



**UNIVERSIDAD
TORCUATO DI TELLA**

Master in Management & Analytics

Predicción de la demanda y optimización de la
distribución de efectivo en sucursales bancarias

Tomás Maqueda

Tutor: Javier Marengo

Abstracto

En esta tesis, se analiza la problemática de distribución del dinero en efectivo entre las sucursales de una entidad financiera. Vemos que hoy tanto el traslado del dinero en efectivo, como el inmovilizado en las sucursales, generan un costo económico y financiero respectivamente. Los costos económicos de distribución del efectivo representan un 8% de los gastos totales de la entidad financiera, una porción representativa.

Lo primero que debemos hacer para dimensionar el abastecimiento a las sucursales es saber cuál será la demanda de efectivo. Se investigó que existen otros artículos que estudian la previsibilidad de efectivo en los cajeros automáticos (ATMs). Sin embargo, Argentina cuenta con un 50% de economía informal, lo que promueve un alto flujo de caja en los cajeros de atención personalizada. En este sentido, muchas veces los outliers de demanda son acordados entre los clientes y los gerentes de sucursal para poder programar mejor los pedidos de remesas.

En la sección de relevamiento del proyecto, se contactaron empleados de distintas áreas de la entidad para entender y diagnosticar como hoy son los procesos, y cuáles son sus puntos de dolor. También, se consultaron estudios predictivos anteriores, en los que llegaron a la conclusión de que el poder predictivo de cada sucursal es bastante bueno.

Se hicieron análisis exploratorios de datos para dimensionar cada una de las variables, y se entrenaron modelos predictivos para pronosticar la demanda y compararla con los pronósticos actuales. Con la demanda ya conocida, se desarrolló un modelo de programación entera para minimizar los costos. Los resultados del modelo fueron satisfactorios para la organización por lo que seguramente esta tesis se utilizará internamente por la entidad estudiada.

Dentro de la propuesta a la organización, también se planteará crear un equipo de Analytics multidisciplinario para el mantenimiento y la ejecución de estos modelos, cuyos perfiles combinen la visión tanto de eficiencia en operaciones como la de servicio al cliente.

Abstract

In this thesis, the problem of distribution of cash between the branches of a financial institution is analyzed. We see that today both the transfer of cash, as well as fixed assets in branches, generate an economic and financial cost respectively. The economic costs of cash distribution represent 8% of the total expenses of the financial entity, a representative portion.

The first thing we must do to measure the supply to branches is to know what the demand for cash will be. It was investigated that there are other articles that study the predictability of cash in automatic teller machines (ATMs). However, Argentina has a 50% informal economy, which promotes a high cash flow in personalized attention box. In this sense, many times demand outliers are agreed between clients and branch managers in order to better schedule remittance orders.

In the survey section of the project, employees from different areas of the entity were contacted to understand and diagnose how processes are today, and what their pain points are. Also, previous predictive studies were consulted, in which they concluded that the predictive power of each branch is quite good.

Exploratory data analyzes were performed to measure each of the variables, and predictive models were trained to forecast demand and compare it with current forecasts. With the demand already known, an integer programming model was developed to minimize costs. The results of the model were satisfactory for the organization, so this thesis will surely be used internally by the entity studied.

Within the proposal to the organization, it will also consider creating a multidisciplinary Analytics team for the maintenance and execution of these models, whose profiles combine the vision of both operational efficiency and customer service.

Índice

1. Introducción	5
1.1. Dominio	5
1.2. Problema	5
1.3. Contenidos de la tesis	10
1.4. Marco teórico	11
1.4.1. Preparación y análisis exploratorio	12
1.4.2. Análisis predictivo de datos	12
1.4.3. Análisis prescriptivo de datos	14
2. Relevamiento	17
2.1. Entrevistas de trabajo	17
2.2. Seguridad de la información	19
2.3. Revisión bibliográfica	19
3. Análisis exploratorio y predictivo	21
3.1. Preparación de los datos	21
3.2. Exploración de los datos	23
3.3. Predicción de la demanda	27
3.4. Otros experimentos predictivos	30
4. Análisis prescriptivo	31
4.1. Modelo de optimización	31
4.1.1. Conjuntos	32
4.1.2. Parámetros	32
4.1.3. Variables	34
4.1.4. Función objetivo	34
4.1.5. Restricciones	34
4.2. Desarrollo	36
4.3. Otros experimentos computacionales	38
5. Resultados y conclusiones	40
5.1. Resultados	40
5.2. Conclusiones	42
5.3. Reflexiones finales	43
6. Bibliografía	45

1. Introducción

1.1. Dominio

El siguiente trabajo de investigación y análisis de datos se desarrolla dentro de una empresa del sector financiero. El banco en el cual se está trabajando es 16 a nivel nacional, pero con una presencia regional importante. Estratégicamente, se encuentra en un período de transformación digital y mejora continua a nivel procesos, con foco en disminuir los gastos que están por encima de la inflación en los últimos tres años.

Hoy dentro de esta empresa existe en desarrollo un área enfocada en Data Science, que a nivel banco tiene diversos proyectos, desde construir un modelo de gobernanza de las distintas bases de datos hasta proyectos de distinta envergadura y con relacionamiento con todas las áreas del banco. Estos proyectos ponen en práctica metodologías de Machine Learning para predicciones de variables preponderantes para mejorar la toma de decisiones de negocio.

Desde la Dirección de Finanzas, se tomó la decisión de aprovechar la oportunidad de replicar un proyecto ya consolidado y que brindó resultados en la casa matriz en Brasil: predecir la cantidad de efectivo de cada una de las sucursales para lograr, con un modelo de optimización adecuado, disminuir los gastos aplicados a este concepto.

1.2. Problema

A continuación, se presenta la composición del cuadro de resultados de un banco:

- Producto bruto bancario: este concepto abarca todos los ingresos financieros por préstamos y títulos, y egresos por depósitos como plazos fijos. También, dado un modelo gerencial interno, evidencia los gastos del efectivo inmovilizado aplicando un costo de tasa de transferencia en el concepto Efectivo. Por otro lado, expone los ingresos por servicios.
- Gastos: el 60% de los gastos del banco es en personal, y entre los próximos conceptos más importantes a nivel gastos aparece el transporte de caudales.

- Pérdida por operaciones crediticias: el riesgo que corre el banco por prestar a personas y/o empresas es que no le paguen, y, en resumidas cuentas, en esta línea se evidencian las pérdidas por impagos o por mora tardía.
- Ingresos brutos: con una tasa promedio de 8% sobre los ingresos, es el impuesto más caro para el banco dado que se cobra sobre el total de ingresos financieros y comisiones correspondientes al PBB.
- Impuesto a las ganancias: ajustado por inflación, en 2019 el banco paga 15% por impuesto a las ganancias sobre el LAIR. El LAIR es el producto bruto bancario (PBB) menos los gastos, menos las pérdidas por las operaciones crediticias y menos los ingresos brutos.

El Cuadro 1 muestra los resultados 2019 de la entidad en análisis y un análisis de sensibilidad de impacto que se puede generar alterando tan sólo un punto en el nivel de ingresos y uno en el nivel de gastos. La fuente es el área de Finanzas del Banco (valores en MM AR\$):

Concepto	2019		Var		2019	Δ
Producto Bruto Bancario	17,480	-->	+1%	-->	17,655	175
Gastos	-9,017	-->	-1%	-->	-8,927	90
Pérdida por operaciones crediticias	-1,200	-->	0%	-->	-1,200	0
Ingresos Brutos	-1,192	-->	+1%	-->	-1,204	-12
Impuesto a las ganancias	-901	-->	+5.3%	-->	-949	-48
Utilidad neta	5,169	-->	+4.0%	-->	5,375	206
ROE	52.7%				54.9%	2.1%
Índice de eficiencia	-51.6%				-50.6%	1.0%

Cuadro 1: resultados de entidad financiera

Vemos que un impacto de esta índole mejora los resultados de la entidad en +4%/+206 MM AR\$, generando una mejora en el retorno para el inversor (ROE) de +2.1% y en el índice de eficiencia (gastos/PBB) de 1%.

Si analizamos la composición de los gastos de la entidad por concepto armando un diagrama de Pareto como el del Gráfico 1, donde se visualizan los principales conceptos que generan el 80% de los gastos, vemos que entre éstos están sueldos y alquileres. Otro de los principales componentes tiene que ver con transporte de efectivo, que es donde en este trabajo se pone foco.




Gráfico 1: gráfica Pareto de gastos

El proyecto entonces apunta a disminuir lo abonado en concepto de Transporte de Efectivo (401 MM AR\$ total 2019). En este sentido, hoy el banco cuenta con un proveedor principal que es Prosegur, que posee camiones de extrema seguridad (ver Gráfico 2) que trasladan las balas de efectivo. Esta empresa le factura mensualmente a la entidad financiera por diversos conceptos:

- Abono mensual por servicio (tarifa fija) y por cantidad de viajes determinada (el exceso tiene un adicional).
- Cantidad transportada: volumetría tanto en pesos como en moneda extranjera tienen una comisión.
- Traslados: tanto ingresos como egresos a sucursal tienen costo por traslado dentro del Área Metropolitana de Buenos Aires (AMBA). Adicionalmente, en los traslados entre sucursal y sucursal se adiciona un traslado al Tesoro, para controlar que los billetes estén en el estado adecuado para circular.
- Aviones: en el caso de sucursales en el interior, se utiliza la vía aérea para el traslado, lo cual al ser más caro obliga a las sucursales a tener un stock que atienda

demandas de más tiempo. Por otro lado, en este tipo de traslados tendrá preponderancia la denominación de los billetes porque el volumen total se cobra.



Gráfico 2: vehículo de la empresa transportadora Prosegur

Adicionalmente a los \$ 410 MM que paga el banco por estos conceptos en 2019, el efectivo inmovilizado tiene un costo financiero, que por los modelos internos que maneja el banco se paga con una tasa de transferencia representativa a las posibilidades de inversión a un día en gran parte. Si el dinero en vez de estar en billete estuviera en la cuenta del BCRA del banco, se podría invertir en instrumentos como LELIQ o pases. Este concepto está reflejado en la línea de PBB del cuadro mostrado anteriormente.

