



**UNIVERSIDAD
TORCUATO DI TELLA**

MASTER IN MANAGEMENT + ANALYTICS

**MODELO DE ASIGNACIÓN DE CASOS DE INCOMING
A UN EQUIPO DE CUSTOMER SERVICE**

TESIS

Santiago Loose

Mayo 2022

Director: Javier Marengo

Resumen

En los últimos años, las empresas de e-commerce han crecido exponencialmente y, debido a sus elevados volúmenes de actividad (ventas, entregas, transacciones, etcétera), suelen generar fricciones con los usuarios finales del producto, quienes tienen preguntas, consultas y quejas, que los llevan a contactarse con equipos de Customer Service para obtener soporte.

Estamos en un mercado muy dinámico, sobre todo en compañías digitales y tecnológicas, ya que constantemente surgen nuevos competidores que brindan servicios similares para dichos usuarios, motivo por el cual se generan ambientes altamente competitivos, y es por esto por lo que toda empresa busca brindar cada vez mejores experiencias para los usuarios de manera tal de destacarse ante la competencia.

El corriente trabajo de investigación parte del análisis de un modelo de Machine Learning llamado Natural Language Programming (NLP) que analiza el texto escrito por un usuario al momento de contactarse con un equipo de Customer Service. Tras analizar dicho texto, es posible determinar la probabilidad de detracción de un determinado caso de incoming en las encuestas de NPS.

Luego de conocer la probabilidad de detracción de un caso de incoming generado por un usuario, la misma fue considerada como input para el desarrollo de diferentes estrategias de asignación de éste a los respectivos agentes del equipo de Customer Service (que son quienes gestionan las consultas de dichos usuarios). De esta manera se proponen una alternativa de asignación de casos que reemplazaría a la estrategia que se realiza actualmente en dicha compañía.

Se llevaron a cabo distintas estrategias para realizar dichas asignaciones, las cuales finalmente se compararon entre sí con el objetivo de encontrar cuál de ellas se debe recomendar a la empresa en cuestión para que pueda implementar en la operación de su equipo de Customer Service.

Estas estrategias se pueden dividir en dos grupos: asignaciones manuales y automatizadas a través de modelos de programación lineal entera de tipo batching utilizando un software de optimización combinatoria.

Independientemente de la estrategia que se utilice, el objetivo consiste en asignar todos los casos de incoming entre los respectivos agentes de Customer Service de manera tal de reducir las probabilidades de detracción de dichos usuarios tras la gestión de su correspondiente consulta o pregunta. La estrategia de asignación resultante es aquella que logra la asignación óptima en la dupla de caso de incoming – agente de Customer Service.

Luego de realizar la comparación de distintas estrategias, se llega a la conclusión de que la asignación más adecuada para usar en la práctica es aquella que surge al utilizar un modelo de programación lineal entera de tipo batching ya que es la estrategia que logra maximizar la función objetivo considerada, logrando buenos resultados, con un tiempo de espera en la cola de gestión del caso de incoming razonable para el usuario.

Abstract

In recent years, e-commerce companies have been growing exponentially, and due to their high volumes of activities (sales, deliveries, transactions, etc) they often generate frictions between the final users of the product, who have questions, queries, and complaints. As a result, this leads them to contact Customer Service teams for support.

We are surrounded by dynamic markets, especially in digital and technological companies since new competitors are constantly emerging and providing similar services for such users. Due to this situation, highly competitive environments are generated, a reason why every company seeks to provide a better experience to the users in order to stand out from the competitors.

This thesis starts from the analysis of a machine learning model called Natural Language Programming (NLP) that analyses written text sent by an user at the moment of contacting Customer Service. After analyzing such text, the model is able to predict the probability of detraction of a given incoming case in the NPS surveys.

After this detraction probability is known, it is considered as input for the development of an assignment model of incoming cases to the respective agents of Customer Service (who manage the user's request). By this way, an alternative is proposed in order to replace the random assignment of cases that the company is currently performing.

In order to make these assignments, different strategies are tested. Those are finally compared with each other to find which one should be recommended to the company in question so that it can be implemented in the operation of its Customer Service team.

These strategies can be divided into two groups: manual and automated assignments through integer programming based assignments using combinatorial optimization software.

Regardless of the strategy used, the objective is to allocate all incoming cases between the respective Customer Service agents to reduce the chances of detraction of the users after the management of their corresponding query or question. The resulting assignment strategy is the one that achieved the optimal assignment in the pair of incoming cases – Customer Service agent.

After comparing different strategies, we conclude that the most appropriate assignment to take into account is the one that results from the use of an integer linear programming model of batching type. This assignment is done since it is the strategy that maximizes the objective function considered, achieving satisfactory results, with a reasonable waiting time in the incoming case management queue for the user.

Índice general

1.	Introducción	9
1.1.	Contexto	9
1.1.1.	¿Customer Service o Customer Experience?	9
1.1.2.	NPS: Net Promoter Score. El número que se necesita para crecer.....	10
1.2.	Oportunidad.....	12
1.3.	Background.....	16
1.3.1.	Descripción del modelo NLP.....	16
1.3.2.	Procesamiento de datos con modelos de Machine Learning – NLP	17
1.3.3.	Ajustes del modelo de Machine Learning inicial y validación de resultados	18
1.4.	Objetivo de tesis.....	23
2.	Análisis de datos.....	24
2.1.	Estructura de los datos.....	24
2.2.	Análisis descriptivo de los datos	25
3.	Estrategias de asignación	38
3.1.	Definiciones.....	38
3.2.	Modelado e implementación.....	39
3.2.1.	Descripción de las variables y condiciones del modelo	39
3.2.2.	Modelado	47
4.	Marco experimental.....	50
4.1.	Tipos de asignación	50
4.1.1.	Estrategias de asignación sin utilizar modelos de programación lineal entera	50
4.1.1.1.	Asignación aleatoria entre todos los Representantes	50
4.1.1.2.	Asignación FIFO al mejor Representante disponible	50
4.1.1.3.	Asignación Greedy según probabilidad de éxito de gestión del Representante, considerando un batching de turno de operación completo	50
4.1.2.	Estrategias de asignación utilizando modelos de programación lineal entera.....	51
4.1.2.1.	Asignaciones de tipo batching, ajustando el tiempo del batch	51
4.1.2.2.	Asignación con máximo tiempo de batching, sin restricciones de equidad entre Representantes de Customer Service	52
4.2.	Procedimiento de ejecución.....	53
5.	Resultados de las estrategias de asignación	55
5.1.	Impacto de resultados sobre la función objetivo.....	55
5.2.	Características de las soluciones obtenidas	59
6.	Conclusiones.....	63
7.	Trabajo futuro	64
7.1.	Posibles alternativas y ajustes sobre el modelo propuesto.....	64

7.2.	Nuevas propuestas a desarrollar.....	65
8.	Referencias.....	67
9.	Anexos.....	69
9.1.	Anexo 1: detalles de las soluciones resultantes tras la ejecución de las diferentes estrategias de asignación en cada una de las instancias consideradas	69
9.1.1.	Cantidad de Representantes asignados en cada instancia, según el tipo de estrategia considerada	69
9.1.2.	Porcentaje de casos asignados en cada una de las estrategias utilizadas, según el perfil del Representante asignado	69
9.2.	Anexo 2: queries utilizadas.....	73
9.2.1.	Query utilizada para descargar incoming con su respectiva información [1]:....	73
9.2.2.	Query utilizada para descargar el monto transaccionado para un determinado cluster de usuarios:	75
9.3.	Anexo 3: software de gestión de bases de datos.....	76
9.3.1.	Tabla de incoming:	76
9.3.2.	Tabla de NPS:.....	76
9.3.3.	Tabla con el detalle del contenido del contacto de usuario:	77

Índice de figuras:

Figura 1.1: Cálculo del NPS (Net Promoter Score), imagen de elaboración propia	11
Figura 1.2: Escenario 1, escenario inicial de asignación (elaboración propia)	13
Figura 1.3: Asignación FIFO (elaboración propia)	13
Figura 1.4: Asignación FIFO, con más de una persona para asignar (elaboración propia)	14
Figura 1.5: Múltiples casos, esperando un tiempo de batching para ser asignados	15
(elaboración propia).....	15
Figura 1.6: Asignación realizada después de un tiempo de batching (elaboración propia)	15
Figura 1.7: NLP - Área bajo la curva ROC del modelo XG Boost – 2020 y 2021	20
Figura 1.8: Matriz de confusión (elaboración propia).....	20
Figura 1.9: Gráfica de la curva de F1 Score, que relaciona el Precision (eje de ordenadas) con el Recall (eje de abscisas) - Dimm [9].....	21
Figura 1.10: Matriz de confusión resultante del modelo XG Boost	22
Figura 2.1: Representatividad del incoming que ingresa en el canal offline sobre el total del incoming de 2020 y 2021	26
Figura 2.2: Incoming de usuarios del canal offline en 2020 y 2021	26
Figura 2.3: Promedio de NPS en canal online y offline, en escala de respuestas de 0 a 10	27
Figura 2.4: Promedio de NPS en canal online y offline, en escala porcentual.....	28
Figura 2.5: Incoming aperturado por país.....	28
Figura 2.6: NPS ponderado según seniority del representante de Customer Service	29
Figura 2.7: NPS ponderado según seniority (ajustado) del representante de Customer Service.....	30
Figura 2.8: Porcentaje de casos de detracción del canal offline.....	31
Figura 2.9: Porcentaje de casos de detracción del canal offline a lo largo de 2020 y 2021	31
Figura 2.10: Incoming generado en el canal offline según el perfil del usuario	32
Figura 2.11: Porcentaje de casos de detracción según perfil de usuario.....	32
Figura 2.12: Incoming de casos según loyalty de usuarios Buyers	33
Figura 2.13: Incoming de casos según el nivel de actividad de usuarios Sellers.....	33
Figura 2.14: Distribución de incoming de detracción en usuarios Buyers según su loyalty	34
Figura 2.15: Distribución de incoming de detracción en usuarios Sellers según actividad	34
Figura 2.16: Distribución de incoming dependiendo del proceso	35
Figura 2.17: Distribución de incoming detractor absoluto, dependiendo del proceso	35
Figura 2.18: Distribución proporcional de incoming detractor por proceso	36
Figura 2.19: Incoming de casos que fueron detractores por país.....	36
Figura 3.1: Cantidad de casos asignados por representante (quienes están ordenados según prob. de éxito decreciente) cuando no hay restricciones de equidad entre ellos.....	43
Figura 3.2: Comparación de cantidad de casos asignados por representante con modelos de asignación con restricciones versus modelo sin restricciones.....	44

