

Modelos de Churn Bancarios con R

Trabajo Final de la Maestría en Data Mining

Presentado por

Diego Ariel Oppenheim

Director

Martin Volpacchio

Fecha: 31/7/2017



UNIVERSIDAD
AUSTRAL

Objetivos del trabajo final

- Entender la situación actual de fuga de clientes del Banco
- Entender cuáles son las variables que mejor explican el fenómeno
- Desarrollar un modelo de Data Mining que permita predecir los clientes que se darán de baja dentro de los próximos dos meses
- Entender los motivos de bajas de clientes y definir acciones comerciales de retención
- Cuantificar el impacto de un programa de retención



Esquema General

Fuentes de Información

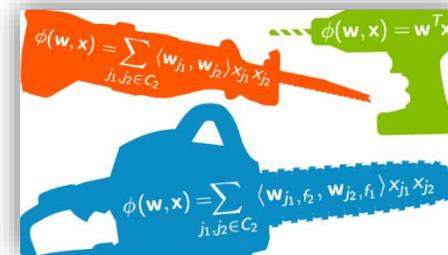


Cuantificar el incentivo, costos y ganancia esperada de un programa de retención



Estrategia post retención para aumentar la fidelización.

Identificación de las principales variables que definen/caracterizan a los clientes que se fugarán



