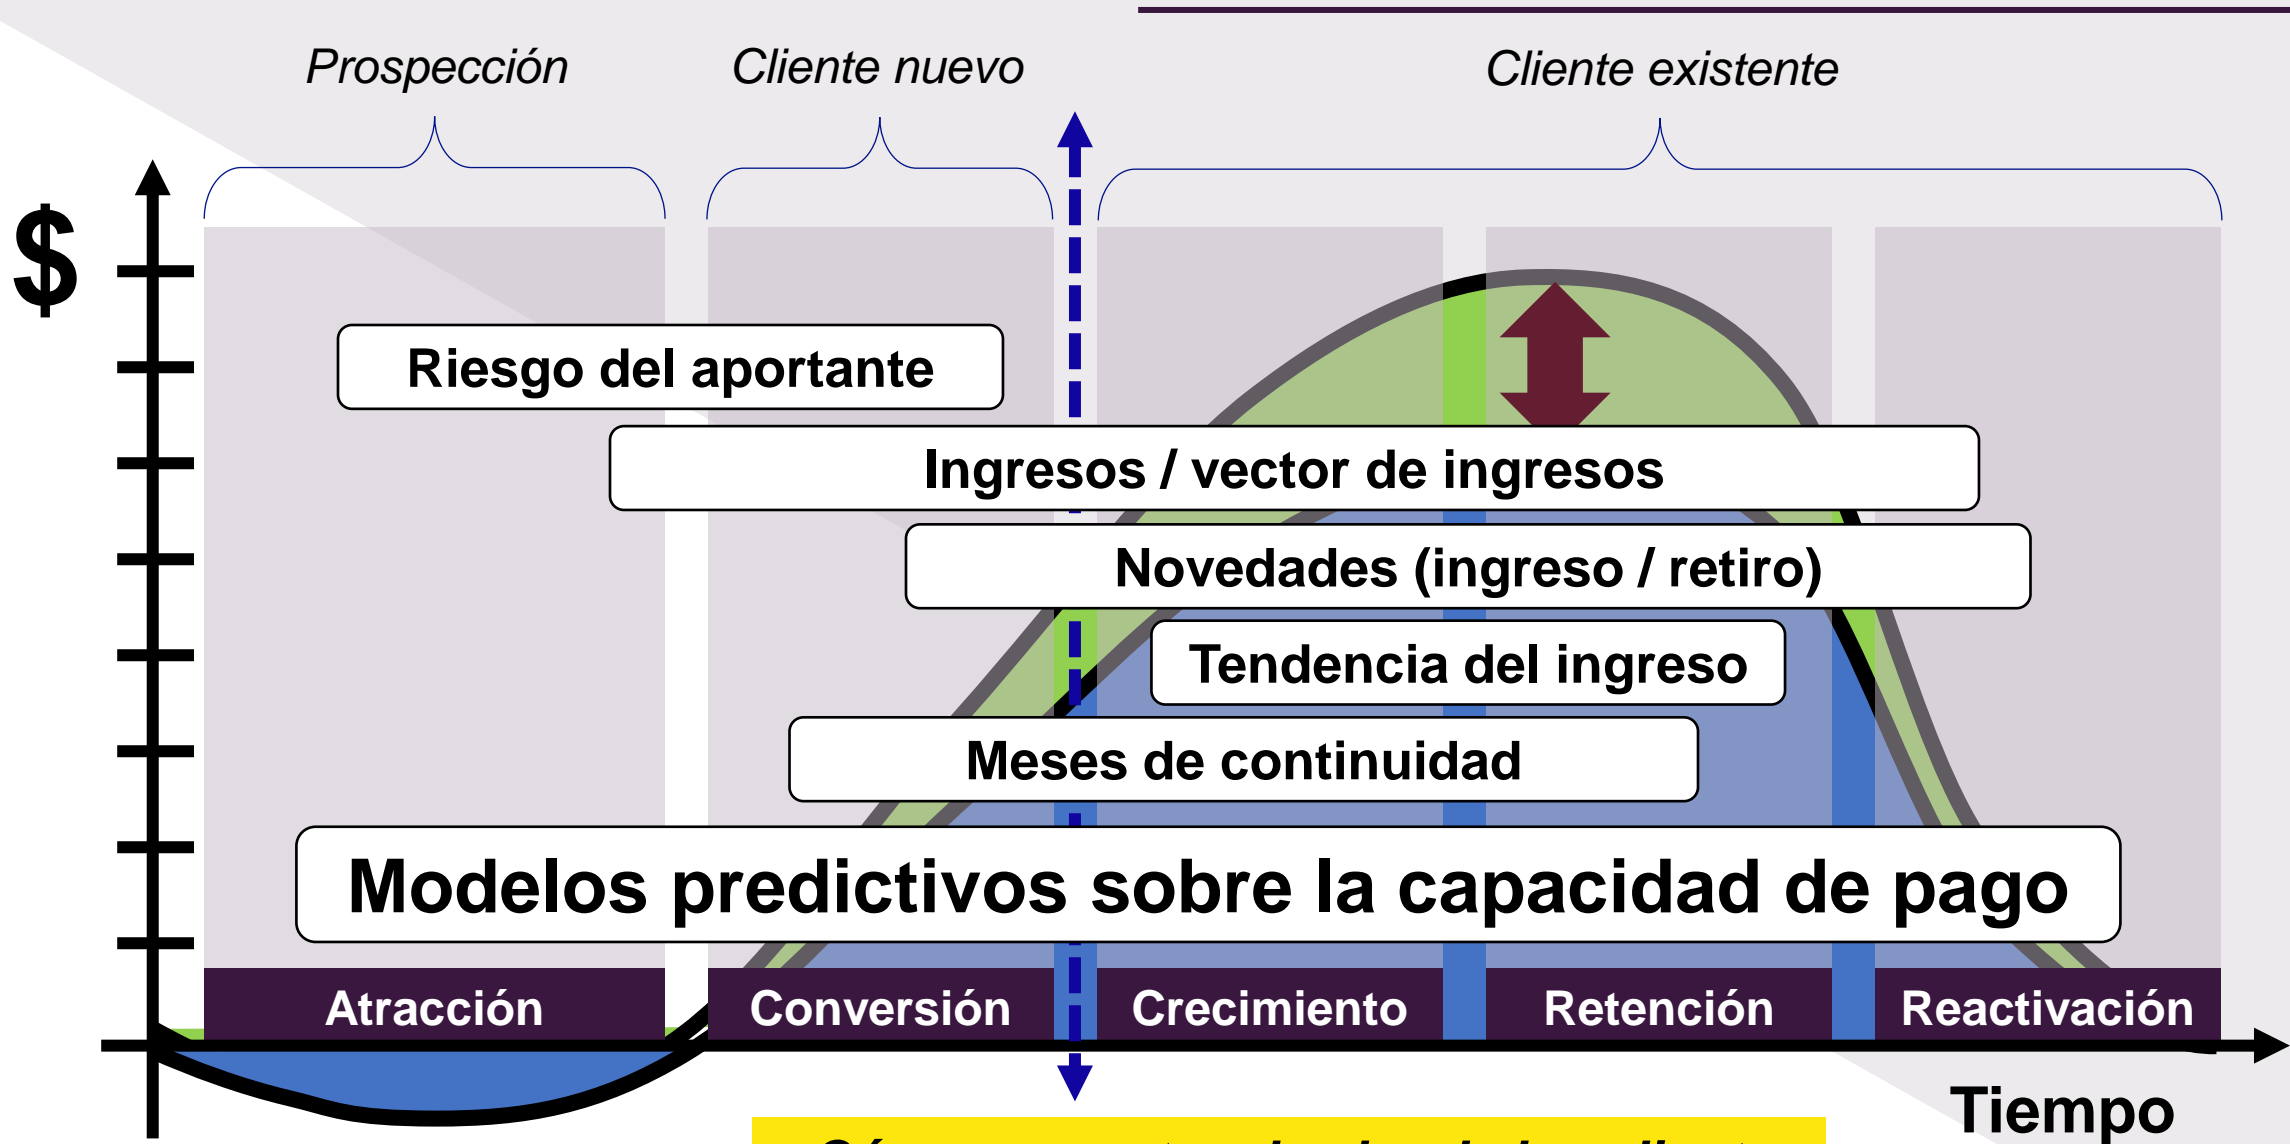
## 2 | El riesgo de crédito en el ciclo de vida del cliente