Figura 5.1: Porcentaje de variación de función objetivo de la asignación aleatoria realizada por la compañía versus la función objetivo de la estrategia propuesta A4 – 1..... 57

Figura 5.2: Porcentaje de variación de función objetivo de la estrategia propuesta versus función objetivo de la estrategia A5 58

Figura 5.3: Porcentaje promedio de casos asignados en cada una de las estrategias de asignación, según el perfil del Representante 60

Índice de tablas

Tabla 1.1: Área bajo la curva ROC de los distintos modelos NLP – 2020 y 2021	18
Tabla 1.2: Área bajo la curva ROC de los distintos modelos NLP - 2020.....	19
Tabla 3.1: Perfil del Representante según la probabilidad de éxito en gestión de casos. Ver ecuación (1) que determina dicha probabilidad.....	41
Tabla 3.2: Representatividad de la dotación de Representantes según su perfil en base a su probabilidad de éxito de gestión.	41
Tabla 3.3: Perfil del usuario que genera el incoming según el monto de dinero transaccionado	45
Tabla 3.4: Representatividad de cantidad de usuarios según su perfil, determinado por el monto transaccionado previo al contacto.....	45
Tabla 3.5: Matriz de compatibilidad perfil de usuario que genera incoming versus la performance del Representante que gestionará el caso.	46
Tabla 5.1: Comparación de funciones objetivo de cada una de las estrategias ejecutadas en cada instancia	55
Tabla 5.2: Porcentaje de Representantes asignados en cada instancia de tiempo, según la estrategia de asignación utilizada	59
Tabla 5.3: Tiempos aproximados para obtención de funciones objetivo de cada estrategia de asignación considerada, en cada una de las instancias.	61
Tabla 9.1: Cantidad de Representantes asignados en cada instancia de tiempo, según la estrategia de asignación utilizada	69
Tabla 9.2: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A1, clasificados según el perfil del Representante asignado	69
Tabla 9.3: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A2, clasificados según el perfil del Representante asignado	70
Tabla 9.4: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A3, clasificados según el perfil del Representante asignado	70
Tabla 9.5: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A4 - 1, clasificados según el perfil del Representante asignado	71
Tabla 9.6: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A4 - 2, clasificados según el perfil del Representante asignado	71
Tabla 9.7: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A4 - 3, clasificados según el perfil del Representante asignado	72
Tabla 9.8: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A5, clasificados según el perfil del Representante asignado	72

1. Introducción

1.1. Contexto

1.1.1. ¿Customer Service o Customer Experience?

En los últimos años, las empresas de e-commerce han crecido exponencialmente, y debido a sus elevados volúmenes de actividad (ventas, entregas, transacciones, etc.) suelen generar fricciones con los usuarios finales del producto, quienes tienen preguntas, consultas y quejas, que los llevan a contactarse con equipos de Customer Service para obtener soporte.

Estamos inmersos en un mercado muy dinámico, sobre todo en compañías digitales y tecnológicas. Constantemente surgen nuevos competidores que brindan servicios similares para sus usuarios, motivo por el cual se generan ambientes altamente competitivos. Es por esto por lo que toda empresa busca brindar constantemente las mejores experiencias para sus usuarios de manera tal de destacarse ante la competencia.

El corriente trabajo de investigación parte del análisis de un modelo NLP (Natural Language Programming) de Machine Learning que analiza el texto escrito por un usuario al momento de contactarse con un equipo de Customer Service. Tras analizar dicho texto, es posible determinar la probabilidad de detracción de un determinado caso de incoming en las encuestas de NPS.

Luego de conocer el patrón de probabilidad de detracción de un caso de incoming en base al texto que éste contiene, la misma es considerada como input para el desarrollo de un modelo de asignación de casos de incoming a los respectivos agentes del equipo de Customer Service (que serán quienes gestionen la consulta de dicho usuario), de manera tal de suplantar la asignación aleatoria de casos que se realiza actualmente en dicha compañía.

La manera de llevar a cabo dicha asignación consiste en realizar modelos que permitan dirigir de manera inteligente (y no aleatoria) los casos de incoming que generan los usuarios entre los respectivos agentes del equipo de Customer Service para ser gestionados.

Para implementar esta asignación, se realizan y comparan distintas técnicas, partiendo de una asignación aleatoria de casos de incoming, llegando a realizar asignaciones a través de modelos de programación lineal entera de tipo batching con un software de optimización combinatoria, con el fin de maximizar una función objetivo. Esto consiste en asignar todos los casos de incoming entre los respectivos agentes de Customer Service de manera tal de reducir las probabilidades de detracción de dichos usuarios tras la gestión de su correspondiente consulta o pregunta, y para ello, el modelo de asignación seleccionado será aquel que determine qué agente debería atender cada caso de incoming.

Como se mencionó anteriormente, el alto volumen de consultas, preguntas y quejas de los usuarios, hacen que sea necesario contar con equipos de Experiencia al Cliente.

Hace tiempo, esos equipos eran llamados de “Atención al Cliente”, pero como menciona Batra [1], no es suficiente con dedicar solamente atención a los clientes, sino también hacerles vivir una mejor experiencia ante su contacto con la empresa. Es por esto, que actualmente, es muy común confundir lo que es Customer Service con Customer Experience.

Es muy importante comprender qué significa “Customer Experience”, y como explican Meyer y Schwager [2], la experiencia no se limita a atender la consulta del usuario, sino tomar como input todas ellas y capitalizarlas en mejoras en el producto, de manera tal que facilite su usabilidad, y por ende, mejore la experiencia del usuario. Tal es así, que la empresa en cuestión tiene dos equipos independientes: Customer Service y Customer Experience, quienes trabajan de manera sinérgica.

- **Customer Service**, es el equipo que recibe el incoming generado por cualquier usuario, al cual le brinda atención y soporte: satisface dudas, explica funcionamiento de un determinado producto, atiende quejas y brinda soluciones.

- **Customer Experience**, es el equipo que toma el input de Customer Service y lo capitaliza. Por ejemplo: Si un usuario llama para consultar sobre cierta funcionalidad de un producto, el representante de Customer Service le explica cómo funciona el mismo. Ahora bien, por el otro lado, el equipo de Customer Experience es quien analiza y plantea posibles alternativas para prevenir dicho incoming. Ante el ejemplo citado anteriormente, una alternativa para prevenir dicho incoming podría ser la utilización de videos tutoriales que expliquen a los usuarios sobre la funcionalidad del producto. Otra alternativa podría ser mejorar el onboarding de los usuarios cuando comienzan a operar con la compañía, etc.
Una vez realizada la propuesta de mejora, dicho equipo tiene como objetivo monitorear las métricas relacionadas a las distintas casuísticas de incoming, para así entrar en un loop de mejora continua en pos de agregar valor en la experiencia del usuario a través de dichas mejoras.

1.1.2. NPS: Net Promoter Score. El número que se necesita para crecer

Vivimos en ambientes muy competitivos, donde la lealtad de los clientes o usuarios de una compañía es fundamental, y como se mencionó anteriormente, la experiencia que ellos tengan al operar en / con la compañía es muy importante. En base a eso, se pueden diferenciar dos tipos de operaciones distintas:

- Cuando el usuario está operando a través de la compañía, y todo lo que trae aparejado: usabilidad, frecuencia de uso, etc.

- Cuando el usuario tiene un inconveniente y desea solucionarlo: atención y experiencia al usuario, tiempos de respuesta de dichos equipos, etc.

El valor de NPS representa una métrica adoptada por la gran mayoría de las industrias y empresas, el cual mide el nivel de satisfacción de los clientes.

Cuando se comenzó a utilizar esta métrica, las industrias determinaron que para medir dicha respuesta, la pregunta más efectiva y utilizada es la que sigue a continuación:

- ¿Qué posibilidades hay de que recomiende [empresa X] a un amigo o colega?