Clientes con mayor valor real y potencial para el Banco

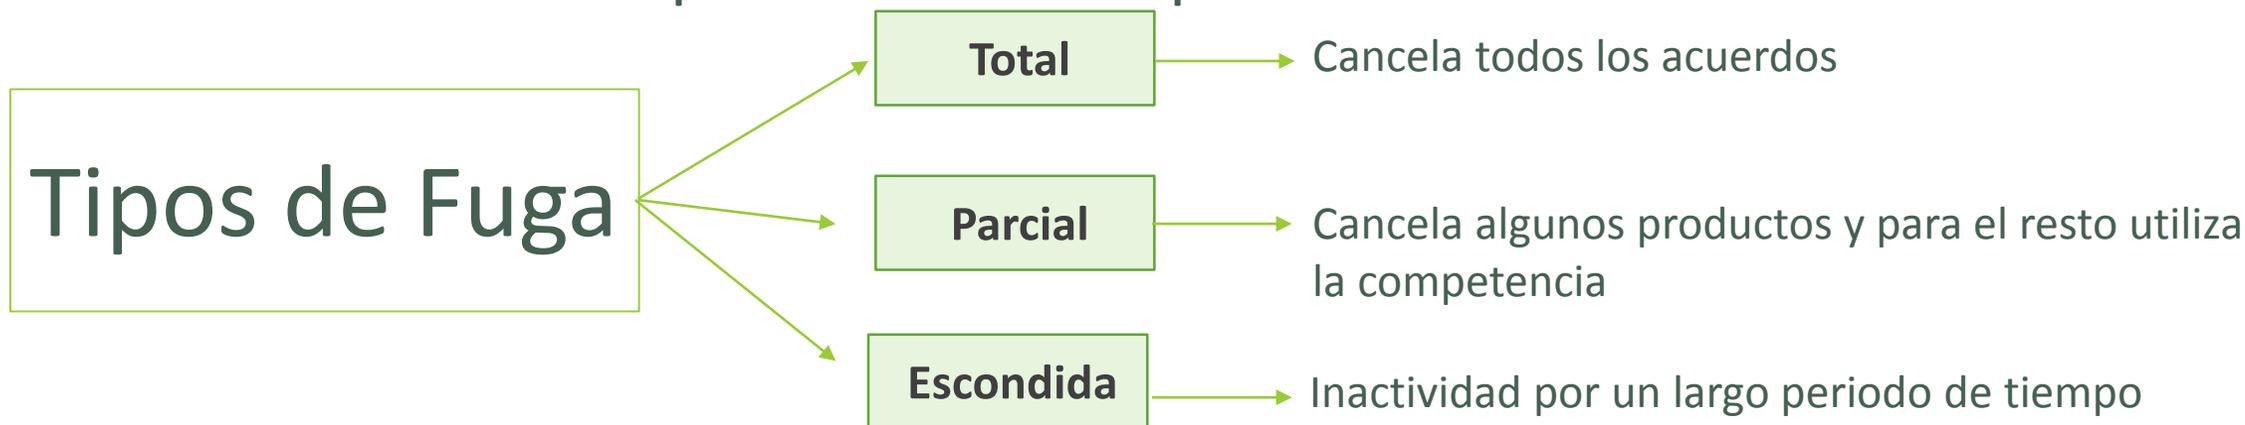


Medidas de retención apropiadas para los clientes en riesgo de fuga



Introducción al concepto de Attrition

- Término utilizado para describir la pérdida del cliente



Motivos de fuga

- Precio
- Producto
- Servicio - Insatisfacción
- Mercado
- Organización
- Ofertas Competencia

Por qué retenerlos?

- Más rentable retener a un cliente valioso que captar uno nuevo
- Clientes a largo plazo tienden a consumir más
- Clientes a Largo Plazo resultan menos sensibles a actividades publicitarias de la competencia
- Nuevos clientes potencialmente riesgosos

Etapas del Trabajo - Concepto del KDD (*Knowledge Discovery in Databases*)

PROCESS CONSULTING



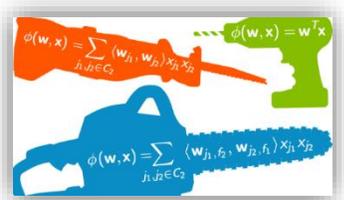
- Fuentes de información
- Análisis de datos
- IT
- Data Warehouse
- Integración
- Multiplataforma
- Formatos diferentes
- Frecuencia de extracción

- Valores ausentes
- Imputación de valores
- Outliers
- Duplicados, registros incoherentes
- Nuevas Variables
- Transformación de variable
- Feature Engineering

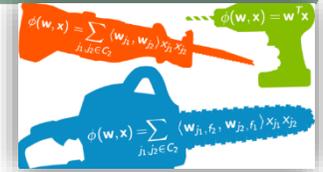
- Descubrimiento
- Patrones, secuencias
- Modelos de clasificación, predicción
- Confiabilidad
- Usabilidad
- Escalabilidad
- Robustez
- Estacionalidad de los datos

- Evaluación técnica y comercial
- Métricas de rendimiento
- Accuracy
- Recall
- AUC
- LIFT
- Curva Roc
- Matriz de confusión

- Acción sobre el cliente (Evento)
- Comunicación
- Presentación de resultados
- Medición
- Plan de retención
- Servicio post venta



Imputación de valores faltantes - Nulos



- Descarte de registros
- Imputación de datos faltantes en base a árboles de decisión
- Conserva la distribución inicial de la variable

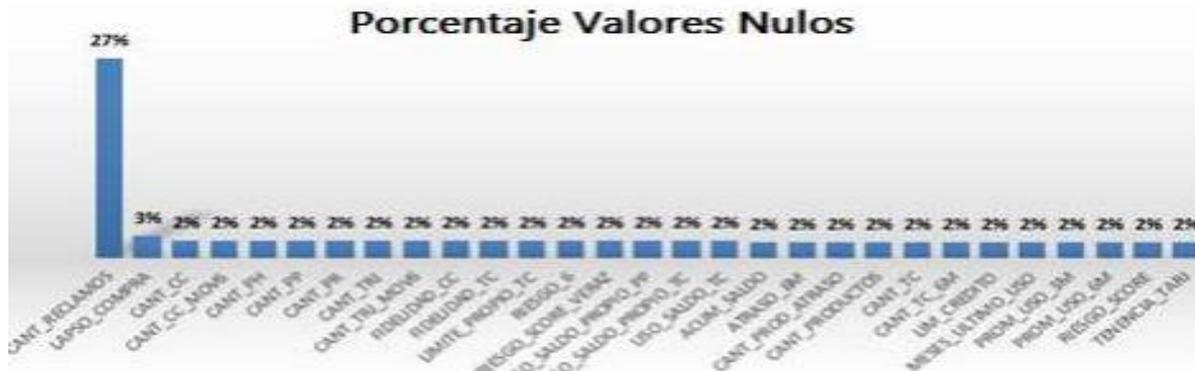
Data Set Original

Mbb	Edad	var_act
NA	3.5	1.4
NA	3	NA
4.7	3.2	1.3
4.6	3.1	1.5
NA	3.6	NA
5.4	NA	1.7
NA	3.4	1.4
4.8	3.4	1.5
4.4	2.9	1.4