Si se hace una evolución mensual del inmovilizado (ver Gráfico 3), veremos que tiene dos componentes principales: volumen y tasa. Vemos que, por ejemplo, en diciembre los gastos fueron los mismos que en abril con un 30% más de volumen.




Gráfico 3: Evolución mensual de volumen y costo del efectivo inmovilizado

Amerita visualizar que aumenta mucho la demanda hacia octubre/noviembre acompañado particularmente de las elecciones presidenciales, y también hay picos en diciembre y enero por la demanda para el período vacacional. Los períodos en los cuales la tasa estuvo más alta fueron a mediados de año, cuando se intentó frenar la demanda de dólares minorista a partir de la suba de tasas y se llegó a pagar hasta 50% por un plazo fijo.

En el caso de dólares, este gasto tendrá asociada una tasa en USD por lo que el inmovilizado tendrá costos menores pues la tasa en USD históricamente es menor a la de pesos.

El desafío es mejorar el circuito de distribución disminuyendo al mínimo el cash out. Este concepto es quedarse sin stock en cajeros, así sea automáticos o manuales de cada sucursal.

Cada sucursal tiene tres lugares donde puede alojar el efectivo: los cajeros electrónicos, la caja misma y el tesoro de la sucursal. Las sucursales atienden de 10 a 15, y donde existe mayor cantidad de movimientos es en los cajeros electrónicos (ATM) que operan las 24 hs. Dependiendo de la ubicación y el período del mes, los cajeros tendrán más o menos operaciones. Por ejemplo, existen ATMs cerca de bancos públicos como el Banco Provincia, que pagan un alto volumen de asignaciones y pensiones, que suele pasar que se quedan sin stock y deben recurrir a los cajeros del banco en tratamiento.

En lo referido al horario de recepción o salida de remesas, terminología utilizada para el flujo de dinero que entra o sale de la sucursal respectivamente, todas las sucursales reciben o liberan efectivo por la mañana. El saldo que sale pernocta (pasa la noche) en el tesoro y sale a primera hora de la mañana. A partir de Enero 2020, el Banco se decidió a comprar dos camiones propios para complementar el trabajo realizado por Prosegur.

Por otro lado, en los cajeros manuales se suele ver mayor volumen de jubilados y clientes que operan sin tarjeta de débito. Existen algunas sucursales que tienen más

clientes jubilados que tienen su calendario de cobro, y que mensualmente asisten a la sucursal el día correspondiente a retirar sus fondos.

Muchas veces los gerentes de sucursales también tienen conocimiento de algún movimiento en particular de alto monto.

1.3. Contenidos de la tesis

Los contenidos que se trabajaron en el transcurso de esta tesis son los siguientes:

0. **Propuesta:**

En Diciembre 2019 se presentó una breve propuesta del trabajo en cuestión, poniendo foco en los conceptos principales que se tratarán a lo largo de este proyecto.

1. **Relevamiento:**

La primera parte del trabajo es un trabajo de campo: entendimiento de qué es lo que se va a estudiar, quiénes van a ser los entrevistados dentro de la compañía, cuáles son las mejoras de mayor impacto donde se va a estar estudiando y el equipo de trabajo que será responsable de esta tesis.

2. **Análisis de Datos:**

La segunda parte tiene que ver con la obtención y el análisis exploratorio de la información de la firma acorde a las necesidades del proyecto. En este sentido, también se debe conservar la confidencialidad de la información, por lo que se utiliza información modificada a partir de información real, para poder tomar dimensión del ahorro posible con este proyecto. Recordemos que estamos hablando de traslado de dinero físico, por lo que la confidencialidad y los cuidados de la información tienen que ver con la seguridad física de las sucursales.

En la preparación de los datos utilizamos Data Cleansing, que atraviesa una serie de controles en los datos (exactitud, completitud, formato, consistencia, etc.) con el objetivo de asegurar la limpieza de los datos para aprovecharlos al máximo. También, se analizan los datos de forma tal de tener alguna base para la segunda etapa de selección de variables relevantes en el modelo de predicción.

Otro foco del análisis es la predicción de la demanda, donde se parte de una base de saldos diarios por sucursal, del cual debemos excluir las remesas. En este campo, se prueban modelos de regresión y se analiza la performance de éstos para establecer una base predictiva sólida sobre la cual apoyarse para la toma de decisiones. Algunas variables que consideraremos inicialmente como importantes son:

- Ubicación de la sucursal y/o código de sucursal: es importante saber si existen otros cajeros cerca y cada zona tendrá una demanda asociada.
- Factores climáticos: se experimentará agregar los días de lluvia como parte del modelo.
- Cash out: entendiendo que los días de cash out se quebró el stock en el ATM, nuestro modelo considera esta variable.
- Periodicidad: el día del mes y de la semana se tienen en cuenta inicialmente en la predicción.

Otra parte del trabajo donde se pone más foco es el armado del modelo de optimización. Con las técnicas de modelado de Programación Lineal Entera, se construye una función objetivo de minimización de costos financieros y de proveedores con las distintas restricciones de flujo correspondientes por sucursal, y entendiendo que el cash out debiera al menos conservar el nivel actual o mejorarlo. La tecnología que se aplicará en esta optimización es el software de IBM Cplex, con el lenguaje de programación Python, el cual es flexible para poder experimentar con el modelo adecuándolo a necesidades del negocio.

3. Conclusiones y revisiones finales:

Una vez realizado el estudio y obtenidos los resultados, se obtienen conclusiones del trabajo realizado. Desde ya, el banco anticipó que siempre quiso implementar un sistema optimizador por lo que es esperable que este proyecto tome relevancia para la firma.

1.4. Marco teórico

En esta sección, se describe el trasfondo teórico aplicado en las secciones de análisis de datos. Podemos dividirlo en tres secciones: Preparación y análisis exploratorio de datos, predicción y optimización.

1.4.1. Preparación y análisis exploratorio

En este sentido, se utilizaron principalmente tres conceptos a la hora de preparar, ingerir y explorar los datos:

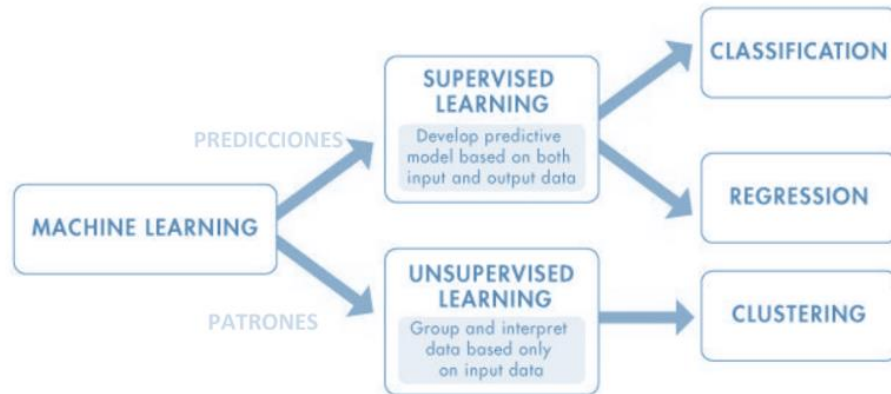
- **Data Cleansing:** son aquellas actividades relativas a proteger y asegurar la calidad de los datos:
 - Validez: se revisan aspectos como el tipo de los datos o claves foráneas.
 - Exactitud: cuán cercano a la realidad es el dato observado.
 - Completitud: cuántos datos faltantes hay en un registro.
 - Consistencia: se revisa que no se presenten contradicciones entre distintos registros del mismo set.
 - Uniformidad: todos los registros deben utilizar las mismas unidades de medida, utilizar los mismos criterios de medición, etc.
- **Data normalization:** el proceso de normalización de datos tiene como objetivos:
 - Eliminar la redundancia en los datos.
 - Aumentar la integridad de los datos.
- **EDA (exploratory data análisis):** tratamiento estadístico al que se someten las muestras recogidas. Consta de dos pasos principales:
 - Medir y describir los datos por medio de la estadística descriptiva: por ejemplo, medias, desvíos, máximos, mínimos, cuartiles, etc.
 - Comparación de caracteres de una muestra por estadística inferencial: aquí suelen haber desde comparativas visuales hasta análisis correlacionales de variables.

1.4.2. Análisis predictivo de datos

Hasta ahora, se vuelcan y analizan con bastante profundidad los datos con los cuales vamos a estar trabajando. Ahora nos toca iniciar el modelado, para lo cual vamos a estar usando conceptos de Machine Learning. Para esto, vamos a hacer una breve introducción de este campo.


Machine Learning o aprendizaje automático es un campo que combina estadística y computación, y tiene el objetivo de desarrollar técnicas para que informáticamente se interpreten patrones de los datos. Y, en este sentido, este aprendizaje suele ser aplicado en contribuir a mejorar el negocio. Tiene dos ramas (ver Esquema 1):

- Aprendizaje supervisado: desarrollo de modelos predictivos basados en el input informativo y el output al que debemos llegar.
- Aprendizaje no supervisado: agrupamiento e interpretabilidad de los datos (clustering).



Esquema 1: técnicas de Machine Learning


Dado que en este caso la variable que debemos predecir es continua, se utiliza aprendizaje supervisado (ver Esquema 2), y, específicamente, regresión. La clasificación se utiliza para predecir variables categóricas o booleanas (binarias).



Esquema 2: técnicas de aprendizaje supervisado

Para construir la regresión, se utiliza la técnica de la partición de la base de datos en dos de forma aleatoria:

- Training Data: estos datos se utilizarán para entrenar los modelos predictivos.
- Testing Data: estos datos se utilizarán para probar la capacidad predictiva del modelo, y evaluando el R cuadrado ver cuán cercano está a la realidad.