A la cual se debe responder numéricamente, cuyos extremos de escala son:

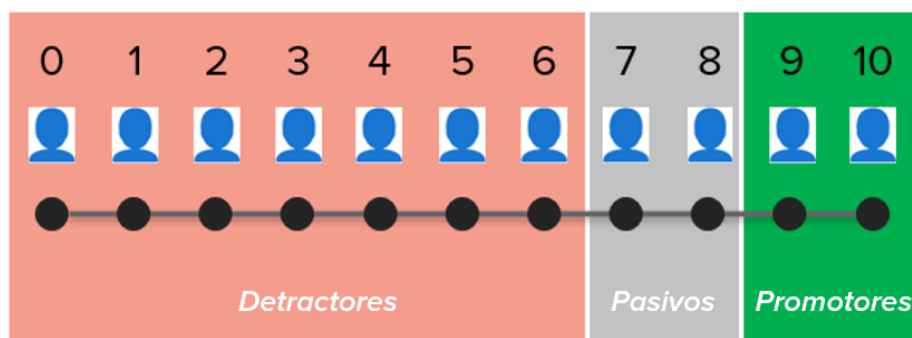
- 0, significa “No hay posibilidades que la recomiende”
- 10, significa “Muy probablemente la recomiende”

En base a la respuesta dada por el usuario, existen tres posibles tipos de usuarios:

- **Promotores:** Aquellas personas que respondieron la pregunta con un valor de 9 o un 10. Son personas que son leales a la empresa y serían capaces de recomendarla
- **Neutros (o pasivos):** Aquellas personas que respondieron la pregunta con un valor de 7 u 8. Son personas que si bien están satisfechas, no están fidelizadas con la marca y estarían dispuestos a irse con el competidor.
- **Detractores:** Son aquellas personas que respondieron la pregunta con un puntaje de 0 a 6. Son personas normalmente insatisfechas, y por esto, no serían capaces de recomendar la empresa

Como mencionan Sahu, Deng y Mollah [3] en el modelo ABCD (o también llamado ABCD Framework), el modelo de negocio de toda empresa que tenga como objetivo llevar a cabo modelos de Customer Experience, será el de disminuir al máximo posible el número de detractores, e intentar convertir a aquellas personas neutras o pasivas en futuros promotores, fieles y leales a la empresa.

En la Figura 1.1 dicho valor se representa gráficamente, donde se puede ver cómo se clasifican los usuarios en base al valor con el que respondan la encuesta.



$$\text{NPS} = \% \text{ Promotores} - \% \text{ Detractores}$$

Figura 1.1: Cálculo del NPS (Net Promoter Score), imagen de elaboración propia

De manera algebraica, el cálculo del Net Promoter Score se representa como se observa en (i).

$$NPS = \frac{\text{Cantidad de promotores} - \text{Cantidad de detractores}}{\text{Total de encuestados}} \quad (i)$$

Según Reichheld [4], dicho valor depende del tipo de industria a la cual se aplique. Es distinto el valor de NPS que obtienen empresas tecnológicas, del que obtienen empresas industriales, del que obtienen empresas de servicios, y esto es porque dependiendo del tipo de empresa e industria, el usuario final puede ser más o menos exigente para con ella.

1.2. Oportunidad

La corriente tesis se elabora en un contexto real, tomando como base de análisis a una empresa que tiene aproximadamente veinte años de experiencia en el mercado local argentino. Hace ya dieciocho años amplió sus horizontes a otros países de Latinoamérica, teniendo presencia actualmente en dieciocho países, siendo representada y gestionada actualmente por más de treinta mil empleados.

Comenzó siendo una empresa que se dedicaba al comercio electrónico y, a lo largo de los años, fue ampliando su espectro pasando a dedicarse también a otros rubros como ser retailing, e incluso incursionando hace algunos años en el rubro Fintech.

Luego de analizar la gestión que realiza el equipo de Customer Service de dicha empresa, se descubre que el incoming generado por los usuarios es asignado aleatoriamente entre los Representantes disponibles del equipo de Customer Service.

El motivo por el cual la asignación de casos se realiza de manera aleatoria es porque nunca se propuso una mejor alternativa. Esto podría estar sujeto a decisiones de negocio perjudiciales para la compañía, ya que se intenta solucionar con un determinado recurso asignado la situación del usuario, cuando se sospecha que no siempre dicha persona es la adecuada para dicha gestión.

Por este motivo, la corriente tesis propone distintos modelos alternativos de asignación de casos de incoming de usuarios a respectivos agentes de Customer Service de manera que reemplacen el modelo de asignación aleatorio que se utiliza en la actualidad.

Cuando se hace referencia a plantear y proponer modelos alternativos de asignación, se parte de la base de que existen distintos tipos de asignaciones posibles, tal como explica Miranda Bront [5].

Con fines didácticos, se plantea a continuación un ejemplo de asignación de contactos generados por un usuario para con un equipo de Experiencia a Clientes, lo que permitirá comprender cómo dicho contacto puede ser asignado a una persona correspondiente para que solucione su consulta.

Imaginemos que se tiene un equipo de Representantes de un equipo de Experiencia a Clientes preparado para atender consultas, reclamos o quejas de los usuarios de una compañía.

Tal como se observa en la Figura 1.2, se puede suponer que ingresa un contacto de un usuario al equipo de Experiencia a clientes. En la margen derecha de la Figura 1.2 se tienen múltiples Representantes disponibles para gestionar dicho contacto, los cuales están graficados según su calidad de atención, que se supone conocida.

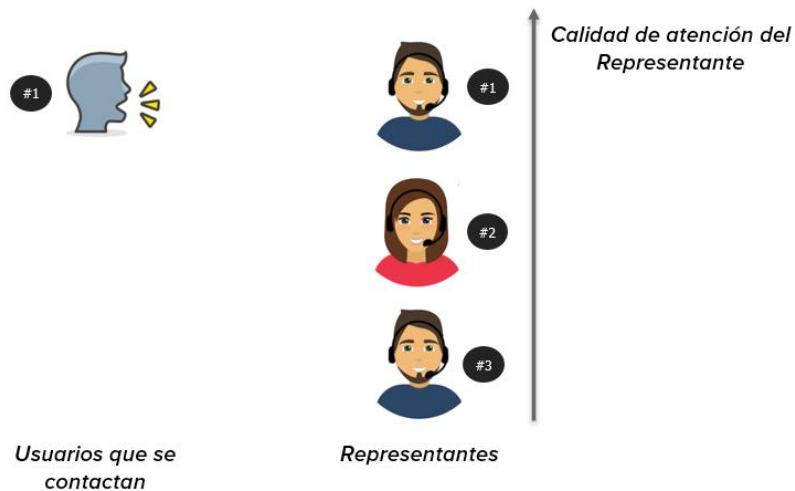


Figura 1.2: Escenario 1, escenario inicial de asignación (elaboración propia)

En pos de brindar la mejor calidad de atención, el contacto generado por dicho usuario #1 será asignado al Representante #1 ya que es quien genera la mejor calidad de atención. Dicho escenario es el que se grafica en la Figura 1.3.

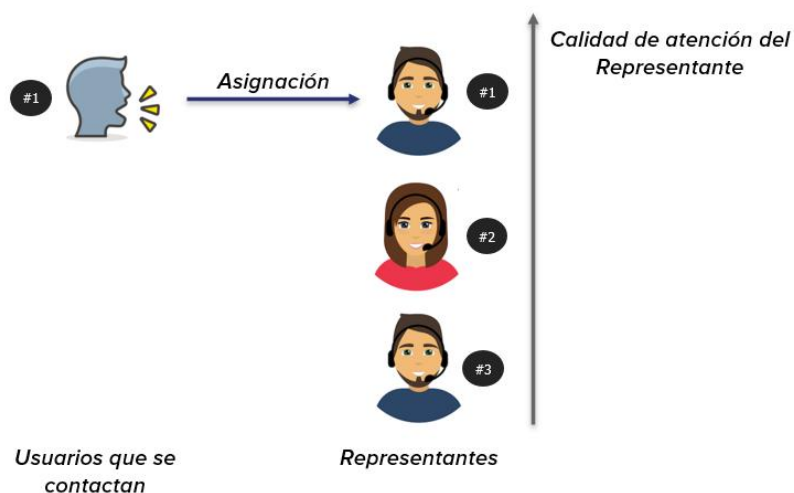


Figura 1.3: Asignación FIFO (elaboración propia)

FIFO significa First in – First out, lo que sería equivalente a pensar que el primero que ingresa es el primero que sale. En el ejemplo, se podría hacer la analogía en que el primer contacto que se genera será el primero en ser asignado con el mejor Representante disponible.

No todos los usuarios tienen el mismo nivel de stress en el momento en que se contactan. Imaginemos que posterior a la asignación realizada en la Figura 1.3 ingresa un contacto de otro usuario con mayor nivel de stress que el usuario #1. En este caso, la mejora manera de asignarlo sería asignando el usuario #2 con el Representante #2, ya que es aquella asignación que generaría el mejor nivel de atención. Este escenario es el que se grafica en la Figura 1.4

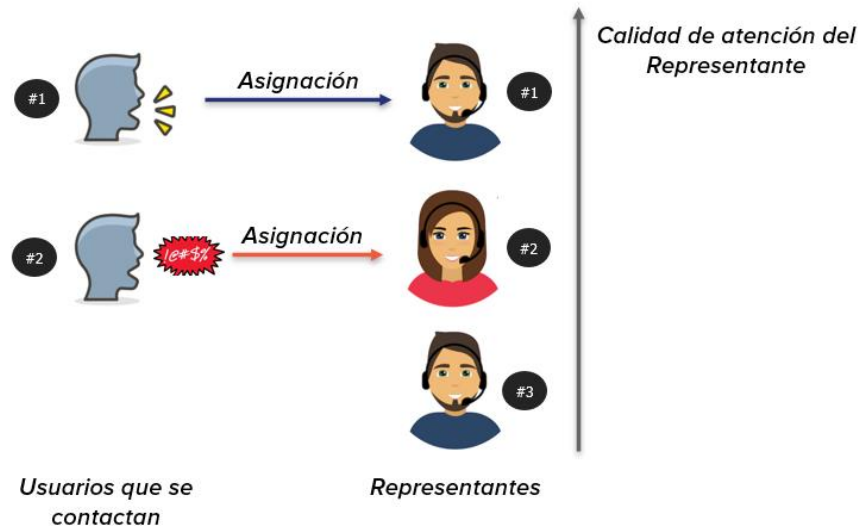


Figura 1.4: Asignación FIFO, con más de una persona para asignar (elaboración propia)

Hasta el momento, a medida que fueron ingresando los contactos, se fueron asignando con el Representante disponible que brindaría la mejor calidad de atención.