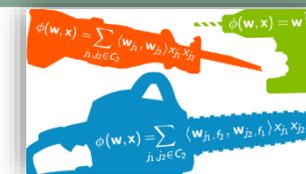
Imputación datos faltantes

nuevo Data set Imputado

Mbb	Edad	var_act
4.3	3.5	1.4
4.4	3	1.1
4.7	3.2	1.3
4.6	3.1	1.5
4.5	3.6	1.7
5.4	3.9	1.7
5.1	3.4	1.4
4.8	3.4	1.5
4.4	2.9	1.4



Balanceo de la muestra



- Problema de clases desbalanceadas
- Escasez de una de las clases (un conjunto de datos resulta significativo)
- Bajo % de fuga de la población de estudio

Clientes	Ventanas Temporales			CHURN_TOTAL	Proporción	Proporción Churn
	Junio	Julio	Agosto			
2.2M	0	0	0	0	97,6%	97,6%
9.2K	1	0	0	1	0,4%	2,4%
23K	0	1	0	1	1,0%	
22.7K	0	0	1	1	1,0%	
2.3M						

Foco en clientes Premium - Alta participación en las ganancias

Muestra no Balanceada

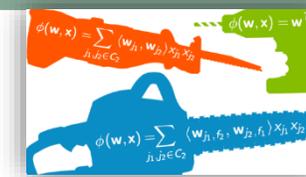
Segmentos Select y Alta	Cientes	Proporción
Cientes NO fugados (0)	411.549	99,15%
Cientes Fugados (1)	3.546	0,85%
Total	415.095	100,00%

Muestra Balanceada

Segmentos Select y Alta	Cientes	Proporción
Cientes NO fugados (0)	25.000	87,58%
Cientes Fugados (1)	3.546	12,42%
Total	28.546	100,00%

Se aplicó la técnica del sub-muestreo aleatorio que elimina al azar instancias de la clase mayoritaria

Creación de nuevas variables - *Feature Engineering*



Derivadas de variables existente

- Discretización de la variable cuadrante (valor del cliente)
- Discretización del mejor producto
- Discretización de la zona de residencia
- Discretización del estado civil

Variables *Flag* (0-1)

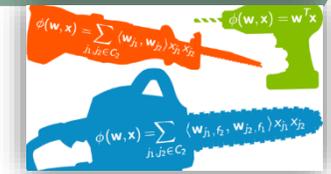
- Tenencia de tarjeta de crédito (últimos 3 y 6 meses)
- Tenencia de tarjeta de débito (últimos 3 y 6 meses)
- Cobro de sueldo hace 3 meses

Variables Ratio

- Variación de MBB (ingreso que deja al Banco)
- Variación en la cantidad de productos bancarios
- Variación de la cantidad de artículos consumidos
- Variación del monto en consumo
- Variación del monto total de las inversiones
- Variación del saldo en cuenta corriente
- Variación de la cantidad de extracciones por Home Banking

Variaciones a 3 y 6 meses

Selección de variables



- Definir las variables más influyentes para los modelos
- Independencia entre variables, baja correlación con entre si y alta correlación con la variable target (fuga del cliente)

Se excluyeron las variables con un coeficiente de correlación mayor o igual a 0.8