Esquema 3: Data splits

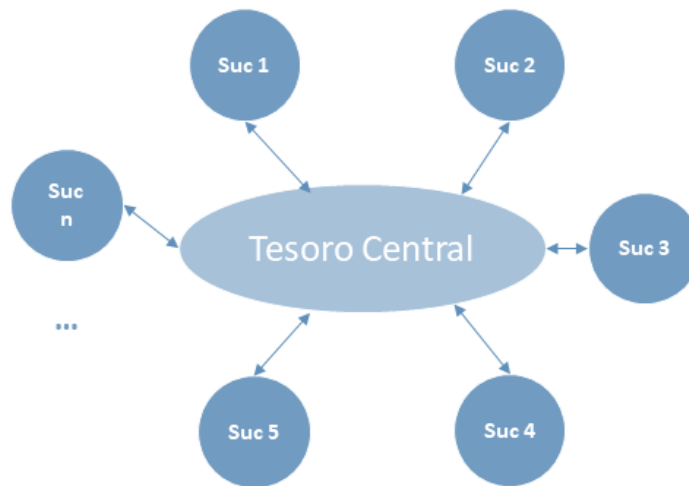
1.4.3. Análisis prescriptivo de datos

El tercer campo de estudio de Analytics que vamos a estar abordando es el análisis prescriptivo. El mismo tiene que ver con toma de decisiones y optimización bajo restricciones de negocios.

En función del diagnóstico del problema abordado, vimos que este campo es el que puede potenciar mayores beneficios para la entidad dado que hoy se está administrando de una forma “artesanal”, y entendemos que es donde hay oportunidades de mejora.

Vamos a utilizar investigación operativa para resolver el problema abordado. Este concepto abarca el estudio y la resolución computacional de modelos matemáticos en los que se optimiza una función sobre un conjunto definido en términos combinatorios (la combinatoria es la rama de la matemática discreta que estudia la construcción, enumeración y existencia de configuraciones de objetos finitos que satisfacen ciertas propiedades).

Dentro de los problemas de investigación operativa, existen varias aplicaciones típicas, y este problema no escapa de una de esas. Una particularidad importante para tener en cuenta es que el movimiento de efectivo se hace siempre desde o hacia el Tesoro Central (ver Esquema 4).



Esquema 4: logística de sucursales de entidad financiera

Operativamente, se piensa en una puesta a punto del sistema diariamente, por lo que, con los datos de la demanda y los costos asociados, debemos ver cuánto nos conviene pedir al día hábil siguiente para cada una de las sucursales, y si amerita un camión.

Este problema también tiene variantes de management de inventarios: tenemos un lead time de un día (tiempo entre pedido y entrega) prácticamente siempre (excepto avión 3 días), tenemos un costo de holding (mantenimiento o costo financiero) y un costo de ordenar (camión y volumetría dentro del camión), y dentro de estas variantes, debemos encontrar el punto donde minimizamos el costo total. Conceptualmente, mientras más efectivo pidamos en las órdenes, vamos a tener más costo de Holding (financiero) y haremos menos pedidos por lo que tendremos menor costo de órdenes (ver gráfico 4).




Gráfico 4: Costos de inventarios

De la misma forma, el modelo debe contemplar un Safety Stock (Stock de Seguridad) de forma tal de poder absorber las incertezas de la demanda o los outliers que se explicaron anteriormente (ver Gráfico 5). De esta forma, el re-ordering point (ROP) tendrá en cuenta estos desvíos que se puedan presentar en el modelo de predicción de la demanda.

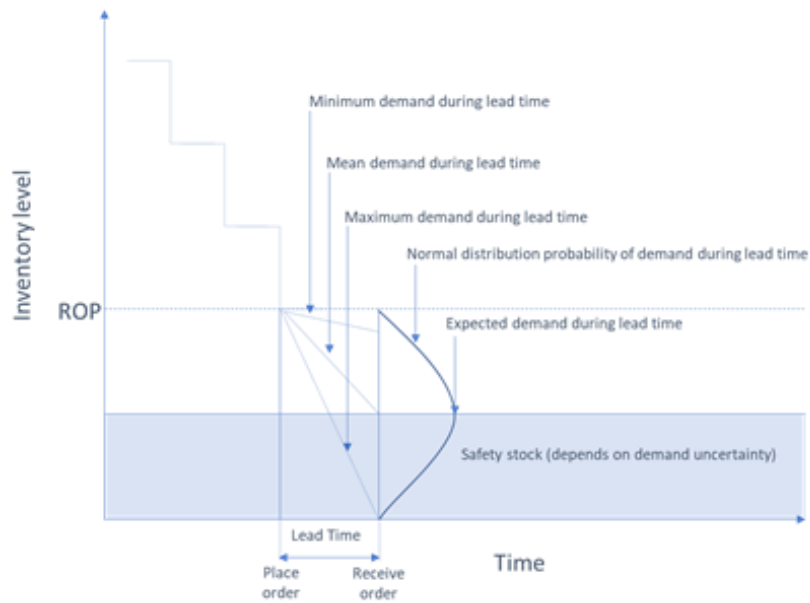


Gráfico 5: ROP y Safety Stock

2. Relevamiento

2.1. Entrevistas de trabajo

Las personas entrevistadas dentro del banco se seleccionaron con el objetivo de que sean las más adecuadas para aportar conocimiento dentro del alcance del proyecto. Muchos de estos encuentros se dieron de modo informal, mientras que con otros se tuvo que formalizar las reuniones. Se vio siempre excelente predisposición a la colaboración, lo cual es uno de los pilares de esta institución en la cual se está trabajando. Las personas que se contactaron fueron:

- Gerente de compras: ex gerente de la Tesorería general, con 15 años de experiencia en la institución, fue la persona de posición más senior o experimentada de las entrevistadas. Estos encuentros (fueron dos) fueron sumamente útiles para entender cómo abordar la problemática y cuáles son los puntos de mejora más acordes a la necesidad del banco y, de esta forma, delimitar el alcance del proyecto definido en la introducción de este trabajo.

El primer encuentro fue formal y duró 45 minutos aproximadamente. Los principales puntos que se hablaron en esta entrevista fueron:

- ✓ Experiencias anteriores relacionadas con esta problemática, donde en varias ocasiones se demostró que el poder predictivo del equipo actual de trabajo tenía bastante concordancia con los resultados obtenidos por modelos sofisticados de predicción. Por eso, de acuerdo a la opinión de esta persona, no tiene mucho sentido profundizar en herramientas predictivas. Sin embargo, comentó que existe la necesidad de un optimizador. Nunca se pudo implementar por cuestiones presupuestarias, pero hay interés desde hace mucho tiempo de parte de toda la dirección.
- ✓ Proveedor principal (Prosegur) y los ítems principales que factura a la entidad.
- ✓ Indicadores que se monitorean de la temática tratada en esta tesis.
- ✓ Particularidades de cada sucursal: un ejemplo que dio el entrevistado fue una sucursal ubicada en frente de un Banco Nación. Cuando aumenta la

demanda de efectivo por asignaciones extraordinarias del gobierno (en general cobradas en Banco Nación), la sucursal de enfrente se queda sin dinero. En consecuencia, quienes cobran con Tarjeta de Débito se acercan a esta sucursal para retirar efectivo y por esto se necesita ingresar remesas extraordinarias. Esto nos dio una idea de que hay eventos particulares que pueden alterar la demanda sustancialmente, y que cada tesorero es quien los conoce.

En el segundo encuentro, esta persona colaboró en el entendimiento del detalle de los procesos logísticos de los tesoreros (costos, billetes, fajas, etc). Este encuentro fue virtual, y se realizó una vez avanzado un poco más el proyecto con preguntas puntuales del proceso diario.

- Analista de métricas: esta persona, con cuatro años de experiencia en el banco, se destaca por el conocimiento de los orígenes de datos adecuados a este proyecto. Fue fundamental este conocimiento para la obtención de ciertas bases con información bastante novedosa dentro del banco (desarrollada el último año) y de suma utilidad para nuestro proyecto. Por ejemplo, las tablas de saldos diarios y de cash out por sucursal se desarrollaron recién en agosto 2019 y están conciliados con la contabilidad diariamente.

El encuentro tuvo una duración de unos 30 minutos. En el mismo, se interpretó en conjunto el significado de los campos y se entendió que métricas son las que se monitorean en la gerencia de operaciones relacionadas a efectivo.

- Analista de finanzas: dentro del mismo equipo de trabajo que el autor de este trabajo, esta persona nos expuso todos los costos asociados a la volumetría que vimos con el analista de métricas. Se realizaron tres encuentros en total. También, se revisaron los modelos y la proyección de tasas de transferencia que se cobran como costos financieros del efectivo de las sucursales, que son coeficientes para el modelo de optimización desarrollado. Se hicieron algunas conciliaciones entre las informaciones del analista de finanzas y el de métricas, sobre todo porque dentro de finanzas se trabaja con información contable y desde métricas la información es operativa, y puede surgir alguna diferencia.
- Analista de Cuentas a Pagar: el último encuentro fue con una analista de cuentas a pagar, que compartió un formato físico de la factura del principal proveedor donde se expone cuáles son los conceptos asociados al costo económico aplicado por la transportadora de caudales. En esta reunión, también nos comunicamos

telefónicamente con el comprador responsable de la cuenta de este proveedor, quien nos comentó las últimas actualizaciones y negociaciones que se estaban llevando a cabo y nos ayudó a entender cuáles eran los principales conceptos abonados por el banco.

2.2. Seguridad de la información

La institución con la que se está trabajando es estricta en cuestiones de confidencialidad de los datos y, por esto, notaremos que hay bastante información encriptada. Se evitarán datos de clientes directos y los datos de los proveedores serán referenciales. Las sucursales están codificadas de forma encriptada, y no se trabaja con datos geográficos. Todos los entrevistados nos transmitieron el estricto cuidado de estos datos, y, sabiendo que este documento es de índole pública, se tuvieron las precauciones del caso y se expusieron sólo datos validados con personal de la institución.

2.3. Revisión bibliográfica

Se relevaron otros estudios para entender si ya existen casos confirmados de éxito en este campo de estudio.

Se analizó un artículo de Žylius G. (2015) para estimar la demanda de ATMs. El mismo utiliza como metodología la máquina de vector soporte con datos similares a los que veremos en este trabajo: estacionalidad, día de la semana, mes, etc. Una particularidad es que al analizar los ATM y no la sucursal por completo, el estudio termina dándonos datos parciales. De cualquier manera, el estudio concluye que lo mejor para estimar la demanda es poner historia corta (si no, el modelo genera overfitting: exceso de información hace que el modelo pierda poder predictivo) y adicionalmente hacer una buena elección de los parámetros de entrada, poniendo principal valoración a los flujos de caja recientes. Y sin duda, quienes más conocen estos flujos de caja por conocer a los clientes son los gerentes de las sucursales. Otros estudios confirman también el valor de los efectos del calendario y la estacionalidad en la predicción.