Imaginemos por un momento que no se realiza la asignación FIFO como se realizó hasta el momento. Existe un tipo de asignación de casos que se denomina batching. Dicha asignación batching considera un cierto tiempo hasta realizar las asignaciones correspondientes. En el ejemplo, se podría imaginar que se tienen ambos casos generados por los usuarios #1 y #2 sin asignar a ninguno de los Representantes, tal como se observa en la Figura 1.5

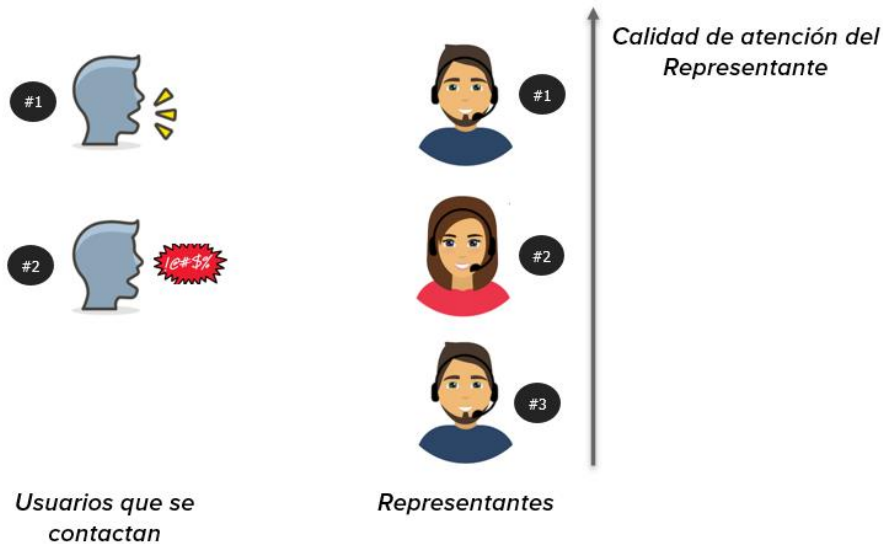


Figura 1.5: Múltiples casos, esperando un tiempo de batching para ser asignados (elaboración propia)

En el escenario presentado en la Figura 1.5 donde los casos aún no fueron asignados a los correspondientes Representantes, la mejor asignación posible sería asignar el usuario con mayor nivel de stress con el mejor Representante disponible. En este caso, se debería realizar la asignación del usuario #2 con el Representante #1 y, por consecuencia, asignar al usuario #1 con el Representante #2, tal como se observa en la Figura 1.6.

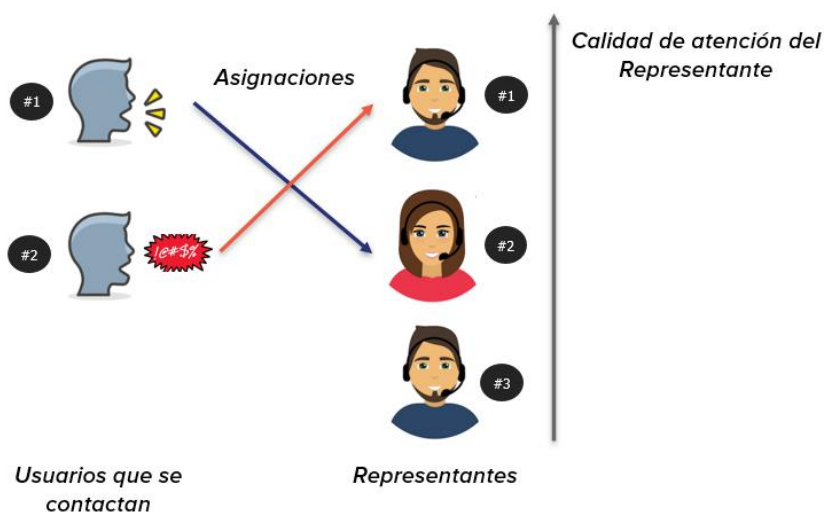


Figura 1.6: Asignación realizada después de un tiempo de batching (elaboración propia)

Si se compara la Figura 1.4 con la Figura 1.6 se observan asignaciones diferentes. Mediante la asignación batching se logró que el usuario más estresado (usuario #2) reciba una mejor atención que si se hubiese asignado según FIFO, como se observa en la Figura 1.4.

La asignación de tipo batching permite que se acumulen casos y finalmente los asigna a todos a la vez. Esto es una desventaja de la asignación de tipo batching ya que existirán usuarios que deban esperar un cierto tiempo para recibir atención. Esto genera un trade off entre dicho tiempo de atención del usuario y la calidad de la asignación realizada.

Las asignaciones de tipo batching permiten obtener iguales o mejores resultados que las asignaciones FIFO. No obstante, se debe considerar que a medida que aumenta la cantidad de casos a asignar (en este caso) deben colocarse restricciones. Las restricciones son aquellas que acotan los resultados posibles de la asignación. En caso de no colocar restricciones podría pasar que surja algún resultado no factible o no conveniente de realizar.

1.3. Background

Para la ejecución de la corriente tesis se toman como punto de partida los resultados obtenidos en la tesis de Maestría de Novo [6] donde se aplica un modelo de Machine Learning de tipo NLP que predice con un 70% de confiabilidad la probabilidad de detracción de un usuario, tras analizar el texto escrito por dicha persona al momento de contactarse con el equipo de Customer Service.

Dentro de los modelos realizados y optimizados en dicha tesis, se encuentran distintos tipos de modelos de Machine Learning:

- Modelos de regresión logística
- Modelo Random Forest
- Modelo XG Boost

Dichos modelos fueron entrenados, optimizados, y finalmente comparados entre sí, para ver cuál de ellos generaba una mejor predicción de usuarios detractores en base, siendo el modelo XG Boost el que logró mejores resultados de predicción de usuarios detractores.

Si bien el modelo tomado como input fue realizado en el año 2021, consideró datos de incoming de usuarios generados en el año 2020. En pos de actualizar los datos, en la corriente tesis se actualizaron dichos modelos con datos correspondientes al año 2021.

Antes de pasar a la ejecución y actualización de dichos modelos de Machine Learning, se procede a una breve descripción de los mismos.

1.3.1. Descripción del modelo NLP

Se puede decir que *Machine Learning* es una disciplina científica que se basa en una serie de algoritmos que utilizan estadísticas para encontrar patrones en grandes volúmenes de datos. Por otro lado se puede mencionar que el *Natural Language Programming* es un campo de las ciencias de la computación, inteligencia artificial y lingüística que estudia las interacciones entre las computadoras y el lenguaje humano.

Como sabemos, los seres humanos nos expresamos y comunicamos de diversas maneras, tanto por escrito como verbalmente. A su vez, dicha comunicación difiere dependiendo del idioma de la persona, de sus costumbres, de su dialecto, etcétera. Es por eso, que un NLP ayuda a resolver la ambigüedad de ciertas oraciones, elimina errores de ortografía y de puntuación, elimina errores de sintaxis y abreviaciones ya que analiza cada una de las palabras escritas y la estructura en un contexto que permite analizar correlación entre caracteres, palabras, oraciones y sus significados. De esta manera se pueden detectar ciertos patrones de comportamiento tras el análisis de palabras independientes.

1.3.2. Procesamiento de datos con modelos de Machine Learning – NLP

Para realizar un modelo NLP, es fundamental conocer el dominio sobre el cual se trabajará, ya que el mismo puede contener caracteres, palabras u oraciones que pueden generar errores de interpretación para el modelado posterior. Entre algunas técnicas que se suelen llevar a cabo como preprocesamiento de datos se pueden mencionar las que se detallan a continuación:

- Eliminar valores duplicados en un dataset. Como suele suceder, es posible que las bases de datos no estén estructuradas correctamente y contengan valores duplicados (más allá que debería asociarse todo a una determinada clave foránea). Como sanity check, se valida que no haya valores duplicados.
- Eliminar valores faltantes o nulos. Los mismos podrían ser generados por errores humanos y podrían generar patrones de comportamientos inesperados.
- Eliminar frases u oraciones predeterminadas, las cuales de antemano se quieren excluir del análisis. Por ejemplo, cuando analizamos el texto que se da en una conversación usuario – representante de Customer Service, se debe eliminar la pregunta previa realizada automáticamente por un bot, como ser “¿Por qué motivo deseas contactarte?”.
- Pasar el texto a minúsculas, para eliminar sesgos del modelo ante ciertas palabras que quizás comiencen una oración, nombres propios, etcétera.
- Eliminar tildes, de manera de no sesgar al modelo ante la ausencia de ellas.
- Tokenizar el texto. Se podría definir como *tokenizar* a la acción de dividir el texto en cada una de las unidades que lo conforman, entendiendo por unidad al elemento más sencillo con un significado propio. En este caso, palabras que conforman cada una de las oraciones que envía un usuario.
- Stemmeo el texto, podría resumirse como la manera en que se reducen las palabras al origen de su significado. Esta técnica permite procesar muchas palabras dependiendo de su raíz lingüística. Por ejemplo: reclamando, reclamé, reclamar, reclamo, son palabras que serán transformadas en ‘reclam’.
- Lematizar el texto, consiste en procesar un grupo de palabras como si fueran la misma. Siguiendo con el ejemplo anterior, se puede decir que se agruparán todas esas palabras dentro de la palabra “reclamar”. Una de las desventajas de esta técnica, es que no comprende ni distingue sinónimos. Por ejemplo: “reclamo” versus “queja”.