# Aplicaciones en el ciclo de vida del cliente





*¿Cuál es la relación con el ciclo de riesgo de crédito?*



# Modelos predictivos sobre la capacidad de pago

Modelos de riesgo a la medida que incluyen información relacionada con las condiciones de empleo e ingresos

Modelos que predicen eventos en relación a la capacidad de pago o mantener las fuentes de ingresos

Modelos de puntuación “affordability”

Modelos que predicen el sobre-endeudamiento

*«El futuro tiene muchos nombres. Para los débiles es lo inalcanzable. Para los temerosos, lo desconocido. Para los valientes es la oportunidad»  
– Victor Hugo, novelista francés*

### 3 | Desafíos & Oportunidades



# Retos en el desarrollo de modelos predictivos alrededor de la capacidad de pago en el contexto de la transformación digital



*Calidad de los datos*

*Interpretación de los modelos*

*Protección de datos*

*Cambios en el comportamiento de los clientes*

*Regulaciones y cumplimiento normativo*

*Eventos macroeconómicos coyunturales*





# Oportunidades en el desarrollo de modelos predictivos alrededor de la capacidad de pago en el contexto de la transformación digital



***Automatización de los procesos (originación y cobranza) → mayor eficiencia y rapidez***

***Mejora la precisión en la toma de decisiones***

***Permite la personalización en la oferta del crédito***

***Favorece la inclusión financiera***

***Facilita la innovación en productos y servicios financieros***



Actualmente Mareigua cuenta con dos modelos predictivos desarrollados totalmente con información relacionada con capacidad de pago, cuyo objetivo es complementar y robustecer los modelos tradicionales. Estos modelos son:

- Score de desempleo
- Estimador de ingreso futuro

***Modelos actualmente operando en entidades financieras***

***Algunos usos que hemos encontrado al trabajar con nuestros clientes:***



**Origenación:** Trabajar sobre zonas grises y en estrategias para poblaciones VIP | personalizar la oferta.



**Mantenimiento:** Mejorar la siguiente mejor oferta y ser proactivos en el tratamiento diferencial del cliente | personalizar la oferta.



**Cobranza y recuperación:** Priorizar | mejorar la negociación.

# Backtesting general [empleados e independientes]

Fue entrenado con 18 millones de consultas, a través de algoritmos avanzados de aprendizaje automático. El modelo predictivo. El score de desempleo es una aproximación de un affordability score.



¿A quién va dirigido el puntaje? A quienes se encuentren **como EMPLEADOS o INDEPENDIENTES** en alguno de sus trabajos actuales