Otro artículo que se puso en análisis es “Cash Forecasting: An Application of Artificial Neural Networks in Finance de Kumar (2006)”. El objetivo es pronosticar la demanda de efectivo de los ATMs, a partir de la metodología de redes neuronales. Estos algoritmos lograron mejores resultados que la máquina de vector soporte. De cualquier manera, destaca que eventos climáticos, espectáculos, temporada de festivales y comportamiento del mercado también son factores que varían la demanda de efectivo.

Otro paper visto fue “A Methodology to Improve Cash Demand Forecasting for ATM Network de Darwish (2013)”, donde también se puso en práctica redes neuronales y se llegó a resultados buenos, pero siempre tomando las mismas consideraciones del mes anterior.

Nuestro país y en particular los bancos, se destacan por tener también una demanda fuerte de efectivo en cajeros manuales, lo cual está atado al calendario jubilatorio y de otras provisiones que tienen varias personas que cobran sin tarjeta de débito. También, el hecho de que prácticamente la mitad de la economía del país sea informal hace que muchos trámites que tienen movimiento de efectivo se hagan en cajero manual en vez que ATM. Por esto, inicialmente tenemos la hipótesis de que nuestra mejor predicción la podremos conseguir confiando en cada tesorero que conoce los movimientos reales no sólo de su sucursal, sino de las sucursales que lo rodean, como vimos en la entrevista con el gerente de Tesorería.

3. Análisis exploratorio y predictivo

3.1. Preparación de los datos

Se cuenta con una base de datos histórica de los saldos de los meses de Noviembre y Diciembre 2019 y Enero 2020 de cada una de las sucursales. Existe un área de automatizaciones y desarrollos dentro de la Dirección de Operaciones que construyó esta base simplificada para hacer seguimiento de los saldos.

La información está clasificada por moneda, por sucursal y por caja o ATM. El Banco en sus sucursales administra cuatro monedas: pesos, dólares, euros y reales. Se verificó la completitud y la calidad de la información y es consistente en estos meses. Incluso se concilió con los saldos contables internos del banco y los resultados obtenidos fueron bastante satisfactorios. La cantidad de registros administrada es de 55 mil.

Los Gráficos 6, 7 y 8 muestran el comportamiento dentro del mes de los saldos.




Gráfico 6: Saldos diarios en sucursal en AR\$ y U\$S de Noviembre de 2019




Gráfico 7: Saldos diarios en sucursal en AR\$ y U\$S de Diciembre de 2019




Gráfico 8: Saldos diarios en sucursal en AR\$ y U\$S de Enero 2020

En el caso de pesos argentinos, el comportamiento de Noviembre y Diciembre indica que, a partir del sexto día hábil, las sucursales deben ser “cargadas” de efectivo para afrontar compromisos. Al consultar cuáles son las sucursales implicadas en esta demanda, se ve que son las que tienen mayor cantidad de asignaciones previsionales, como ser jubilaciones, jubilaciones italianas (el banco paga a jubilados italianos) y asignaciones universales por hijo, entre otros. Enero tiene un comportamiento más estable entendiéndose que se trata de un período vacacional y de menos movimiento en CABA, donde se ubica la gran mayoría de sucursales.

Los dólares en billete aumentan la demanda a fines de Diciembre de forma acentuada también por la temporada alta turística de Enero.

En cuanto a concentración, de las 85 sucursales y centros de pago totales, en las primeras 30 en cuanto a saldo se aloja el 50% del saldo, lo cual evidencia una distribución bastante equitativa entre las sucursales, aunque no necesariamente con la misma periodicidad o el mismo día del mes.

Adicionalmente, contamos con una base dentro del período establecido de los cash out (quiebre de stock) de los ATMs. El promedio de los Centros de Pago es 2.4%, mientras que en las sucursales el cash out es 1.2%. El perjuicio del cash out, más allá del servicio a los clientes, es que el Banco Central de la República Argentina (BCRA) hace un ranking de sucursales de cash out donde quedan evidenciados aquellos bancos que tienen un servicio deficiente. Afortunadamente, en el último año el banco en cuestión estuvo entre los tres primeros como mejor banco. Si bien esto es bueno, indica que en el Trade Off entre el servicio al cliente y la eficientización de costos, el banco está cediendo en la segunda.

La tercera base clave en este trabajo es la base de las remesas, donde figuran los ingresos y egresos diarios por sucursal, que solicita cada uno de los tesoreros sobre la base de la demanda y oferta de efectivo. Los pedidos de remesas de los tres meses estudiados tienen un comportamiento bastante similar: en el cuarto día se da un pico en el pedido y luego baja hacia los últimos meses (ver Gráfico 9). Esto ocurre porque naturalmente las sucursales son pagadoras de efectivo los primeros días del mes y son receptoras de efectivo los últimos días.

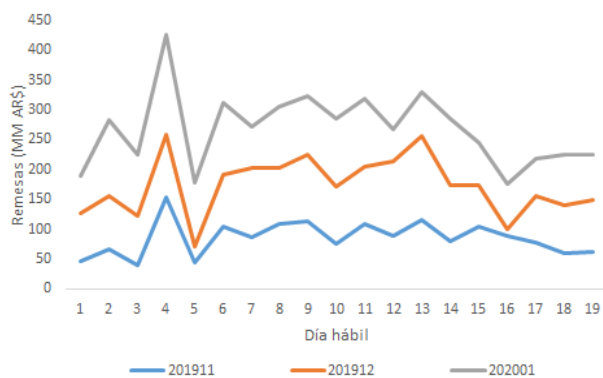


Gráfico 9: Remesas por día hábil

Si se analiza por sucursal los pedidos, vemos que el 75% de las sucursales tuvo un balance de ingreso de remesas mientras que el 25% solicita el egreso de remesas, lo cual da un comportamiento en general de “cobertura” frente a las posibilidades de quedar expuesto a un cash out.

La cuarta base (base histórica de la cual se habla en la propuesta de trabajo) sirve para entender las transacciones que más mueven efectivo y dan un marco para entender la concentración. El 90% de las transacciones que mueven efectivo son de personas físicas en volumen, y en transacciones el 99%. Esto indica que hay casos aislados de empresas de alto monto, que se deben tratar puntualmente. Y la transacción que más mueve efectivo son los retiros en ATM, y en menor medida, los pagos a las asignaciones (AUH, jubilaciones).

Una quinta base se obtiene desde la web pública <https://www.meteoblue.com/es/tiempo/historyclimate/weatherarchive/>. Esta base contiene los días de lluvia, variable que consideramos clave para ver la asistencia a los bancos en el transcurso de estos tres meses de estudio.

3.2. Exploración de los datos

Las cinco bases explicadas en la Sección 3.1 (saldos de sucursales, cash out, remesas y transacciones) se utilizan para construir una BUS (Base Única de Saldos) que se utiliza para armar el modelo predictivo de la demanda. Como fue explicado previamente, se altera la codificación de las sucursales por un tema de confidencialidad de la información.

El cash out aparece por ATM. Cada ATM corresponde a una sucursal y las remesas son por código de sucursal. La BUS tendrá como dato el día del mes, que como vimos en la sección anterior es fundamental para la predicción de la demanda. La base tendrá en total 5.013 registros con las siguientes columnas:

- Día del mes (numérica)
- Mes (numérica)
- Sucursal
- Saldo bruto
- Remesa solicitada
- Saldo neto (Saldo + remesa)
- Cash out (binaria)
- Lluvia (binaria)
- **Demanda**

La demanda de efectivo es lo que vamos a querer estudiar. Se calcula fácilmente haciendo el saldo bruto del día posterior (apertura al día siguiente) menos el saldo neto del día (apertura al día + remesas entrantes - remesas salientes). Este concepto explica cuánto dinero en efectivo necesitan o les sobra a nuestros clientes. El análisis se simplifica a nivel sucursal y, en función de la performance de los modelos predictivos, se analizará si amerita ir a mayor detalle (ATMs, cajeros manuales, tesoro, por ejemplo). Amerita aclarar que la variable “remesa solicitada” es la solicitud cargada el día anterior por el tesorero, que será recibida en el día que se está analizando.

Dentro del armado de base, se hicieron algunos controles de razonabilidad que afortunadamente no arrojaron ninguna inconsistencia. Por ejemplo, uno de ellos fue verificar que, si hubiese una remesa saliente, no puede ser mayor al saldo de la sucursal.

Para empezar a entender los órdenes de razonabilidad de los valores, se hizo una descripción de las variables más importantes (Cuadro 2) y un histograma con todas las variables aprovechando las herramientas de análisis descriptivo de datos que ofrece Python a partir de un Júpiter Notebook.

	Saldo_bruto	Remesa	Saldo_netto	Cashout	Lluvia	Demanda
count	5013.000000	5013.000000	5013.000000	5013.000000	5013.000000	5013.000000
mean	6172463.207810	1108683.050618	7281146.258428	0.025135	0.389587	1123215.509435
std	3167846.237520	3646951.414746	4199124.180980	0.156550	0.487705	3862357.340939
min	133345.000000	-9949257.330000	136334.000000	0.000000	0.000000	-12866582.250000
25%	3931548.000000	47179.700000	4641036.360000	0.000000	0.000000	-429949.610000
50%	5959242.000000	695101.720000	6762965.010000	0.000000	0.000000	652397.000000
75%	8067214.500000	1298389.400000	9126742.200000	0.000000	1.000000	1730900.940000
max	19225115.000000	47878659.580000	50089211.580000	1.000000	1.000000	48911954.480000

Cuadro 2: estadística descriptiva de variables

Vemos que el saldo de las sucursales va desde 130 mil pesos hasta casi 20 millones de pesos, presentando una gran variabilidad tanto en su remesa como en su demanda. Cada sucursal es un mundo totalmente aparte con características propias, pero la generalidad indica que son proveedoras de efectivo a principio de mes y tomadoras de efectivo hacia el cierre de mes. Un cash out de 2.5 % en el total de la base suena un valor razonable (97.5% de las transacciones se ejecutan sin inconveniente).