- Eliminar stopwords. Para dar un ejemplo, las llamadas stopwords, son las palabras usuales que utilizamos cuando nos comunicamos, como ser “de”, “el”, “la”, “las”, etcétera. De esta misma manera, se pueden considerar stopwords (que deben ser eliminadas) ciertas palabras habituales que forman parte de una comunicación que no agregan valor alguno, por ejemplo, cuando se termina una conversación con la palabra “chau”.

1.3.3. Ajustes del modelo de Machine Learning inicial y validación de resultados

Para el desarrollo de la corriente tesis se expande el dataset del modelo de Machine Learning inicial [6] adicionando información del año 2021. Luego, se valida el mismo siguiendo una serie de pasos que se describe a continuación:

- Se importan las bibliotecas principales en un modelo NLP realizado en Google Colab
- Se importa el dataset a estudiar
- Se nombran las columnas
- Se tokeniza el texto
- Se remueven las stopwords
- Se lematiza el texto
- Se realiza one hot encoding de las variables categóricas
- Se divide el dataset: train y test
- Se genera lista de resultados (listado de comentarios de usuarios, ya tokenizados)
- Se genera el modelo Word2vec, que es una técnica de NLP que trata a las palabras como una representación vectorial de n-dimensiones. A diferencia de la técnica de Bag-of-Words, Word2vec permite capturar no sólo el significado de una palabra en el documento, sino también las similitudes semánticas y sintácticas, y las relaciones con otras palabras.
- Se calcula un vector promedio para cada observación (es decir, de cada case_id)
- Se remueven los NAs, NaN
- Se separan las muestras en train y test de los respectivos vectores
- Se realizan los modelos (Regresión logística Logit, Random Forest, XG Boost)
- Se determinan las métricas de performance

Luego de la ejecución de dichos pasos, se presentan en la Tabla 1.1 los resultados obtenidos.

Modelo	Área bajo la curva ROC (Año 2020 + 2021)
Regresión logística Logit	0,64
Random Forest	0,67
XG Boost	0,68

Tabla 1.1: Área bajo la curva ROC de los distintos modelos NLP – 2020 y 2021

Teniendo en cuenta lo que detalla Caren Marzban [7] sobre el significado de la curva ROC, podríamos concluir expresando a modo de resumen, que el área bajo la curva ROC es un valor numérico que permite medir la capacidad de predicción de un clasificador. Cuando mayor sea dicho valor, mejor será el modelo prediciendo, ya que gráficamente está separando correctamente las clases estadísticas que forman parte del análisis.

A modo de resumen, se puede definir a un modelo XG Boost diciendo que es aquel que consiste en crear varios árboles de decisión que parten de un training-set, quienes luego son entrenados de manera secuencial.

Cada uno de los árboles que forman parte del modelo XG Boost puede ser pequeño y a medida que se va entrenando se va lentamente optimizando. En otras palabras, dichos árboles siempre parten de un árbol entrenado previamente, lo que resulta adecuado para llegar finalmente a una mejor predicción (a diferencia del modelo de Random Forest en donde cada árbol es independiente) por sobre los modelos de Regresión Logística y Random Forest, que parten de una cantidad de árboles de decisión menor, motivo por el cual llevan más tiempo y pasos para la optimización.

Como se observa en la Tabla 1.1, el modelo XG Boost es aquel que resultó como mejor predictor ya que es quien tiene un área bajo la curva ROC mayor, logrando un 68% de probabilidad de confiabilidad a la hora de predecir el comportamiento de un usuario. Para comparar dicho resultado, se presentan en la Tabla 1.2 los resultados obtenidos en el año 2021[6] donde solo se consideraba información relacionada al año 2020.

Modelo	Área bajo la curva ROC (Año 2020)
Regresión logística Logit	0,69
Random Forest	0,69
XG Boost	0,70

Tabla 1.2: Área bajo la curva ROC de los distintos modelos NLP - 2020

Con esta información se podría concluir que tras haber ajustado el modelo inicial con datos del año 2021 se obtiene una probabilidad de detección similar y aceptable.

En la Figura 1.7 se muestra el gráfico obtenido tras la ejecución del modelo XG Boost ajustado (con datos del año 2020 y 2021) que representa el área bajo la curva ROC.

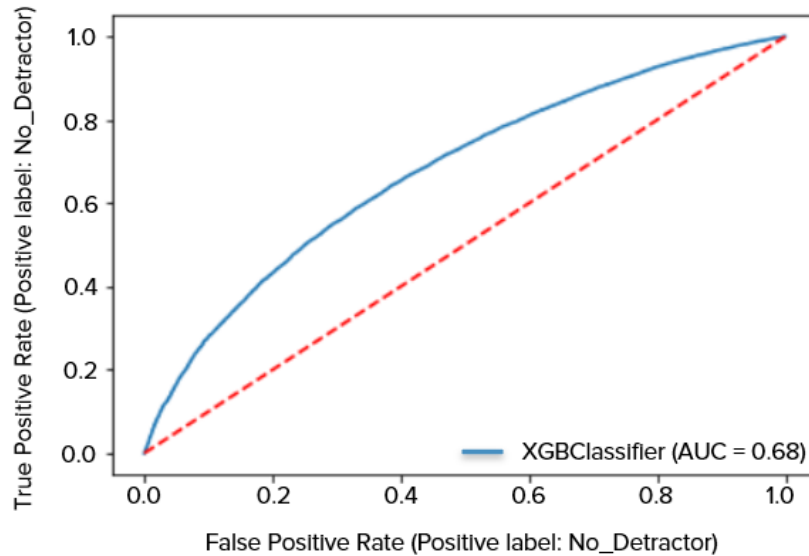


Figura 1.7: NLP - Área bajo la curva ROC del modelo XG Boost – 2020 y 2021

Si bien dicha métrica es una de las más utilizadas en el mercado, existen también otras métricas que al comparar los diferentes modelos entre sí, afirman que el modelo XG Boost tiene mayor capacidad para predecir la detección de un determinado usuario. Dichas otras técnicas son las que se describen a continuación.

Para ello, se debe partir de una matriz de confusión y como detallan Visa, Ramsay y Ralescu [8] se debe partir de una matriz con cuatro cuadrantes como la que se observa en la Figura 1.8.

	PREDICCIÓN NEGATIVA	PREDICCIÓN POSITIVA
VALOR REAL NEGATIVO	A	B
VALOR REAL POSITIVO	C	D

Figura 1.8: Matriz de confusión (elaboración propia)

En donde:

- A, también llamado TN (True negative) representa el número de instancias negativas, clasificadas correctamente como negativas
- B, también llamado FP (False positive) representa instancias negativas clasificadas como positivas
- C, también llamado FN (False negative) representa las instancias positivas clasificadas como negativas
- D, también llamado TP (true positive) son las instancias positivas clasificadas correctamente como positivas.

Con dichos valores, se determinan distintas métricas que permiten comparar distintos modelos entre sí.

- Precisión: permite medir el porcentaje de instancias clasificadas como positivas que realmente son positivas

$$\text{Precision} = \frac{TP}{TP + FP} \quad (\text{ii})$$

- Recall: permite medir la proporción de instancias positivas que son correctamente clasificadas como positivas.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (\text{iii})$$

Accuracy: permite medir el porcentaje de casos que el modelo acertó, es decir lo correctamente clasificado.

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + FN} \quad (\text{iv})$$

- F1 Score: es una métrica que, como puede observarse en la Figura 1.9, permite combinar las métricas de Precision (eje de ordenadas) y Recall (eje de abscisas) combinando el rendimiento de ambas. Se podría decir que son métricas complementarias y equivalentes.




Figura 1.9: Gráfica de la curva de F1 Score, que relaciona el Precision (eje de ordenadas) con el Recall (eje de abscisas) - Dimm [9]

$$\text{F1 Score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (\text{v})$$

Finalmente, luego de ajustar con datos de 2020 y 2021 y ejecutar el nuevo modelo XG Boost, se pueden cuantificar dichas métricas en los valores que se observan en la Figura 1.10.




Figura 1.10: Matriz de confusión resultante del modelo XG Boost

La Figura 1.10 representa cuatro cuadrantes y muestra cuántos de los casos que realmente fueron “detractores” o “no detractores” (eje de ordenadas) efectivamente fueron predichos como tal (eje de abscisas). A modo de ejemplo, en dicha figura se puede hacer foco en los dos cuadrantes superiores, donde se observa la totalidad de casos detractores. El cuadrante superior izquierdo expresa que 2774 de dichos casos, el modelo efectivamente los predijo como casos “detractores”, mientras que el cuadrante superior derecho expresa que 8244 de dichos casos fueron predichos como “no detractores”.