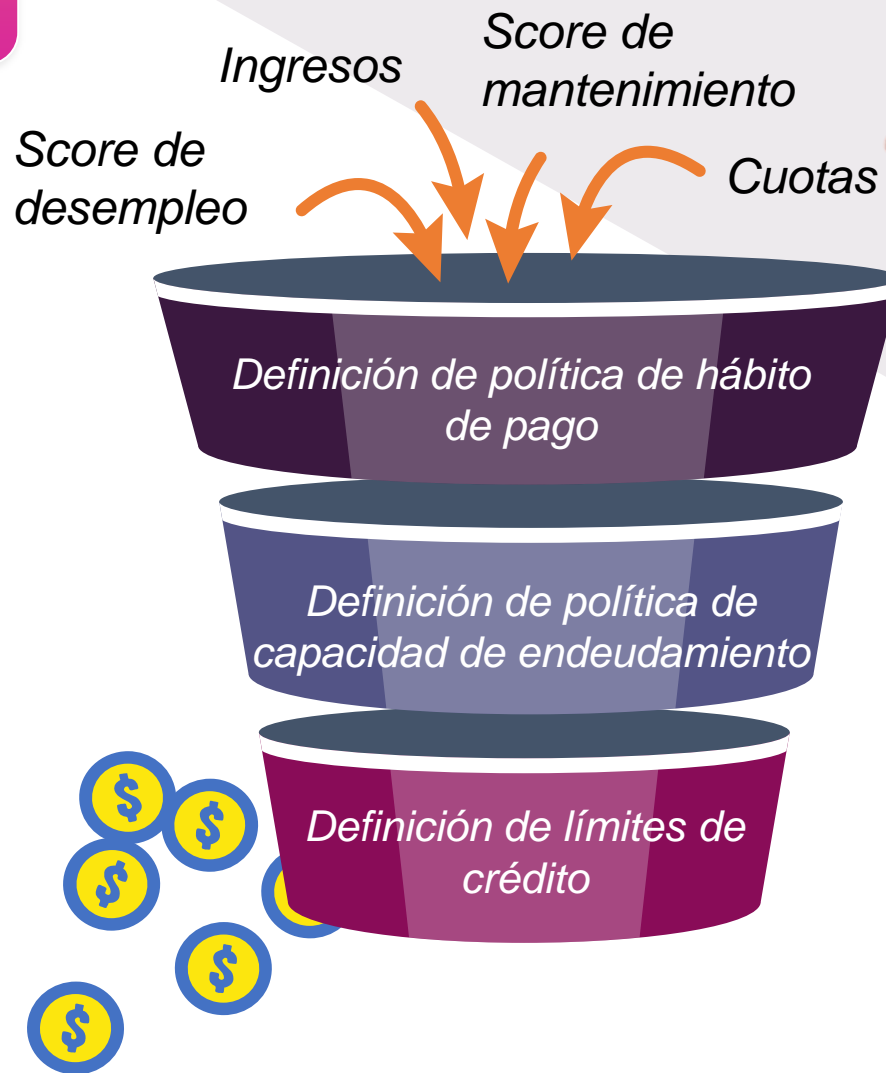
KS	GINI	ROC
57.66%	69.63%	84.82%

Min Score	Max Score	%Total	Tasa de Buenos	%Buenos Acum	Tasa de Malos	%Malos Acum	Odds
918	953	9.63%	99.80%	100.00%	0.20%	0.20%	494.70
887	917	10.39%	99.65%	89.94%	0.35%	0.28%	282.29
871	886	10.72%	99.50%	79.09%	0.50%	0.36%	200.11
856	870	10.18%	99.32%	67.92%	0.68%	0.44%	145.61
828	855	9.33%	98.88%	57.34%	1.12%	0.56%	88.56
805	827	10.41%	98.51%	47.68%	1.49%	0.72%	66.07
739	804	9.33%	97.52%	36.94%	2.48%	0.96%	39.32
678	738	9.99%	94.87%	27.42%	5.13%	1.48%	18.50
617	677	10.02%	88.24%	17.49%	11.76%	2.62%	7.50
488	616	9.99%	78.73%	8.23%	21.27%	4.49%	3.70
Total		100.00%	95.51%	.	4.49%	.	21.29

¿Qué mide? La probabilidad de que se queden **desempleados en TODOS SUS TRABAJOS ACTUALES** durante seis meses después de consultado (medido a través de los pagos, cuando la ausencia de ellos se presenta de manera consecutiva)

## Ejemplo: Proceso de preaprobación tarjeta de crédito

1



1

- Garantizar las fuentes de ingreso (score de desempleo)
- Capacidad de pago esperada

2

- Punto de corte rentable (Score de mantenimiento)
- Tasas de interés diferenciales