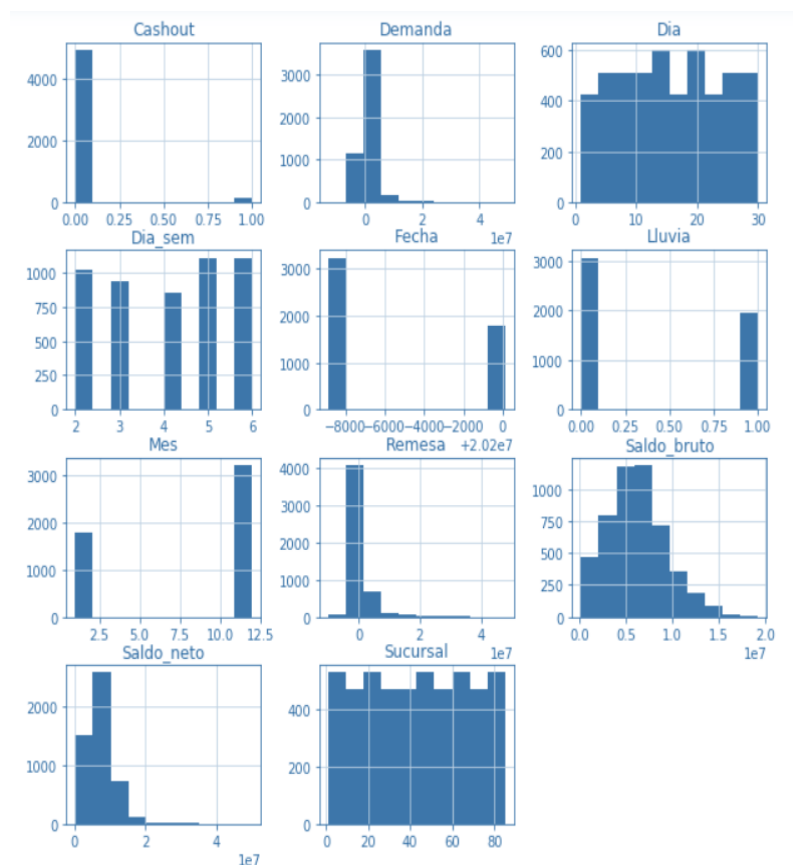


Gráfico 10: histograma de variables

Al hacer el histograma por variable, vemos que algunas variables tienen razonabilidad y otras no tienen mucho sentido, pero nos sirve al menos para darnos idea de la magnitud de los datos con los que trabajamos y los outliers. Vemos, por ejemplo, que la lluvia incidió en 39% de los días y que los pedidos de remesas se dan principalmente los días Jueves y Viernes (5/6) y esto tiene que ver con el aumento de demanda los fines de semana. Se visualiza también el bajo porcentaje de cash out y vemos que el saldo en general está en su gran mayoría en hasta 7 millones de pesos y luego son pocas las sucursales que requieren más de 9 millones de pesos (seguramente esto tenga que ver con las de cobro de jubilaciones u otros casos explicados anteriormente). Cuando vemos los saldos, vemos que la gran mayoría de las sucursales tienen entre 5/10 millones de pesos en la caja como para darnos una idea de la magnitud, algunas tienen menos que eso y pocas son sucursales más grandes con más efectivo. Estas últimas suelen coincidir con sucursales con mucha circulación de efectivo o acceso lejano como la sucursal de Salta. Al trasladar por vía aérea los billetes, los viajes suelen disminuirse y los Tesoros suelen llenar más su capacidad al límite.

Una herramienta útil en este contexto es la matriz de correlaciones (ver Gráfico 11). En este caso, el gráfico de calor a continuación nos indica el grado de correlación entre las variables, siendo el color más claro la mayor correlación y el más oscuro la menor correlación.




Gráfico 11: diagrama de correlaciones

Vemos que la variable que más nos interesará estimar tiene una correlación muy importante con la remesa que se pide diariamente, lo que tiene cierta lógica porque las sucursales que tienen más consumo de efectivo probablemente sean las de pedidos más voluminosos. En menor medida, existe correlación con el saldo neto y lógicamente con la sucursal. Vemos que el hecho de que hay cash out o llueva no correlaciona mucho con la variable de interés.

Contamos con información suficiente para empezar a desarrollar la siguiente etapa: la predicción.

3.3. Predicción de la demanda

A partir del software Jupyter Notebook, con código Python, se hizo la partición de la base de datos y se utilizó la regresión a partir de las variables conocidas del día de la base descripta en la sección anterior.

Se contrastaron dos modelos:

1. Regresión lineal: el primer modelo tiene en cuenta la alta correlación que existe entre la demanda y las remesas cargadas (ver Esquema 5). Este modelo funciona de la siguiente forma:
 - ✓ y es la variable que queremos predecir
 - ✓ B_1 es la pendiente
 - ✓ x es la variable independiente que predice
 - ✓ B_0 es un valor constante que afecta el resultado de Y

$$y = \beta_1 * x + \beta_0$$

Exponemos en el Esquema 5 los resultados obtenidos con una visualización de la correlación entre remesas y demanda.

Coefficiente beta1: 0.97281

Coefficiente de regresión: 0.84219

Error cuadrático medio: 1,160,232

Coeficiente de determinación: 0.85



Esquema 5: resultados de la regresión

Podemos calificar cualitativamente este modelo por los siguientes conceptos:

- Error cuadrático medio (también llamado MSE o Mean Squared Error): para sumar los errores en módulo absoluto, se debe armar una media de éstos al cuadrado y luego aplicarles la raíz. Un valor cercano a 0 (casi nunca alcanzado en la práctica) es bueno. En este caso, el error cuadrático medio es muy grande, pero entendemos que con el nivel de montos que trabajamos es difícil tomarlo como una medición lógica.
 - Coeficiente de Determinación (también llamado R cuadrado): este concepto indica que proporción de la variabilidad total en la variable dependiente está siendo explicada por el modelo. Está entre 0 y 1, y un modelo más preciso estará más cerca de 1. En esta regresión simple, el valor es 85% lo cual es un gran score para un modelo.
2. Holt Winters: este método provee una forma de predecir series temporales de manera muy adecuada en casos en los que hay una estacionalidad y periodicidad. Se destaca por su bajo costo computacional. De hecho, este método es ampliamente utilizado en casos de predicción de demanda diversos, como por ejemplo ventas o demanda de energía eléctrica. Particularmente para el caso de demandas en cajeros electrónicos, hay evidencias de que suelen funcionar bien

combinados con otras técnicas, cómo explica el artículo “Forecasting Cash Withdrawals in the ATM Network Using a Combined Model based on the Holt-Winters Method and Markov Chains” de Mikhail V Aseev, Sergei Nemeshaev, Alexander Nesterov (2016).

Conceptualmente, este modelo construye el pronóstico utilizando parámetros de suavizado de atenuación al promedio de los datos (nivel), a la estimación de la tendencia y a la estacionalidad. Estos parámetros se introducen en distintas ecuaciones que alimentan cada valor, y se pueden modificar sus valores y analizar la performance del modelo. Asignar valor mayor a estos parámetros se traduce en darle mayor relevancia a la historia más reciente.




Gráfico 13: fluctuación de la demanda diaria de sucursal 82

Los resultados de este modelo para una sucursal representativa de la entidad se ven en el Gráfico 13. Vemos que el movimiento de la demanda en la sucursal tiene un comportamiento muy variable, lo cual terminó no dando resultados satisfactorios con este modelo experimentado (R cuadrado de 0.23). Esto ocurre porque al utilizar periodicidad diaria (que es lo que nos importa para la optimización) y estimar la demanda de la sucursal completa (no sólo ATM), hay eventos particulares que hacen que la demanda diaria fluctúe mucho y no tenga un comportamiento estacional, premisa clave de este modelo.

Se realizaron otras pruebas de este modelo utilizando el día de la semana en vez del mes e incrementando los alfa, beta y gamma. En ninguno de los dos casos, se logró alcanzar el R cuadrado obtenido en la regresión lineal.

Se puede pensar que la demanda del día correlaciona muy bien con el pedido de remesa por una cuestión operativa: de alguna forma los Tesoreros ya conocen la misma. Por eso, se analizó el proceso intraday del pedido de Remesas y el mismo funciona de la siguiente forma: los tesoreros cargan las remesas para el día siguiente posteriormente al cierre de caja a las 15 30. Operaciones reúne todos los pedidos y los carga en el sistema centralizado cuyo procesamiento genera los remitos para el armado de los camiones. Como vimos, estos camiones saldrán al día siguiente del tesoro a cada sucursal. Dado que en esta base se analiza la recepción del día de las remesas (el pedido del día anterior) y la demanda del día, podemos concluir que los pedidos correlacionan muy bien con la demanda del día posterior. Tiene lógica que los modelos predictivos para la demanda diaria no hagan otra cosa que confirmar que las remesas correlacionan con la demanda, porque tenemos 85 personas que conocen muy bien los movimientos en función del periodo mensual combinado con que muchas veces se solicita anticipación para los movimientos de mayor dinero. Y esta correlación es mucho más fuerte que cualquier otro patrón que se haya presentado. La anécdota presentada en la Sección 2, en la que vimos que un tesorero tenía conocimiento hasta de lo que pasaba en las sucursales de alrededor, sustenta esta conclusión.

3.4. Otros experimentos predictivos

Se hicieron pruebas de regresiones multivariadas agregando otras variables al análisis y siempre los resultados obtenidos fueron de calidad inferior a la regresión simple con remesas. Otra prueba experimental que se hizo fue estimar la demanda del día posterior suponiendo que conocemos la demanda del día, y llegamos a un R cuadrado de 0.52, lo cual tampoco fue un gran resultado. Una regresión multivariada que mejoró el R cuadrado fue agregando la demanda del día siguiente al modelo actual, llevándolo a 0,86. De cualquier manera, esto en la práctica es imposible dado que uno desconoce la demanda real hasta que no ocurre. Por esto, no vale la pena utilizar este modelo.

Dentro del relevamiento realizado en el banco en cuestión, se identificó que hubo varios estudios predictivos previos, en los cuales se acercaron consultoras especialistas en análisis de datos, y los resultados que siempre se obtuvieron no fueron muy distintos a lo que se obtuvo en este trabajo en cuanto a la demanda de efectivo por sucursal.