Luego de haber ajustado los modelos NLP ya existentes hasta el momento con datos del año 2021 y realizado las ejecuciones de los mismos nuevamente, se lograron resultados de predicción razonables y aceptables, motivo por el cual se considera seguro utilizar dichas predicciones del modelo XG Boost seleccionado, como insumo para el desarrollo de modelos de asignación en la corriente tesis.

1.4. Objetivo de tesis

Luego de ajustar y validar el modelo NLP con datos de los años 2020 y 2021, la secuencia de gestión que debería efectuar la compañía mencionada en caso de querer implementar la propuesta planteada deberá ser como se detalla a continuación.

1. Se recibe el incoming de un usuario.
2. Se analiza el texto que el usuario envía. Esto se realiza analizando cada uno de los casos de incoming a través del modelo NLP, el cual devuelve como resultado la probabilidad de detracción de dicho caso de incoming.
3. Se toma como input dicha probabilidad de detracción y se plantean diferentes tipos de asignación de dicho caso a su correspondiente Representante.
4. Se realiza la asignación del caso de incoming a un respectivo Representante de Customer Service.
5. Una vez asignado, el Representante de Customer Service deberá gestionar el caso de incoming como lo realiza normalmente.
6. Finalmente, el Representante deberá enviar la encuesta de NPS a dicho usuario.

El objetivo de la corriente tesis es estudiar la performance de distintos modelos de asignación de casos de incoming generados por usuarios a los respectivos Representantes del equipo de Customer Service de la compañía en cuestión, para así minimizar su probabilidad de detracción.

En primera instancia se realizará un análisis descriptivo de los datos. Se estudiarán por un lado los casos de incoming que llegan al equipo de Customer Service, cómo se estructuran y por qué canales de contacto ingresan. Por otro lado, se analizará a los usuarios que generan dichos casos, comprendiendo quiénes son, cómo se clasifican, cómo se comportan y qué tipos de fricciones tienen al operar que generan que necesiten contactarse con Customer Service. Por último, se analizarán aquellos Representantes que gestionan dichos casos de incoming comprendiendo también cómo se organizan en la operación y cómo gestionan los casos.

Luego se describirán las diferentes estrategias de asignación, en qué consiste cada una de ellas y qué consideraciones se deben tener para su implementación. Para ello se deberán describir qué variables se tendrán en cuenta y qué definiciones se toman luego del entendimiento de los datos realizado anteriormente. A modo de ejemplo, se definirá qué criterios se consideraron para agrupar a los usuarios que generan el incoming, a los Representantes, etcétera.

Aquellas variables y definiciones tomadas deberán ser relacionadas entre sí para una posterior implementación dependiendo de las diferentes estrategias de asignación posibles, para finalmente obtener los resultados de cada una de ellas, poder analizarlas y finalmente realizar las recomendaciones necesarias a la empresa en cuestión sobre cuál de ellas es recomendable para que sea implementada en la operación del equipo de Customer Service.

2. Análisis de datos

2.1. Estructura de los datos

Para el desarrollo y elaboración de la corriente tesis, se contó con la aprobación de la empresa en cuestión para el acceso total a los datos, siempre y cuando no se exponga ninguna información sensible de la empresa ni de los usuarios.

El primer paso realizado fue definir el dominio de los datos con los que se realiza el posterior análisis.

- **Temporalidad:** Como se mencionó en el capítulo anterior, si bien el modelo NLP tomado como input fue realizado para el año 2020, con fines de actualización de datos, se sumaron los datos correspondientes del año 2021.
- **Lenguaje / léxico del usuario:** Se acotó únicamente a los países de habla hispana en los cuales la empresa de e-commerce tiene presencia, ya que como se mencionó anteriormente, parte del preprocesamiento de datos en el modelo NLP, tiene que ver con el idioma del usuario, léxicos y palabras que utiliza en el momento de contactarse con Customer Service, etc.

Una vez definido el alcance de los datos a analizar, se procede a la obtención de los mismos a través del estudio y análisis de bases de datos relacionales [10], que es la manera en que dicha empresa tiene almacenados los datos.

Para llevar a cabo la obtención de los datos, se utiliza lenguaje SQL (Structured Query Language) [11] mediante el cual se realizaron las queries que se pueden ver en el Anexo 2. Para llevar a cabo las mismas, fue necesario investigar el software de gestión de datos que utiliza la compañía. De esta manera se puede comprender cómo están estructuradas las bases de datos (y sus componentes) para obtener la información deseada. En el Anexo 3 se muestran imágenes de dicho software sobre cómo se disponibiliza la información para luego ser consumida.

Las bases de datos relacionales que se utilizaron constan de la siguiente estructura:

- Contienen **Registros/Tuplas:** cada caso de incoming que llega al equipo de Customer Service tiene su respectivo ID (Campo que se conoce como Case_id en el dataset).
- A su vez, están formadas por **Atributos:** son valores que se almacenan para cada uno de los registros. Por ejemplo: perfil del usuario que genera el incoming, por dónde realiza el contacto, por qué motivo se contacta, a qué país pertenece dicha persona, qué texto escribe al contactarse, etcétera.
- Mantienen **Relaciones:** conjunto de registros para los cuales se almacenan los mismos atributos. Dicho de otra manera, es la forma a través de la cual se relacionan distintas tablas entre sí al contener información relevante de análisis.

- Cada tabla debe tener una **clave primaria**: es el atributo que identifica unívocamente a cada registro. En nuestro caso, es el Case_ID a través del cual se nombra o identifica cada caso de incoming.
- Cada tabla debe tener a su vez una o más **claves foráneas**: es la clave primaria de otro registro referenciado por el a través del cual se pueden unir (o en términos técnicos se suele decir “joinear”) dos tablas distintas. Para ello, ambas tablas deben contener dicho campo.

2.2. Análisis descriptivo de los datos

Para comenzar dicho análisis descriptivo, se parte desde el momento inicial, que es el momento en que se produce el contacto usuario – Representante de Customer Service.

Cuando un usuario necesita contactarse con un representante de Customer Service, lo puede hacer a través de distintos canales:

- **Canales online**: son aquellos mediante el cual el usuario puede contactarse con un representante de manera casi inmediata. Esto podría ser: un chat o una llamada telefónica. Normalmente, como la interacción del usuario es inmediata, su experiencia (por ende su puntuación en la encuesta de NPS) suele ser mejor que en los canales offline.
- **Canal offline**: Es aquel canal mediante el cual un usuario genera su contacto completando un formulario detallando su problema, el cual luego es enviado por mail y finalmente es respondido por un representante al cabo de un tiempo medio de respuesta (TMR).

Luego de analizar los datos y comprender el funcionamiento del modelo NLP de Machine Learning, se decidió acotar el modelo únicamente al incoming generado por usuarios que se contactan por el canal offline. De esta manera se elimina todo tipo de sesgos del modelo al interpretar un intercambio de frases entre usuario-representante, como pueden darse en el canal online, los cuales no agregan valor e incluso podrían generar errores en el modelo NLP de predicción.

En la Figura 2.1 se puede apreciar la representatividad del canal offline sobre el total de casos de incoming que generaron los usuarios en los años 2020 y 2021.

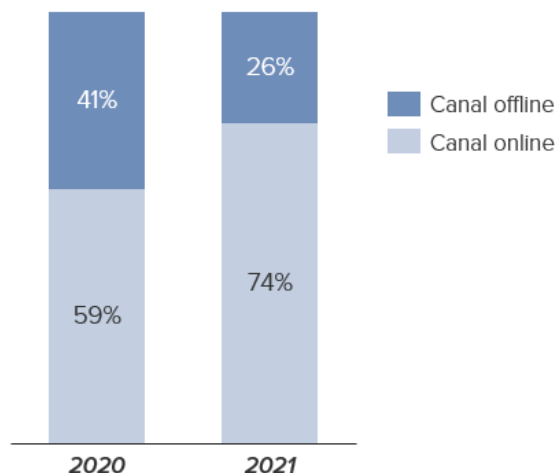


Figura 2.1: Representatividad del incoming que ingresa en el canal offline sobre el total del incoming de 2020 y 2021

Al hacer foco solamente en el canal offline, se presenta en la Figura 2.2 el volumen en cantidad de casos mensual generado por usuarios a lo largo de 2020 y 2021.