Ingreso Promedio y Suma del Ingreso tienen alta correlación positiva



Se excluye la que menor correlación tiene con la variable target

Lapso de compra y Attrition tienen alta correlación negativa



Se mantiene la variable

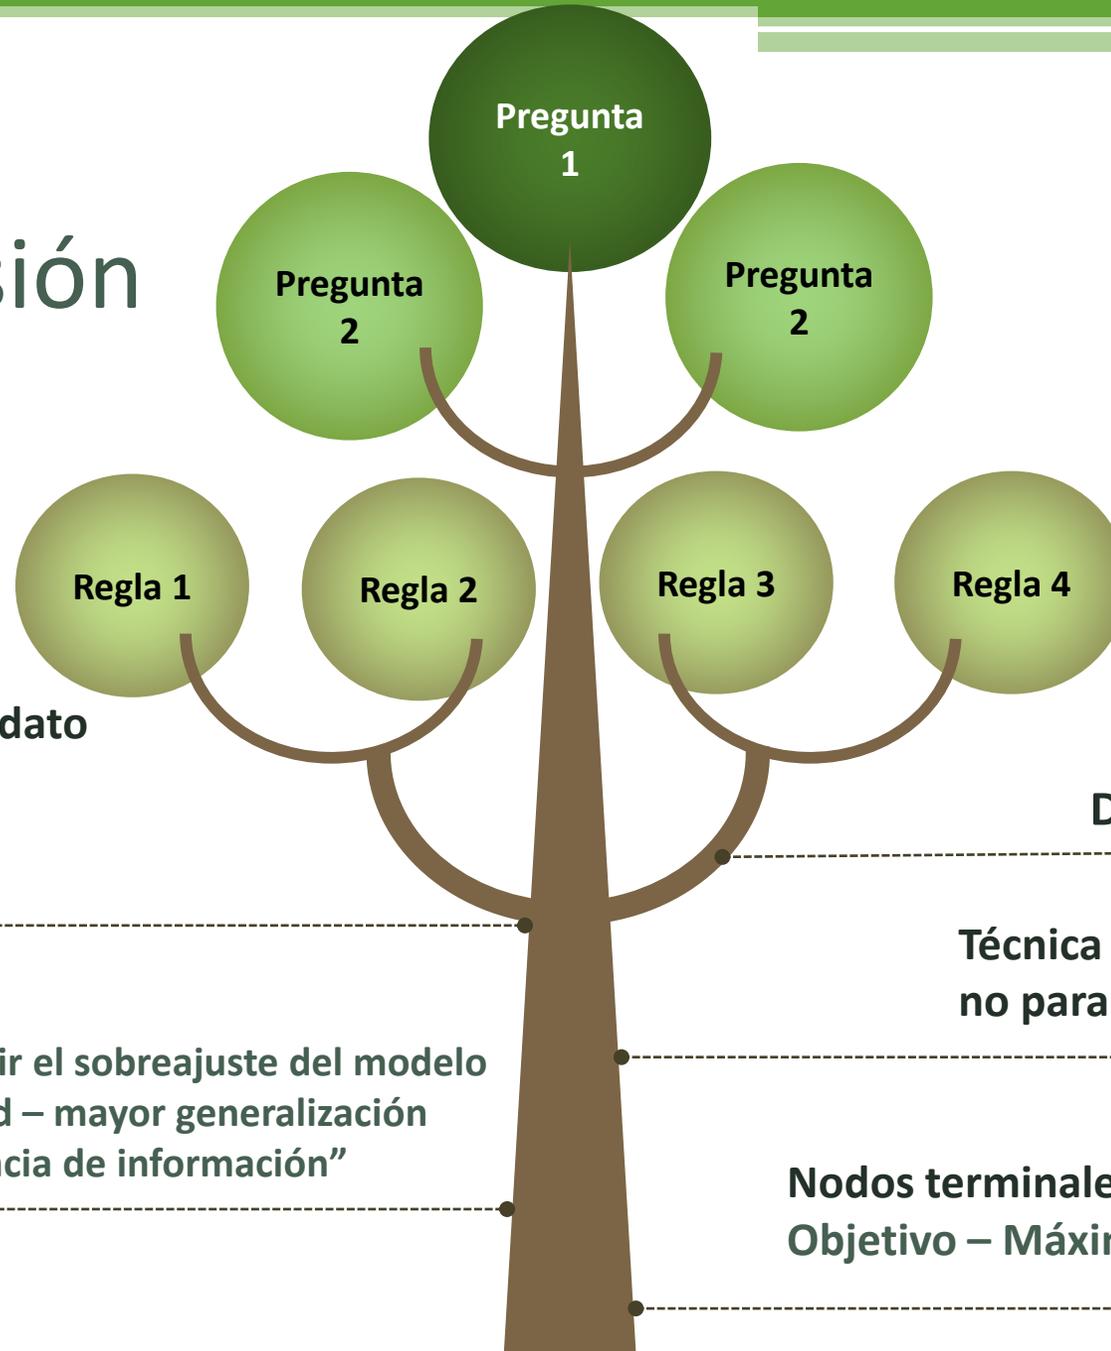
Modelos



Árboles de decisión

Bagging – Boosting – Random Forest

Árbol de decisión



- Robusto a Outliers
- Aplicable a cualquier tipo de dato
- Sencilla interpretación
- Reutilizable