3

1. Cálculo de un ingreso disponible (ingresos – deudas mensuales) → cuota nueva potencial
2. Cálculo de un monto a ofrecer en función de la cuota nueva potencial



## Ejemplo: Proceso de definición de estrategias de cobranzas

Dos clientes con la misma información tradicional para la gestión de cobranzas... pero con información de ingresos y condiciones laborales diferentes

El score de desempleo permite realizar pruebas a la estrategia de la cobranza al estilo "champion/challenger"



Score de riesgo = 800  
Saldo adeudado = \$4.000  
Cuotas a pagar = \$2.000  
Altura de mora = 30  
Ingreso en originación = \$3.000

**Score de desempleo = 500**  
**Ingreso actual = \$4.500**  
**Novedad = retiro**  
**Capacidad de pago = \$2.500**



Score de riesgo = 800  
Saldo adeudado = \$4.000  
Cuotas a pagar = \$2.000  
Altura de mora = 30  
Ingreso en originación = \$3.000

**Score de desempleo = 750**  
**Ingreso actual = \$2.500**  
**Novedad = ingreso**  
**Capacidad de pago = \$500**

Una misma acción de cobranza



Dos acciones de cobranza diferentes



*«Centrarte en algo y hacerlo realmente bien te puede  
llevar muy lejos»  
– Kevin Systrom, cofundador de Instagram*

## 4 | Casos de éxito

# Importancia de la capacidad de pago

Entidad financiera empieza a usar soluciones Mareigua y obtiene valor en originación y en cobranzas con diferentes variables asociadas a la capacidad de pago

Originalmente usaba en su estrategia un score de crédito del mercado y filtros de mora, priorizaba la cobranza únicamente con base al score

- A través de un piloto identificó poder de discriminación en score de desempleo, riesgo y CIIU empleador, meses continuidad, promedio ingreso neto, cantidad empleadores
- Nueva estrategia analizando primero la capacidad de pago y posterior el comportamiento de mercado
- Prioriza en cobranza >90 dpd clientes acaban de quedar empleados y con cuota/ingreso  $\geq 0.5$

**Resultado: Aumentó 52% tasa de aprobación, atiende nuevo segmento sin experiencia crediticia. Disminuyó tasa de rodamiento en 23%**



# Actualizar oferta y servicio proactivamente

Entidad financiera programó alerta cuando sus clientes alcanzaran o disminuyeran de \$8MM, siendo el segmento VIP de la entidad con atención personalizada

Anteriormente sólo actualizaba información anualmente y la tasa de respuesta de la campaña era baja al ser reactiva

Mensualmente ajusta los canales de atención y siguiente mejor producto de acuerdo al ciclo de vida del cliente y su capacidad de pago real

**Resultado: Aumentó 68% aceptación de campaña, disminución tasa de deserción en 19% y 23% disminución en costos de servicio**