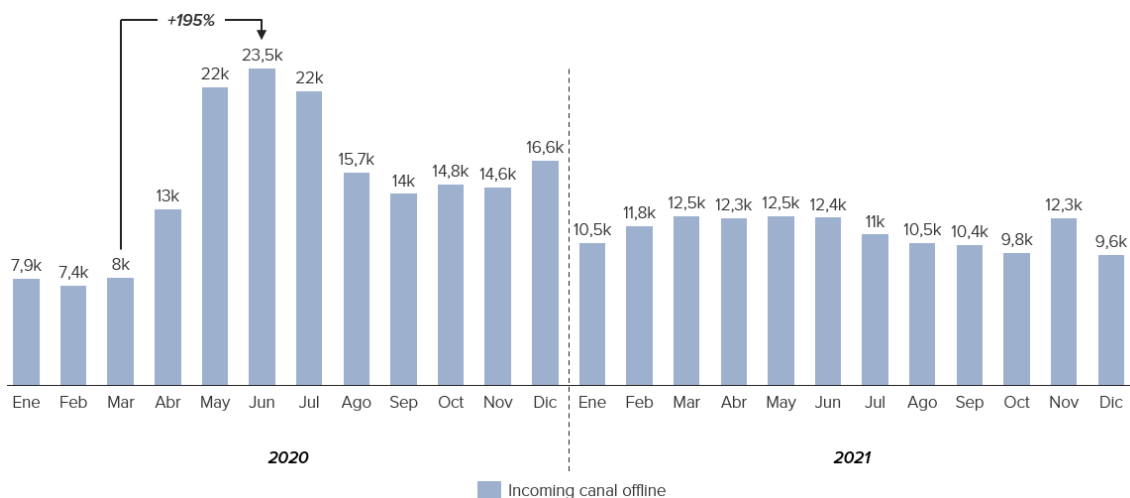


Figura 2.2: Incoming de usuarios del canal offline en 2020 y 2021

Tal como se puede apreciar en la Figura 2.2, el incoming de usuarios del canal offline que llega al equipo de Customer Service comienza a subir a partir del mes de abril 2020 a causa de la pandemia causada por el virus SARS COV-2.

La suba significativa del incoming de usuarios a partir de abril 2020 está relacionada con un aumento de consumo y usabilidad de la empresa de e-commerce en estudio. A modo de ejemplo, podrían citarse algunas de las operaciones que crecieron exponencialmente: envíos de productos, delivery, compras online, entre otras. Todas ellas, potenciadas a efectos que los usuarios no podían salir de sus domicilios.

Dicho efecto también puede apreciarse en otros rubros, como ser empresas retailing, empresas de transporte, etcétera, tal como menciona Beccaria [12].

Como sabemos, la pandemia fue totalmente inesperada y no se pudo predecir la dotación de Staff del equipo de Customer Service.

Al no poder satisfacer la demanda de casos de incoming que surgió a partir de abril 2020, la compañía tomó la decisión de reducir la disponibilidad del canal online, aumentando así la disponibilidad del canal offline. Dicha medida se realiza considerando que, como dijimos anteriormente, el canal offline tiene un TMR mayor que el canal online, lo que permitía gestionar mejor el tiempo y mantener el orden en los equipos de atención. Este motivo fue el que hizo crecer considerablemente (+195 %) el incoming del canal offline de los meses posteriores, como se ve en la Figura 2.2.

En la Figura 2.2 se observa que en los meses posteriores a abril 2020 el incoming del canal offline permanece alto y si bien no alcanza valores nominales (como quizás lo era en enero 2020), se reduce considerablemente respecto a meses anteriores. Esto se debe a que los equipos de Customer Service se reestructuraron y disponibilizaron nuevamente el canal online para un mayor porcentaje de usuarios.

Por otro lado, se grafica en la Figura 2.3 el gap de NPS que existe entre el canal online y el canal offline. Dicha diferencia es la que se querrá eliminar aumentando el NPS de usuarios del canal offline al recibir una mejor atención por parte de los Representantes de Customer Service en el momento del contacto.




Figura 2.3: Promedio de NPS en canal online y offline, en escala de respuestas de 0 a 10

En términos prácticos, un corte muy común que se suele hacer a nivel de datos de encuestas de NPS es clasificar a todos los usuarios detractores con un (-1), a todos los pasivos con un (0) y a todos los promotores con un (+1). De esta manera lo que se puede hacer es determinar el promedio ponderado (en porcentaje) de NPS dependiendo del perfil del usuario, independientemente del puntaje que hayan dado de la encuesta de NPS.

Para explicarlo en términos prácticos, se procede a promediar los distintos tipos de usuarios dependiendo si fueron detractores, pasivos o no detractores. Al promediar entre los números anteriormente dichos, el resultado de esto será un número entre cero y uno.

Finalmente si dicho valor es expresado en porcentajes, resulta la gráfica que se observa en la Figura 2.4.

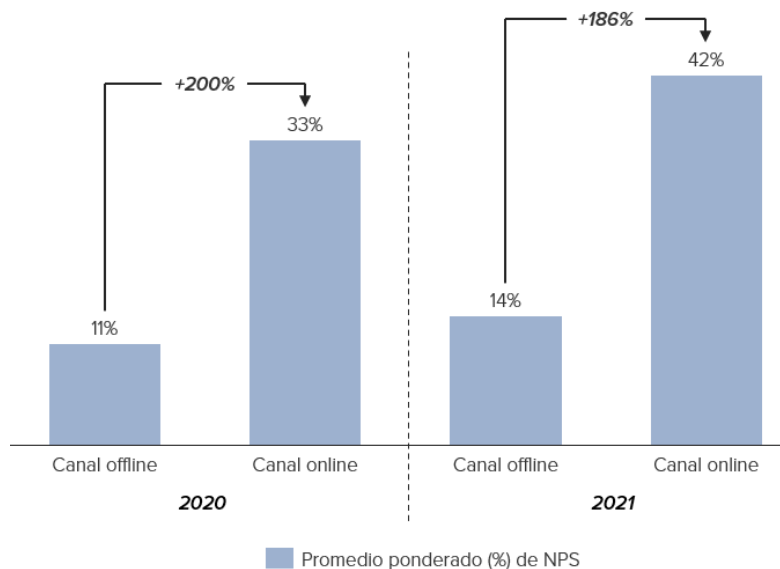


Figura 2.4: Promedio de NPS en canal online y offline, en escala porcentual

Tal como se mencionó en el Capítulo 1, se decide enfocar el modelo NLP en analizar el incoming generado por usuarios a través del canal offline, y únicamente en los países de habla hispana.

En base a esto último, en la Figura 2.5 se puede ver cómo se distribuye dicho incoming de usuarios, dependiendo de los países de habla hispana en el que la empresa tiene participación, En donde se podrá apreciar que tanto Argentina, México y Chile son los principales tres países que tienen mayor cantidad de casos de incoming.




Figura 2.5: Incoming aperturado por país

Las referencias del eje de abscisas de la Figura 2.5 son:

- ARG: Argentina
- MEX: México
- CHI: Chile
- VEN: Venezuela
- COL: Colombia
- URU: Uruguay
- PER: Perú
- Otros. Incluye: Ecuador, Paraguay, Honduras, etc.

Por otro lado, un análisis interesante, pensando a futuro en cómo se formulará el algoritmo de asignación posterior, gira en torno a qué tipos de Representantes gestionan dichos casos.

Una de las hipótesis de las cuales se parte es que los representantes de Customer Service con mayor experiencia podrían generar una mejor experiencia de cara al usuario, y así lograr mejores resultados de atención, motivo por el cual los promedios en encuestas de NPS podrían ser superiores.

Durante el año 2020 se clasificaba a los representantes de Customer Service según su seniority, y en base a dicha clasificación se puede apreciar en la Figura 2.6 el valor de NPS promedio para cada segmento.




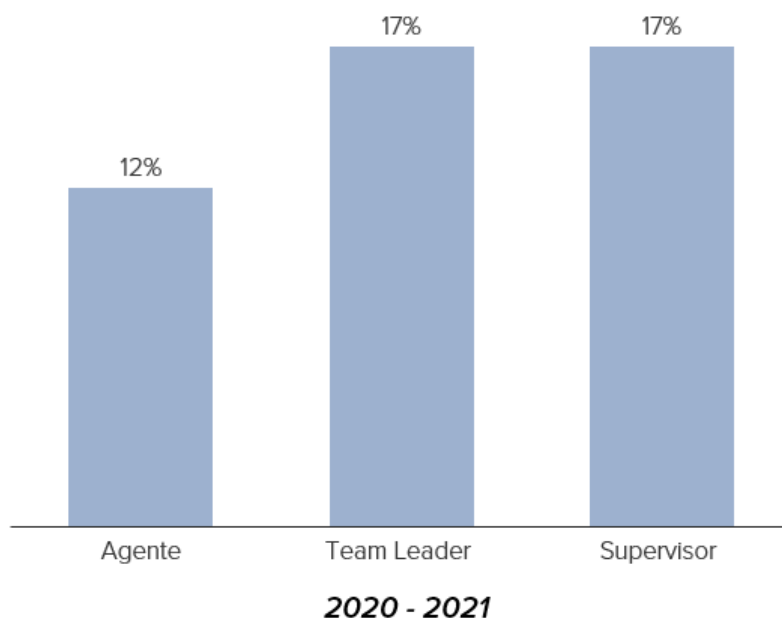
Figura 2.6: NPS ponderado según seniority del representante de Customer Service

Como se puede apreciar en la Figura 2.6, durante el 2020 un representante de categoría Senior generaba 33% más NPS que un representante Junior.

Vale mencionar que no se realiza la comparación de diferencia de NPS entre un representante Junior versus un Team Leader o un Supervisor ya que estos últimos intervienen únicamente en la gestión de casos particulares (por ejemplo, ante el incoming generado por ciertos usuarios específicos a quienes se desea brindar un excelente nivel de servicio).

Un detalle no menor a destacar es que durante el análisis del dataset se encuentra que hacia fines del año 2020 se realizó un cambio en la manera en que se denominan los perfiles de los representantes, pasando a llamarse de manera genérica “Agentes” (dejando de tener la nomenclatura de Junior, Semi-Senior y Senior). Es por eso por lo que para el análisis posterior se definió como direccionalmente correcto agrupar a todos los agentes Junior, Semi-Senior y Senior dentro de la nueva categoría denominada genéricamente “Agente”.