Overfitting

Poda para prevenir el sobreajuste del modelo
Mayor simplicidad – mayor generalización
Técnica de “ganancia de información”

Divide y vencerás

Técnica de clasificación
no paramétrica

Nodos terminales
Objetivo – Máxima pureza



Modelos: *Bagging*

- Muestreo selectivo – Aumento de la performance
- Creación de diferentes modelos usando muestras aleatorias con reemplazo y luego combina y ensambla los resultados mejorando la predicción



Modelos: *Boosting*

- Cada nuevo clasificador presta mayor atención a los datos clasificados erróneamente por los clasificadores anteriores
- Combinación de resultados para obtener un clasificador con mayor poder de predicción

Modelos: *Random Forest*

- Cada árbol contiene una muestra aleatoria de observaciones y es construido con variables seleccionadas de forma aleatoria

Métricas de Rendimiento



- Matriz de Confusión, muestra los resultados de los modelos de clasificación binaria

		Clase Actual	
		NO CHURN	CHURN
Clase Predicha	NO CHURN	TP	FN
	CHURN	FP	TN

Sensitivity

$$\rightarrow TP / (TP+FN)$$

Specificity

$$\rightarrow TN / (FP+TN)$$

Positive Predictive Value

$$\rightarrow TP / (TP+FP)$$

Negative Predictive Value

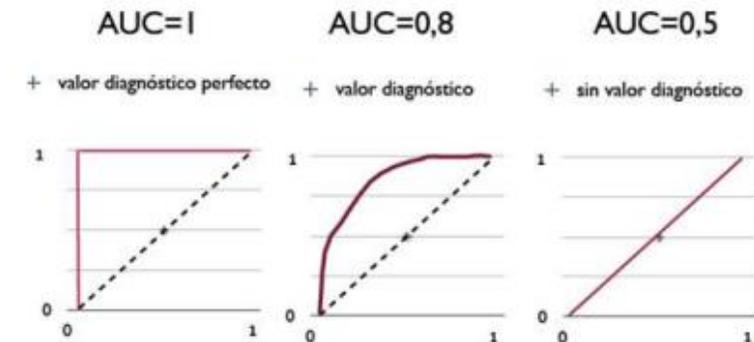
$$\rightarrow TN / (FN+TN)$$

Accuracy

$$\rightarrow (TP+TN) / (TP+FP+FN+TN)$$

AUC - Área bajo la curva ROC - LIFT

- Comparación entre las predicciones correctas e incorrectas del clasificador
- LIFT: Indica la cantidad de veces que mejora la predicción del modelo con respecto al azar





Principales variables seleccionadas con los modelos

CLUSTER 0	1?	CLUSTER 1	0?
VARIABLES		VARIABLES	
ANTIGUEDAD		ANTIGUEDAD	
AVG_CANTIDAD	*	AVG_CAJERO_PPIO_MONTO_ACT	*
AVG_CONSUMO_ACT		AVG_CONSUMO_ACT	
AVG_HOME_BANKING_TRX		AVG_HOME_BANKING_TRX	
AVG_SALDO_ACT	*	CROSS_SELLING	*
EDAD		EDAD	
LAPSO_COMPRA		LAPSO_COMPRA	
LIM_CREDITO	*	MBB	
MBB		MOV90_CTA	
SUM_MBB		RIESGO_SCORE_VERAZ	
MOV90_CTA		SCORE_PROMEDIO	
RIESGO_SCORE_VERAZ		SUM_MBB	
SCORE_PROMEDIO		USO_SALDO_PROPIO_TC	
USO_SALDO_PROPIO_TC		VAR_CANTIDAD	*
VAR_CONSUMO		VAR_CONSUMO	
VAR_CROSS_SELLING		VAR_CROSS_SELLING	
VAR_HOME_BANKING_TRX		VAR_HOME_BANKING_TRX	
VAR_INGRESO_12		VAR_INGRESO_12	
VAR_MBB		VAR_MBB	
VAR_SUM_MBB	*	VAR_MOV90_CTA	
VAR_MOV90_CTA		VAR_SALDO	
VAR_SALDO		VAR_SCORE_PROMEDIO	
VAR_SCORE_PROMEDIO			