4. Análisis prescriptivo

4.1. Modelo de optimización

En este capítulo, se construye el modelo de programación entera con el cual se toman las decisiones operativas más eficientes. Esto se hace en último lugar dado que utiliza información de las predicciones anteriores y los datos conseguidos de la compañía.

Los modelos de optimización suelen iniciarse en un formato simple, con función objetivo de minimización o maximización y pocas restricciones. Luego, en la medida que se estudian las limitaciones del problema, se agregan restricciones. Es importante que quede en claro cuáles de estas restricciones son obligatorias y cuáles son deseables, dado que éstas últimas pueden no ser consideradas o agregadas en la función objetivo como un costo si queremos simplificar el problema. Recordemos que mientras más restricciones tengamos, menor será la performance del programa.

En consecuencia, se buscó un equilibrio entre la velocidad de resolución y la cantidad de restricciones. Por esto, el modelo de programación entera desarrollado asume algunas simplificaciones:

- No considera los posibles paros y/o problemas sindicales que pongan en riesgo la durabilidad del lead time de entrega, considerado fijo en todos los casos.
- Considera hundidos los costos asociados a la recepción de los camiones y la distribución interna por parte de los tesoreros y empleados de la sucursal del efectivo dentro de la sucursal (ATM/Cajas/Tesoro).
- Para el Safety Stock, se considera una porción fija de la demanda en función de las entrevistas. Probablemente, este valor deba modificarse en función de las condiciones de volatilidad macroeconómica, que puedan afectar a la variabilidad de la demanda.
- No se considera el riesgo de seguridad (o costo de seguro) del dinero en sucursal dentro del modelo.
- En lo que respecta a la moneda, vamos a estar entrenando el modelo para pesos únicamente. Hacemos esto porque el costo de tener pesos inventariados es extremadamente mayor que el costo de tener dólares inventariados. Y, adicionalmente, el circulante de pesos es extremadamente mayor al circulante de moneda extranjera.

Estas simplificaciones responden a la aplicación del principio de Pareto: no podremos abarcar absolutamente todo, entonces pondremos foco al producto crítico: el efectivo en pesos.

El modelo de programación entera va a estar basado en la información del proveedor y en los costos de Finanzas, y en la predicción de la demanda de cada una de las sucursales que se correrá diariamente.

Utilizamos programación entera y no programación lineal porque una de las variables que componen la solución es binaria. Lamentablemente esto complejiza la performance computacional. En base a los tiempos que obtengamos de procesamiento, veremos si se puede aplicar la solución computacional óptima o debemos ir por una solución de buena calidad con una heurística. Amerita comentar que el modelo no es lineal, pues el último término de la función objetivo multiplicará dos variables del modelo.

Para describir el modelo, los modelos de optimización combinatoria tienen varias secciones: conjuntos, variables, función objetivo y restricciones.

4.1.1. Conjuntos

- i : el único subíndice que utilizaremos es la sucursal i . Cómo los camiones deberán siempre conectarse con el Tesoro, los camiones con el subíndice de la sucursal serán los que trasladen desde y hasta cada sucursal.

4.1.2. Parámetros

Los coeficientes son los datos que acompañan a las variables y son datos del modelo de programación lineal entera. Se deben mantener actualizados si queremos que el resultado sea relevante.

- D_i (Miles de AR \$): demanda de la sucursal i extraída del modelo predictivo seleccionado en el punto anterior. En este punto, el área de Operaciones también deberá tener en cuenta como dummy del modelo o como diferencial el hecho práctico de que los Tesoreros pueden tener conocimiento de alguna extracción o

depósito como outlier. Es aconsejable revisar diariamente la razonabilidad de los resultados del modelo.

- Cf(Q): Costo del inmovilizado. La fórmula para aplicar es: Tasa de transferencia * plazo transcurrido /365. Esto explica cuánto va a costar en función de las noches que pase en sucursales o en el tesoro central. Se estima en 0.1% por peso incurrido (TNA 36%)
- Cv(AR\$/Miles de AR\$): Costo por monto de efectivo transportado.
- Cti(Miles de AR\$): Costo por traslado a la sucursal i. En general, los traslados son vía terrestre en el AMBA. Existen algunas excepciones de sucursales radicadas en el interior del país que poseen un costo más elevado por utilizar la vía aérea.
- Si(Miles de AR\$): Saldo de la sucursal i en el cierre del batch nocturno (saldo bruto del modelo anterior). En general, hay procesos que impactan en el saldo on-line como las extracciones y hay otros procesos que impactan por lote como los depósitos por ATM (los controla el Tesorero previo a darlos de alta en el sistema). La contabilidad toma todos estos eventos y nos da un saldo de cierre del día, y éste será nuestro input.
- SSi(Miles de AR\$): Stock de seguridad i: el cálculo del safety stock por sucursal se torna un poco complejo dado que la variabilidad como vimos es extremadamente grande, por lo que difícilmente se parezca a una distribución normal. Esto ocurre porque a veces la cantidad de dinero demandada llega a ser negativa y a veces positiva (es decir, no aplica el gráfico serrucho de stock). Ahora cuando tomamos períodos más cortos de tiempo, la variabilidad disminuye y vemos que la gran mayoría de casos no se llega al cash out. El Safety stock es, idealmente, el ROP menos la demanda por el lead time, que definimos de un día. De la demanda, utilizaremos el percentil 98 por sucursal.
- Ci(Miles de AR\$): Capacidad de la sucursal i: este dato fue provisto por la entidad financiera.
- Ctri(Miles de AR\$): Capacidad máxima del camión o del avión: este dato proviene del proveedor y se hace por sucursal en función del acceso posible.
- Ca (%): porcentaje adicional que cobra Prosegur por viaje por excederse del abono diario (6.8%).
- CCa: Capacidad de camiones del abono diario (20).

4.1.3. Variables

Las variables son parte de los resultados del modelo y nos indicarán cuánto y cuándo pedir, y es lo que se carga desde el área de Operaciones en los sistemas de remesas en función de los resultados del modelo:

- Re_i (Miles de AR\$): Remesa entrante de la sucursal i
- Rsi (Miles de AR\$): Remesa saliente de la sucursal i
- Bti (1 si el camión se traslada, 0 en caso contrario): Binaria de traslado.
- Ba : binaria de abono adicional

4.1.4. Función objetivo

La función objetivo es la expresión que debemos minimizar o maximizar dependiendo del problema. En este caso, al hablar de costos, buscamos minimizar la función objetivo y posee los siguientes términos.

$$\text{Mín } \sum_{i=1}^n [(Si + Rei - Rsi - Di) * Cf + Rei * Cv + Rsi * Cv + Bti * Cti] + Ba * (\sum_{i=1}^n Bti - CCa) * Cti * Ca$$

- $(Si + Rei - Rsi - Di) * Cf$: Costo inmovilizado de la sucursal i (Stock por costo). Al saldo bruto, para llegar al saldo de cierre, le debemos sumar la remesa entrante y restar la saliente (si hubiese) y restarle la demanda para entender cuál será el saldo al cierre del día por el cual se le aplicará el costo financiero.
- $Rei * Cv$: Costo por volumen de Remesas entrantes de la sucursal i .
- $Rsi * Cv$: Costo por volumen de Remesas salientes de la sucursal i .
- $Bti * Cti$: Costo por traslado de la sucursal i .
- $Ba * (\sum_{i=1}^n Bti - CCa) * Cti * Ca$: la variable Ba será 1 si nos excedemos del abono y a ese diferencial, se le cobrará el adicional de 6.8%.

4.1.5. Restricciones

Las restricciones son las reglas que debemos cumplir en relación a las variables establecidas en la función objetivo. Cada restricción tiene un motivo de existencia, y veremos que los mismos pueden ser diversos: capacidad, reglas de negocio, flujo, etc.

- La primera restricción es estrictamente de negocio: la carga o descarga de camiones de remesas a primera hora será lo que altera el saldo de cierre del día anterior y confeccionará el saldo inicial neto. El mismo debe cubrir la demanda del día y el Safety Stock definido anteriormente, y esto es lo que decimos una regla de negocio. El no cumplir esta regla nos lleva al riesgo de cash out, pérdida de la calidad de servicio y, en consecuencia, pérdida de clientes o peor rating contra la competencia.

$$R1: Si + Rei - Rsi - (Di + Ssi) \geq 0 \text{ para todo } i$$

- La segunda restricción es un truco típico de los modelos de programación lineal entera con variables binarias. Si la suma de las remesas entrantes y salientes de la sucursal i es igual a 0, tenemos justa evidencia de que no se usará ningún camión pues no habrá necesidad y la minimización de la función objetivo nos indicará que $Bti=0$. En cambio, si es mayor a 0, debemos activar la variable binaria Bti para la sucursal i (valor 1) para cumplir esta restricción. Por eso, en esta restricción, se multiplica este Bti por M , siendo M la máxima capacidad de $Rei + Rsi$, que nunca se podrá superar con la suma de ambas.

$$R2: Rei + Rsi \leq Bti * M \text{ para todo } i$$

- De la tercera a la quinta restricción, se restringe la capacidad tanto de la sucursal como de los medios de transporte en los cuales se trasladan las remesas, con el máximo que se puede almacenar en ambos.

$$R3: Rei + Si \leq Ci \text{ para todo } i$$

$$R4: Rei \leq Ctri \text{ para todo } i$$

$$R5: Rsi \leq Ctri \text{ para todo } i$$

- La sexta y séptima restricción son adicionales para el abono que nos cobra el proveedor. Si el Banco se pasa de los 20 camiones diarios, Prosegur cobra un adicional de 6.8% del precio para el viaje. En la sexta restricción, indicamos que la suma de Bti será siempre mayor o igual a 20 por la binaria que nos indica si nos pasamos. Y la séptima restricción nos indica que, si nos pasamos, debemos activar Ba . Estas restricciones son univocas (no son para todo i dado que aplica suma).

$$R6: \sum_{i=1}^n Bti \geq 20 * Ba$$

$$R7: \sum_{i=1}^n Bti - 20 \leq 65 * Ba$$

- Las últimas restricciones especifican la naturaleza de las variables.