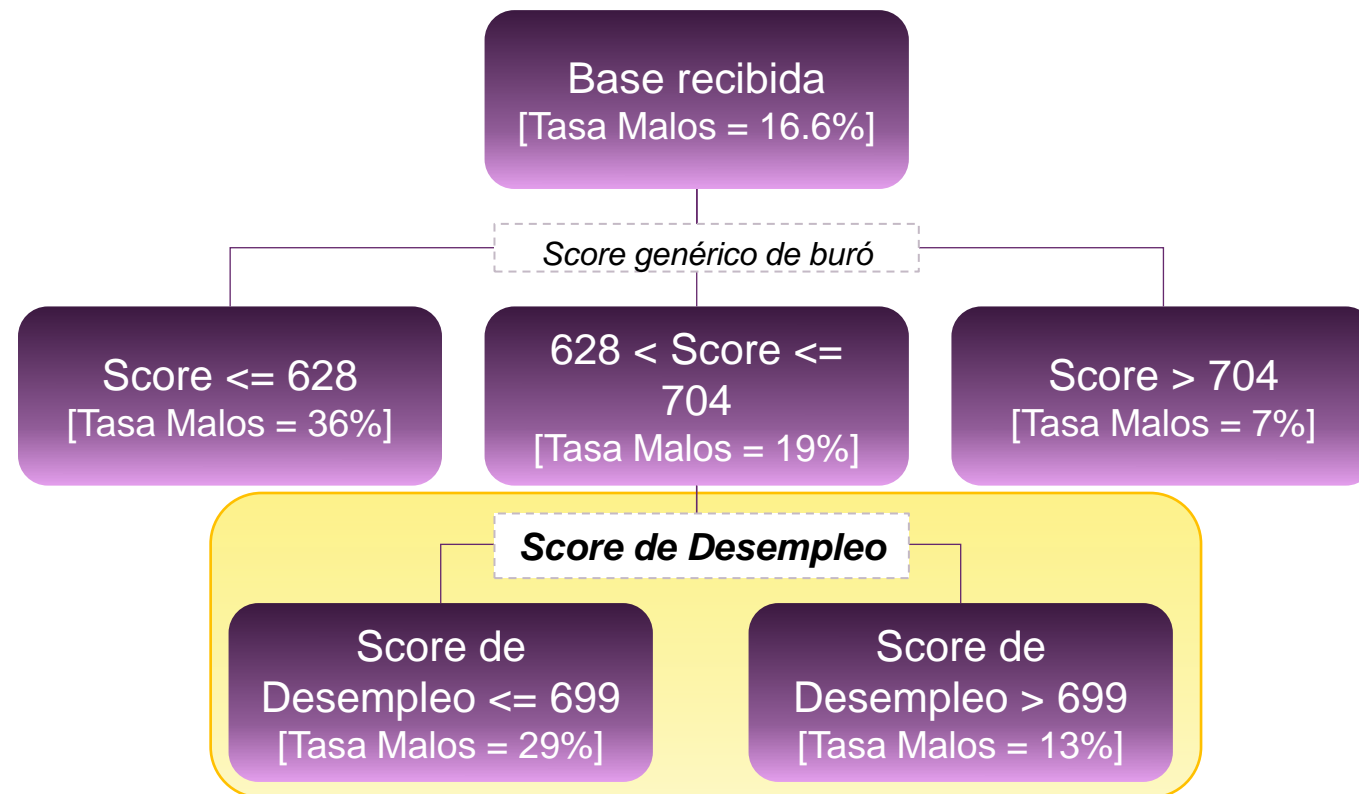


# Score de desempleo: Caso de éxito 1

Hemos identificado oportunidades de mejora en los rangos medios del score genérico de buró segmentando de una manera más eficiente

**Árbol de decisión para el uso conjunto del score genérico de riesgo y del score de desempleo**

**Definición de incumplimiento = 90+ @ 6 meses**



**Resultado: Aumentó un 18% en la aprobación del crédito, equivalente a un aumento del 70% en montos colocados al conocer el ingreso y generar otorgamiento a través de él**

# Score de desempleo: Caso de éxito 2

Utilizando el score de desempleo de Mareigua, un grupo de entidades financieras logró reducir sus pérdidas de crédito en un 13%, demostrado a través de un caso de negocio

Con base en información de originación se evidencia el ordenamiento del score de desempleo sobre la tasa de mora alcanzada por los clientes:


## Estado de resultados

(pesos)

Score	Clientes	Monto	Ever 60+	LGD	Pérdida crédito
Score < 614	5.627	\$4.500.000	28,59%	102%	<b>\$7.384.205.187</b>
Score >= 614	65.088	\$4.500.000	17,33%	94%	\$47.713.344.192
Total	70.715	\$4.500.000	18,30%	95%	\$55.097.549.379



**Al excluir el grupo de menor puntaje, las entidades financieras obtuvieron una disminución del 13% en sus pérdidas de crédito**



**Gracias**





**MAREIGUA**  
[www.mareigua.co](http://www.mareigua.co)