Comportamientos diferenciados para cada uno de los *grupos de clientes seleccionados (Clusters)*

Variables:

- Cantidad de compras (transacciones) en los últimos 3 meses
- Saldo en cuenta de los últimos 3 meses.
- Variación de la suma de MBB (Ingreso que deja el cliente al Banco)
- Cantidad de extracciones en cajeros
- Tenencia (en número) de productos bancarios
- Cantidad de compras en los últimos 3 meses

Evaluación de los modelos

VALIDACIÓN CON DATA FUTURA (1 AÑO)



Clases altamente desbalanceadas para ambos clusters para la variable Target (Attrition)



	Churn	No Churn	% Churn
Cluster 0	3.897	254.787	1,53%
Cluster 1	725	227.513	0,32%
Total	4.622	482.300	0,96%

Validación de los modelos con datos a Abril 2016

Modelos Random Forest y Boosting

AUC
96%-97%

Accuracy
95%-99%

Falsos Positivos
60%-77%

LIFT - Primeros 20.000 clientes
11.23

TN, True Negative (Especificidad)

90% (para el Cluster 0 el modelo encontró a 3715 de los 3879 clientes fugados)

El modelo Boosting clasificó correctamente al 23%-42% de los clientes que predijo como Churners

Más probable a abandonar el Banco a un cliente seleccionado al azar

Programa de Retención



+ LIFT + Rentabilidad + Éxito del programa

N: Número total de clientes, 486.922

Pr: Porcentaje de clientes a impactar con el programa de retención (Percentil 8), 8%

Pe: Son los verdaderos positivos que el modelo detectará, es el porcentaje de clientes impactados por el programa que efectivamente serán fugas del Banco, (tener en cuenta que el *Attrition* de la cartera para los *Cluster* 0 y 1 es de 0.96%), 10.22%

e: Tasa de éxito del programa, se asumen 3 escenarios posibles, [10%, 30%, 50%]

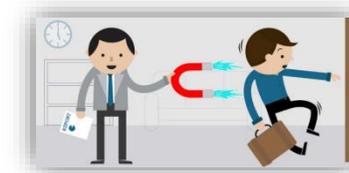
C: Costo del incentivo ofrecido por el Banco, 50 USD

Co: Costo de contactar al cliente, 5 USD

CLV: Valor del cliente para el Banco en caso en que sea retenido, 4000 USD

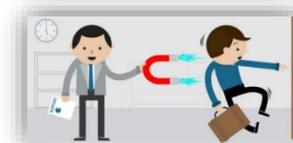
V: Valor del programa de retención (ganancia/pérdida)

$$SV = 486.922 * 8\% * (10.22\% * 10\% * (\$4.000 - \$50 - \$5) + 10.22\% * (1 - 10\%) * (-\$5) + (1 - 10.22\%) * (-\$50 - \$5))$$



- * Aquellos clientes impactados por el programa fueron los de **mayor valor comercial** para el Banco
- * Mayor probabilidad de fuga
- * Mayor LIFT
- * Se busca reducir la tasa de los Falsos Positivos (clientes que permanecen en el Banco habiendo recibido un incentivo)

Resultado e Implementación del Programa de Retención



SUPUESTOS CONSIDERADOS:

1. Distribución constante del CLV
2. Tasa de éxito del 20%
3. Ganancia media de 2MM USD (en 3 meses)

ÉXITO DEL PLAN DE RETENCION ANTE:

- Clientes con gran valor para el Banco
- Alto riesgo de fuga para los próximos meses
- Correcta comunicación, canal e incentivo con el cliente
- Revisión y mantenimiento de los modelos predictivos