$R8: R_{si} \geq 0$ para todo i

$R9: R_{ei} \geq 0$ para todo i

$R10: B_{ti} \in \{0,1\}$

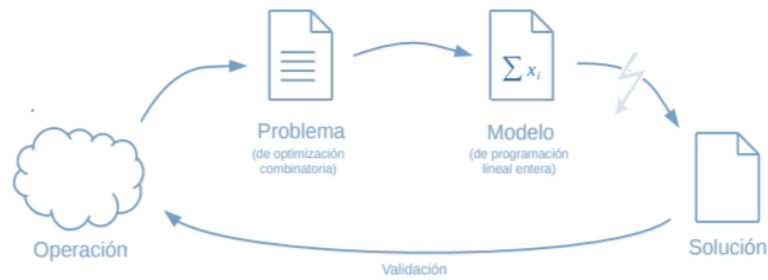
$R11: B_a \in \{0,1\}$

El modelo presentado contempla que los pedidos entrantes se realizarán siempre y cuando la salida de efectivo demandada obligue a la sucursal a estar por debajo de su stock de seguridad. Claramente, esta regla de negocio hace más ineficiente el uso de los recursos pero por decisión corporativa estamos obligados a minimizar el riesgo de cash out. Para las sucursales que piden que se retire dinero, si se envía camión o no depende de las relaciones entre el costo del camión, el costo del volumen transportado y el costo del efectivo inmovilizado (y de si nos pasamos de los 20 camiones).

Para explicitarlo en un ejemplo, el proveedor nos cobra 7 pesos por mil pesos transportados, 2.018 pesos por cada camión. El inmovilizado con una tasa de 36.5% es 1 peso cada mil. Este modelo nunca va a retirar ese efectivo porque es más barato el inmovilizado que retirar el dinero vía remesa marginalmente. En realidad, este razonamiento es correcto en la medida de que haya una demanda sostenida que obligue a solicitar una remesa entrante cada determinado tiempo. A su vez, si suponemos que por algún motivo la demanda se paraliza y pasa a ser nula eternamente, pasados 7 días el costo marginal de sacar el dinero iguala al inmovilizado y seguramente hubiese convenido retirar el dinero. Estas particularidades se deben llevar por fuera del modelo planteado, dado que la periodicidad del ejercicio es diaria.

4.2. Desarrollo

Hasta ahora, abordamos el problema y construimos un modelo para poder resolver el problema de optimización. El siguiente paso es el desarrollo para llevar a cabo una solución tecnológica al problema de turno, y luego llevar a la homologación y producción del sistema. Siempre en la operación se deberá llevar a cabo el mantenimiento de ciertos parámetros, por lo que el flujo es circular y siempre debemos estar en constante revisión de todas las etapas (ver Esquema 6).



Esquema 6: flujo de desarrollo de modelo de programación entera

En este caso, vamos a estar programando la implementación en el paquete CPLEX con el lenguaje Python. Se selecciona este lenguaje por contar con una gran comunidad, y hoy la entidad en la cual se está trabajando está potenciando sus colaboradores para que tengan conocimientos en este lenguaje.

En sí, la programación es un poco más codificada, por lo que se trabaja con una clase que posee todas las características de la sucursal y del medio de transporte que traslada sus remesas (ver Esquema 7).

```
class Sucursal:
    def __init__(self):
        self.id = 0
        self.saldo = 0
        self.traslado = 0
        self.safety_stock = 0
        self.capacidad_suc = 0
        self.capacidad_cam = 0
        self.traslado_unitario = 0
        self.demanda = 0
```

Esquema 7: inicialización de clase en Python

Luego, se lee el archivo para incluir dentro de esta clase el listado de sucursales con sus características. Con el input interpretado, primero presentamos las variables con sus tipologías y los coeficientes que las acompañan en la función objetivo. Indicamos tipologías y límites (las restricciones 4, 5, 6, 7 y 8 son parte de la “lower band” y “upper band” del programa).

Se enuncian las tres restricciones por sucursal utilizando un ciclo For, y finalmente se corre el algoritmo, codificando también las salidas que necesitamos: costo definitivo y remesas entrantes y salientes a asignar por sucursal.

Amerita aclarar que el modelo se corre diariamente. La salida indica el costo diario y adicionalmente informa los resultados de las 255 variables del modelo (ver Esquema 8).

Como vemos, en cuanto a performance, hemos logrado un objetivo satisfactorio al correr el modelo en muy poco tiempo.

```

Default variable names x1, x2 ... being created.
Default row names c1, c2 ... being created.
CPXPARAM_Read_DataCheck 1
Tried aggregator 1 time.
MIP Presolve eliminated 255 rows and 255 columns.
MIP Presolve modified 81 coefficients.
All rows and columns eliminated.
Presolve time = 0.02 sec. (0.15 ticks)

Root node processing (before b&c):
Real time = 0.02 sec. (0.18 ticks)
Parallel b&c, 8 threads:
Real time = 0.00 sec. (0.00 ticks)
Sync time (average) = 0.00 sec.
Wait time (average) = 0.00 sec.
-----
Total (root+branch&cut) = 0.02 sec. (0.18 ticks)
Funcion objetivo: 923091.148
Status solucion: integer optimal solution (101)
BT_0: 0.0
BT_1: 0.0

```

Esquema 8: solución de Cplex

4.3. Otros experimentos computacionales

En el desarrollo de la solución, se encontraron algunos desafíos y experimentos que se podían hacer con el objetivo de conservar la función objetivo, pero simplificar el programa:

- La restricción 6 podría eliminarse y aun así el programa conserva la misma solución óptima. De cualquier manera, no varía sustancialmente el tiempo de ejecución.
- Se está resolviendo un problema de programación entera y no lineal dado que uno de los términos de la función objetivo es cuadrático. En este campo, se nos ocurre que puede linealizarse la función objetivo trabajándolo como una función lineal a trozos (Bti1 para cantidad menor a 20, Bti2 para cantidad mayor a 20. La función objetivo la dividiremos entonces de la siguiente forma:

$$\text{Mín } \sum_{i=1}^n [(Si + Rei - Rsi - Di) * Cf + Rei * Cv + Rsi * Cv + Bti1 * Cti + Bti2 * (Cti + Cta)]$$

Las restricciones que se modifican son las restricciones 6 y 7, y se reemplazarán por varias que tendrán una variable binaria (W1):

$$\sum_{i=1}^n Bti = \sum_{i=1}^n Bti1 + \sum_{i=1}^n Bti2$$

$$\sum_{i=1}^n Bti1 \leq 20$$

$$\sum_{i=1}^n Bti1 \geq 20W1$$

$$\sum_{i=1}^n Bti2 \leq 85W1$$

Este grupo de restricciones lo que hacen es indicar las limitaciones: hasta 20 camiones el costo es el habitual. Cuando superamos esa cantidad, W1 se activa y llegamos al límite de Bti1 de 20 y empezamos a contar de Bti2 (con adicional de 6.8%) cuando superamos el abono.

En nuestro caso particular, no fue necesario utilizar esta reformulación dado que Cplex puede resolver problemas de programación entera con función objetivo cuadrática. En caso de que el solver no contemple esa posibilidad y sólo pueda resolver modelos de programación lineal entera, se deberá usar esta última variante.

En cuanto a la eficiencia de ejecución, notamos que el tiempo de resolución de ambos modelos es similar, y en todos los casos fue de unos pocos segundos. Como práctica de programación dentro de python, se evitaron bucles de ciclos dentro de otros ciclos, lo cual potencia el orden de la complejidad temporal y puede originar demoras en la respuesta del algoritmo.

5. Resultados y conclusiones

5.1. Resultados

Para dimensionar el impacto en resultados de los modelos desarrollados, vamos a correr una simulación completa en el mes de Enero día por día de los que se pidió y lo que se gastó en remesas, y lo vamos a comparar con lo que hubiésemos obtenido procesando los datos en función de lo establecido en la parte de análisis de datos de este trabajo.

Adicionalmente, al ahorro le podremos dar una interpretación para los accionistas como vimos con el ROE y para la eficiencia del banco como fue analizado en la introducción.

El Cuadro 3 expone los valores obtenidos y proyectados para 2020, tanto dentro del proceso actual como con el nuevo con Cplex, y sus diferencias en monto y porcentuales.

Valores en Miles AR\$	Actual	Cplex	Δ	$\Delta\%$
Costo fijo de transporte	-8,000	-8,000	0	0
Costo fijo de camiones	-3,223	-563	2,660	-83%
Por traslado	2,018	2,018	0	0%
Volumen de camiones	1,597	279	-1,318	-83%
Costo por volumetria	-22,114	-14,765	7,349	-33%
Costo promedio por traslado de M AR\$	11	11	0	0%
Volumen trasladado	2,010,369	1,342,300	-668,069	-33%
Total Gastos Ene-2020	-33,337	-23,328	10,008	-30%
Forecast 2020	-500,052	-349,925	150,127	-30%
Costo inmovilizado PBB	-21,591	-20,429	1,162	-5%
Tasa de transferencia promedio anual	43.0%	43.0%		
Tasa nominal mensual	3.7%	3.7%		
Saldo promedio	591,207	559,395	-31,813	-5%
Total reducción PBB Enero	-21,591	-20,429	1,162	-5%
Forecast 2020	-323,868	-306,441	17,427	-5%

Cuadro 3: Beneficios de solución obtenida

Algunas consideraciones de estos datos:

- El Forecast fue constituido con un escenario intermedio con inflación del 50% para el 2020.

- Dentro del Costo Inmovilizado se excluye el Costo de Moneda Extranjera y del dinero en el Tesoro y otros conceptos por los cuales el banco paga efectivo, como ser corresponsales en el interior y exterior.
- El modelo de costo del inmovilizado se hace con la proyección de tasas del 2020 que vimos que se acentuó a la baja en los primeros meses del año 2020. El Gráfico 13 muestra la evolución de las tasas REPO, que es el promedio de pasas interbancarios con el Banco Central de la República Argentina (BCRA).