		Tasa de Éxito del Programa de Retención					
		10%	15%	20%	25%	30%	35%
Customer Lifetime Value (USD)	\$4.000	\$ -371.595	\$ 414.350	\$ 1.200.294	\$ 1.986.238	\$ 2.772.183	\$ 3.558.127
	\$4.500	\$ -172.621	\$ 712.810	\$ 1.598.241	\$ 2.483.672	\$ 3.369.103	\$ 4.254.534
	\$5.000	\$ 26.352	\$ 1.011.269	\$ 1.996.187	\$ 2.981.105	\$ 3.966.022	\$ 4.950.940
	\$5.500	\$ 225.325	\$ 1.309.729	\$ 2.394.134	\$ 3.478.538	\$ 4.562.942	\$ 5.647.347
	\$6.000	\$ 424.298	\$ 1.608.189	\$ 2.792.080	\$ 3.975.971	\$ 5.159.862	\$ 6.343.753
	\$6.500	\$ 623.272	\$ 1.906.649	\$ 3.190.027	\$ 4.473.404	\$ 5.756.782	\$ 7.040.159
	\$7.000	\$ 822.245	\$ 2.205.109	\$ 3.587.973	\$ 4.970.837	\$ 6.353.702	\$ 7.736.566
	\$7.500	\$ 1.021.218	\$ 2.503.569	\$ 3.985.920	\$ 5.468.271	\$ 6.950.621	\$ 8.432.972

GANANCIA ADICIONAL ante una mejora del 1% en el LIFT

		Tasa de Éxito del Programa de Retención					
		10%	15%	20%	25%	30%	35%
Customer Lifetime Value (USD)	\$4.000	\$ 17.709	\$ 25.568	\$ 33.428	\$ 41.287	\$ 49.146	\$ 57.006
	\$4.500	\$ 19.698	\$ 28.553	\$ 37.407	\$ 46.261	\$ 55.116	\$ 63.970
	\$5.000	\$ 21.688	\$ 31.537	\$ 41.386	\$ 51.236	\$ 61.085	\$ 70.934
	\$5.500	\$ 23.678	\$ 34.522	\$ 45.366	\$ 56.210	\$ 67.054	\$ 77.898
	\$6.000	\$ 25.668	\$ 37.506	\$ 49.345	\$ 61.184	\$ 73.023	\$ 84.862
	\$6.500	\$ 27.657	\$ 40.491	\$ 53.325	\$ 66.159	\$ 78.992	\$ 91.826
	\$7.000	\$ 29.647	\$ 43.476	\$ 57.304	\$ 71.133	\$ 84.962	\$ 98.790
	\$7.500	\$ 31.637	\$ 46.460	\$ 61.284	\$ 76.107	\$ 90.931	\$ 105.754

Conclusiones



- Se trata de un problema del desbalanceo de clases (existe una clase predominante y una minoritaria, fuga de clientes). Relación 99.5% a 0.5%
- Balanceo de casos mediante sub-muestreo, eliminación de registros de clase dominante.
- Problema de la sub especificación del modelo: No contar con todas las variables para poder explicar el fenómeno (existencia de limitaciones y supuestos)
- Ranking de clientes en base a la probabilidad de fuga
- Acciones comerciales de retención, necesidad de bajar el CHURN del 12% anual
- Cambios rápidos en las condiciones económicas del país
- Oportunidad de mejora (+ retención - adquisición)

Conclusiones



- Aquellos clientes que cobraban en el Banco hace 6 meses y que redujeron la cantidad de productos en un 30% y redujeron en más de un 20% la cantidad de artículos comprados, tienen el triple de probabilidad de abandonar el Banco (X3)
- Dentro del grupo de clientes que no acreditaba sueldo en el Banco, aquellos que disminuyeron el saldo en vista en un 25%, no consumieron en más de 2 meses y disminuyeron en un 30% la cantidad de movimientos voluntarios totales, tienen el quintuple de probabilidad de fuga (X5).

Trabajo Futuro



- Inclusión de nuevas variables
- Revisión de los algoritmos utilizados
- Optimización de parámetros de los modelos
- Implementación de nuevos algoritmos. Ejemplo, *gradient boosting* (XGBOOST)

A diferencia del algoritmo Boosting aplicado en el trabajo, el XGBOOST construye arboles de manera secuencial añadiendo a cada iteración el árbol que mejor compensa los errores de los arboles previos. Esto se realiza árbol a árbol.

- *Ensembles* de modelos para explorar diferentes hipótesis sobre los datos
- Predicción de fuga mes a mes (Función de Hazard)
- Afinar supuestos de *Customer Life Time Value*

Dudas, preguntas?



Muchas gracias!

Diego Ariel Oppenheim