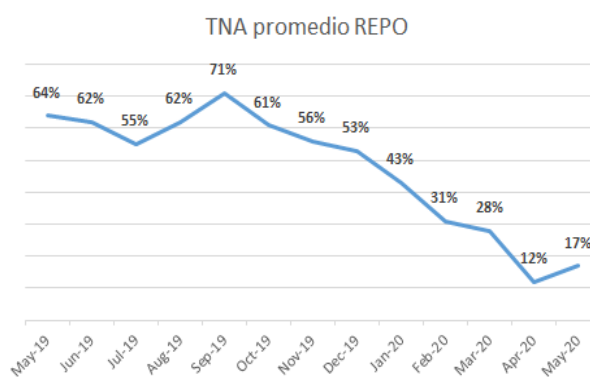


Gráfico 14: evolución mensual tasa REPO

En cuanto al transporte de efectivo, se logra un impacto más preponderante en los gastos que en el costo del inmovilizado. Esto tiene que ver con el contexto actual: tasas negativas contra la inflación. Consideremos que, a la hora de solicitar una salida de remesa, es mayor el costo de traslado que el de tener el dinero en la sucursal.

Específicamente nuestro modelo nos indica que se debe pedir menos camiones con más volumen y así optimizar el costo de viaje. Y también bajar en menor medida la volumetría trasladada. Prácticamente, no recomienda remesas salientes sino esperar a que la demanda que tiende a la salida por las extracciones (por jubilaciones/AUH y otros conceptos que vimos) tome ese efectivo de sucursales inmovilizado. Por esto, tampoco se ve un ahorro sustancial en la parte de inmovilizado (-5%).

Se pronostica que el proyecto ahorra a la entidad financiera en gastos 150 millones de AR\$ en todo el 2020, y, en los conceptos de PBB, 17 millones de AR\$. No se consideran dentro de este análisis los gastos asociados a la capacitación y puesta a punto del sistema.

Si analizamos este impacto a nivel banco, vemos que también es preponderante: los gastos pronosticados para 2020 son de 12.500 millones de pesos, y ahorrar 150 millones de pesos es 1.2% de los gastos totales del banco. Ya vimos cómo impacta un cambio del 1% de gastos en la sección inicial y entendemos que puede ser de gran interés para el comité directivo de la entidad.

5.2. Conclusiones

En el presente trabajo, se visualiza cómo un análisis completo de los datos puede lograr alto impacto en los resultados de una entidad, y en otros indicadores también importantes como el índice de eficiencia y el retorno para el inversor (ROE). Esto es lo que en la entidad se llama creación de valor (resultados sobre Patrimonio). Para esto, se tuvieron que recorrer los tres campos que se analizaron en la charla de seminario (ver Esquema 10)



Esquema 10: campos de Analytics

Estos resultados ayudan a que la compañía muestre eficiencia sin necesidad de tener que recurrir a la reducción de otros gastos importantes como el personal. En consecuencia, indirectamente, como expertos en datos podemos ayudar a conservar más puestos de trabajo en la empresa.

De cualquier forma, el desafío en este proyecto es la implementación y el mantenimiento de las herramientas diseñadas. Es entendible que un proyecto de esta envergadura requiere un cambio en la cultura de la empresa y una capacitación en herramientas de datos que es difícil lograr en el corto plazo. Recordemos que quienes realizan esta tarea son personas muy experimentadas, pero usar las mismas herramientas hace 20 años.

También, mantener los inputs de información con una calidad adecuada nos permitirá obtener mejores resultados. Ya se vio cómo cayeron las tasas y eso impacta directamente en el costo financiero. También, en un país con 50% de inflación probablemente los proveedores estén cambiando constantemente las listas de precios y pueden llegar a cambiar el esquema de

cobro, lo que puede alterar nuestro modelo de trabajo. Por eso, se pensó en Python como lenguaje para tener flexibilidad en el análisis y la optimización.

Otra variable que debemos monitorear es el cash out. Bajo este esquema de trabajo y con el programa implementado, mantenemos el nivel de servicio con los clientes, pero el mismo no debe caer. Por eso, es importante que los analistas involucrados en esta función tengan un rol preponderante en el control del proceso.

Para posteriores trabajos, se puede pensar también en un diseño o una programación de camiones semanal y no diaria para disminuir trabajo operativo. Para lograr esto, deberíamos tener un contexto de mucha mayor estabilidad en el país que el actual. Hoy, creemos que con la volatilidad que hay, es importante tener una programación diaria de logística de camiones.

Otra variable a tener en cuenta es la parte regulatoria: en el contexto actual, la entidad en la que se estuvo trabajando comentó que en los últimos tiempos desde el BCRA no aceptaban cambiar el efectivo por dinero transaccional, y, de esta forma, las entidades no tenían forma de deshacerse del efectivo. Esto ocurrió en cuarentena e hizo que la volumetría aumentara enormemente, aunque el aumento de liquidez generó una baja de tasas. Estas medidas macroeconómicas afectan al proyecto, pero son muy difíciles de modelar en un país como el que se está analizando.

5.3. Reflexiones finales

El presente trabajo está enfocado principalmente en la mejora de los resultados del banco a partir de modelos de datos. La implementación del contenido de esta tesis es un desafío mucho más complicado (a veces, imposible) porque se debe adecuar la cultura y los roles dentro del banco para aceptar un proyecto de gran envergadura como éste.

El arquetipo de cultura organizacional de una institución como la entidad en la que se desarrolla el proyecto es el del Rol, donde lo que importa es cumplir con el estándar de trabajo y es adversa a los riesgos.

Hoy el área de Operaciones no decide a quién enviar el efectivo: los tesoreros de las sucursales son quienes piden. Muchas veces, se pide la salida de remesas al Tesoro (no al BCRA) para evitar el costo directo asignado a la sucursal por inmovilizado, trasladándolo a un costo indirecto del banco. Esto, a fin de cuentas, no cambia el resultado del banco, pero sí el de la sucursal (hoy la gestión de la sucursal se mide principalmente por los gastos directos). Y combatir con este tipo de choques culturales es un desafío que merece su tiempo y lugar.

También existen auditorías y procesos contables asociados al proceso actual, que deberán ser adaptados al nuevo proceso.

Como equipo de trabajo, entendemos que el próximo paso será convencer a quienes gestionan el negocio y la operatoria de que con esta herramienta se benefician todos. Como primer paso, lo primero que debemos lograr es transferir la responsabilidad de los pedidos de la sucursal al área de operaciones. Y, a ésta, agregarle una clara meta de eficiencia en camiones. Como está dado hoy el esquema, no hay un área centralizada que ejecute el proceso completo y creemos que Operaciones es el más adecuado para hacerlo.

Probablemente, se deba construir un nuevo equipo multidisciplinario, con diversos roles, entre estos:

- Analista operativo: quien hoy opera y carga las operaciones en el sistema Core del banco debe seguir haciéndolo.
- Analista financiero o de negocio: monitorear los resultados de los análisis de datos, identificar desvíos importantes, exponer al negocio los beneficios y elaborar el forecast de este gasto.
- Data scientist: mantener la potencialidad de los análisis de datos y adaptar el modelo a las distintas regulaciones o cambios en el negocio.

Pensamos que el equipo debe tener todos los roles porque la ejecución de los procesos debe ser diaria, por lo que se precisa rápida de velocidad de respuesta (vimos en el trabajo lo variable que es la demanda y cómo es más complicado estimar la demanda de un día posterior) y flexibilidad.

No dudamos de que, si se supera la etapa de implementación, el proyecto traerá sus beneficios y probablemente motive a la institución a poner foco en Analytics, que es el campo de principal interés de esta tesis.

6. Bibliografía

- T.H. Cormen. "Introduction to Algorithms", tercera edición, MIT Press (2009).
- "The Python Tutorial", <https://docs.python.org/3/tutorial/>.
- J.M. Stock y M. Watson, Introducción a la Econometría. 3a edición. Pearson Educación (2012).
- N. Agrawal y S. Smith, Springer, The Role of Execution in Managing Product Availability, N. DeHoratius y Z. Ton, en Retail Supply Chain Management, 2da edición (2015).
- Rockin data: curso de análisis de datos en Python
- S. Robbins y T. Judge, Pearson. Organizational Behavior, 15 th Edition (2013).
- L. Wolsey, Integer Programming, J. Wiley y Sons (1998).
- D. Chen, R. Batson y. Dang. Applied Integer Programming (2010).
- G. Nemhauser y L. Wolsey, Integer and Combinatorial Optimization, Wiley Interscience (1999).
- D. Luenberger. Investment Science, Oxford University Press (2014).
- S. Brealey, C. Myers, F. Allen, Principios de Finanzas Corporativas (2016).
- Z. Bodie, A. Kane y A.J. Marcus. Principios de Inversiones, McGraw Hill (2014).
- G. James, D. Witten, T. Hastie, y R. Tibshirani, An introduction to statistical learning (2013).
- M. Friedman, T. Hastie y R. Tibshirani. The elements of statistical learning (2001).
- H. Paul Williams. Model Building in Mathematical Programming, Wiley, 5 ta edición (2013).
- V. Chvatal, Linear Programming, Series of books in the mathematical sciences, Bedford books, (2016).
- M. Bazaraa, J. Jarvis y H. Sherali. Linear Programming and Network Flows (2010).
- K. Talluri y G. Van Ryzin, The theory and practice of Revenue Management, 1ra edición, Springer (2004).
- F. Hillier y M. Hillier, Introduction to Management Science, McGraw Hill, 2da edición (2003).
- M.N. Marz y J. Warren, Big Data: Principles and best practices of scalable realtime data systems, Hanking (2015).
- H. Karau, A. Konwinski, P. Wendell, M. Zaharia, Learning Spark, O'Reilly (2015).

- M. Armbrust. Apache Spark Analytics Made Simple, DataBricks (2015).
- D. Loshin, Big Data Analytics (2013).
- G. Žylius, Evaluation of ATM Cash Demand Process Factors Applied for Forecasting with CI Department of Automation, Faculty of Electrical and Electronics Engineering. Kaunas University of Technology (2015).
- M. Darwish, A Methodology to Improve Cash Demand Forecasting for ATM Network. International Journal of Computer and Electrical Engineering, Vol. 5, No. 4, August 2013, pp. 405-409 (2013).
- A. Kumar, Cash Forecasting: An Application of Artificial Neural Networks in Finance. International Journal of Computer Science & Applications. Vol. III, No. I, pp. 61 - 77 (2006).
- Mikhail V Aseev, Sergei Nemeshaev y Alexander Nesterov, Forecasting Cash Withdrawals in the ATM Network Using a Combined Model based on the Holt-Winters Method and Markov Chains (2016).
- Omar Maguiña Rivero, El método de pronóstico de Holt-Winters (2016).