Al analizar los valores de NPS de 2020 y 2021 (en conjunto) de los distintos perfiles de representantes, se obtiene la Figura 2.7.



■ Promedio ponderado (%) de NPS según seniority del Representante de Customer Service

Figura 2.7: NPS ponderado según seniority (ajustado) del representante de Customer Service

Continuando con el análisis descriptivo del respectivo dataset, se desea entender qué cantidad de casos resultaron con encuestas negativas de NPS. En otras palabras, se desea comprender qué cantidad de casos de incoming resultaron detractores, lo que quiere decir que dichos usuarios al calificar la encuesta de NPS lo hicieron de manera no satisfactoria. Para mostrar esto, se presenta a continuación la Figura 2.8.



2020 - 2021

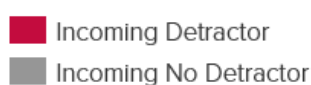


Figura 2.8: Porcentaje de casos de detección del canal offline

Como se puede ver en la Figura 2.8, el 37% del incoming generado a lo largo de 2020 y 2021 resultaron casos de detección.

Al profundizar sobre dicha clasificación, se desea comprender cómo ese 37% de casos de incoming detractores evolucionó a lo largo del tiempo, lo cual se representa en la Figura 2.9.

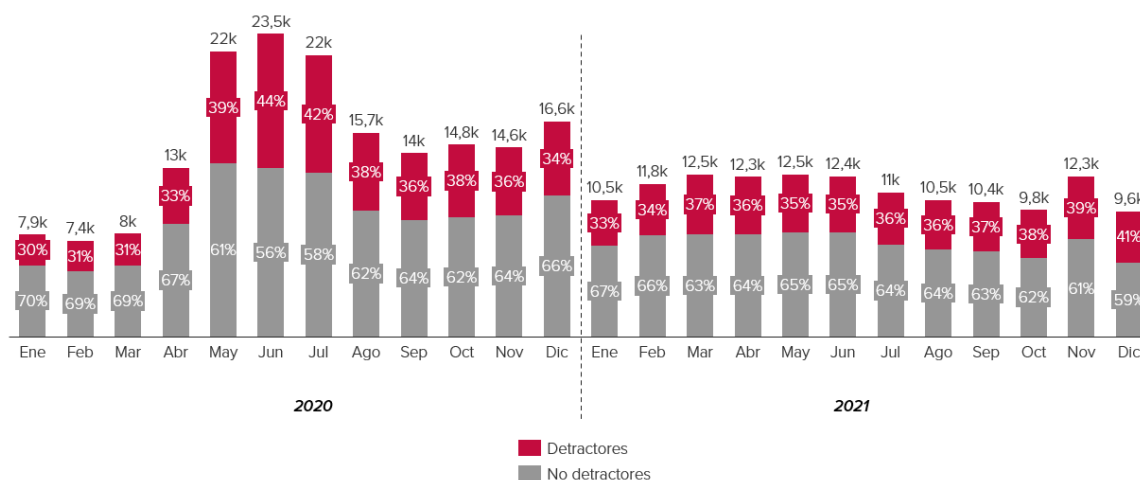


Figura 2.9: Porcentaje de casos de detección del canal offline a lo largo de 2020 y 2021

Como se observa, el pico de casos que resultaron detractores coincide con el pico de incoming del mes de junio 2020 (relacionado a la situación mundial mencionada). Como conclusión de la Figura 2.9, se podría decir que si bien a partir de 2021 se reduce el incoming de usuarios del canal offline, se puede observar que el porcentaje de usuarios detractores permanece elevado.

Como se expresó anteriormente, el canal offline tiene desventajas por sobre el canal online. Por ejemplo, en el canal offline, un usuario para ser atendido debe esperar un tiempo mayor al que suele esperar en el canal online. Dicha cuestión es uno de los desafíos más grandes al que se enfrentan las empresas, ya que cada vez, los usuarios desean respuestas más rápidas a sus necesidades.

Otra descripción interesante se basa en comprender quiénes son esos usuarios que se contactan por el canal offline. Dichos usuarios suelen clasificarse en dos grandes categorías como puede verse en la Figura 2.10.




Figura 2.10: Incoming generado en el canal offline según el perfil del usuario

En la industria del e-commerce de Latinoamérica se utiliza con frecuencia la terminología “Buyer” y “Seller” para referirse respectivamente a los compradores y vendedores que transaccionan en la plataforma.

Como se observa en la Figura 2.10, el 82% del incoming es generado por usuarios de tipo Buyer, mientras que el 18% restante corresponde a incoming generado por usuarios de tipo Sellers.

Los usuarios Sellers son quienes más transaccionan dentro de la compañía, y luego de realizar un análisis en conjunto con el equipo de NPS de la compañía, se concluyó en que son quienes ante alguna consulta, queja o inconveniente, buscan soluciones inmediatas. Es por este motivo por el cual prefieren acudir al canal online, ya que pueden intercambiar mensajes de una manera más directa y dinámica con los Representantes de Customer Service. En la Figura 2.10 se puede apreciar que la representatividad de incoming generada por usuarios Sellers en el canal offline es menor que la de usuarios Buyers.

Al profundizar sobre los perfiles de usuarios descritos en la Figura 2.10, se puede representar la segmentación que resulta en la Figura 2.11.




Figura 2.11: Porcentaje de casos de detracción según perfil de usuario

Tal como se observa en la Figura 2.11 el porcentaje de detracción del canal offline es mayor en usuarios Sellers que en usuarios Buyers. Esto tiene total sentido en base a lo representado en la Figura 2.10: cuando un usuario seller se contacta con Customer Service busca la mejor solución, en el menor tiempo posible. Al acudir al canal offline y no obtener la respuesta o solución que desea, es quien peor puntúa en la encuesta de NPS. Dicho en otras palabras, podría decirse que los usuarios de tipo Seller resultan ser de los más exigentes para la compañía.

Continuando con el detalle del incoming generado según el perfil del usuario, se puede obtener una sub-clusterización de Buyers y Sellers tras aperturarlos como se muestra a continuación en las Figuras 2.12 y 2.13 respectivamente.

- Los usuarios Buyers, se subdividen según su nivel de Loyalty. El Loyalty es un valor que se asigna a cada usuario en función de la cantidad de transacciones efectúe en un determinado período de tiempo y del monto que represente cada una de ellas. Cuantas más transacciones realice dicho usuario con la compañía, mayor será su Loyalty. Los usuarios que tienen mayor nivel de Loyalty reciben más y mejores beneficios en la compañía, por ejemplo: descuentos en ciertos productos, tasas de envíos preferenciales, etcétera.




Figura 2.12: Incoming de casos según loyalty de usuarios Buyers

- Los usuarios Sellers se dividen según su nivel de actividad.




Figura 2.13: Incoming de casos según el nivel de actividad de usuarios Sellers

Dentro de los niveles de actividad que pueden observarse en la Figura 2.13 se destacan los segmentos Longtail, Midtail fijo y variable que son aquellos que menos actividad con la compañía genera, mientras que por el contrario aquellos que más transacciones generan son los llamados Seller líder y Best sellers.

Si se analiza el porcentaje de detracción de dichos segmentos de usuarios se obtiene lo que se observa en las Figuras 2.14 y 2.15 respectivamente.

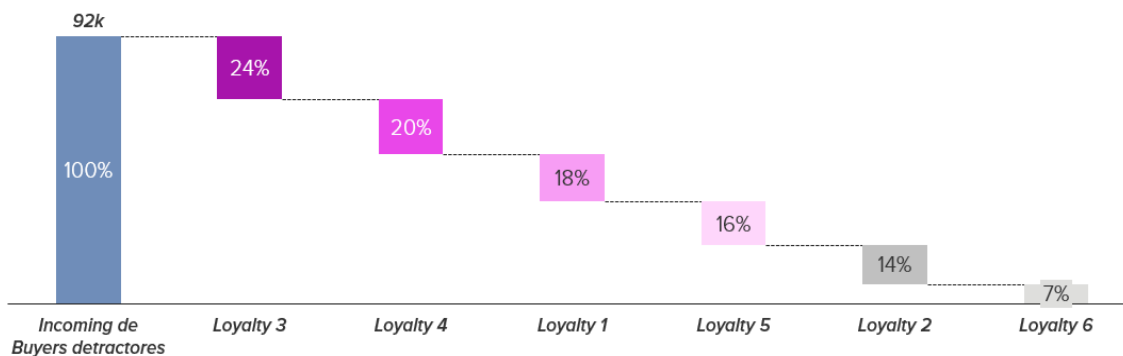


Figura 2.14: Distribución de incoming de detracción en usuarios Buyers según su loyalty




Figura 2.15: Distribución de incoming de detracción en usuarios Sellers según actividad

Otro enfoque del dataset podría ser el siguiente: cuando se genera un caso de incoming, el mismo debería entrar contextualizado ya que previo a que el mismo sea efectuado, el usuario debe completar un formulario, el cual tiene una serie de preguntas preestablecidas lo que hace que luego dicho caso sea dirigido al equipo de gestión correspondiente.

Estos equipos de gestión están organizados y distribuidos por distintos procesos. Dichos procesos permiten comprender la naturaleza de la posible pregunta que realizará el usuario. Por ende, un corte interesante en el dataset es lo que se observa en la Figura 2.16 que permite comprender qué representatividad tienen cada uno de los procesos cuando analizamos el 100% del incoming.

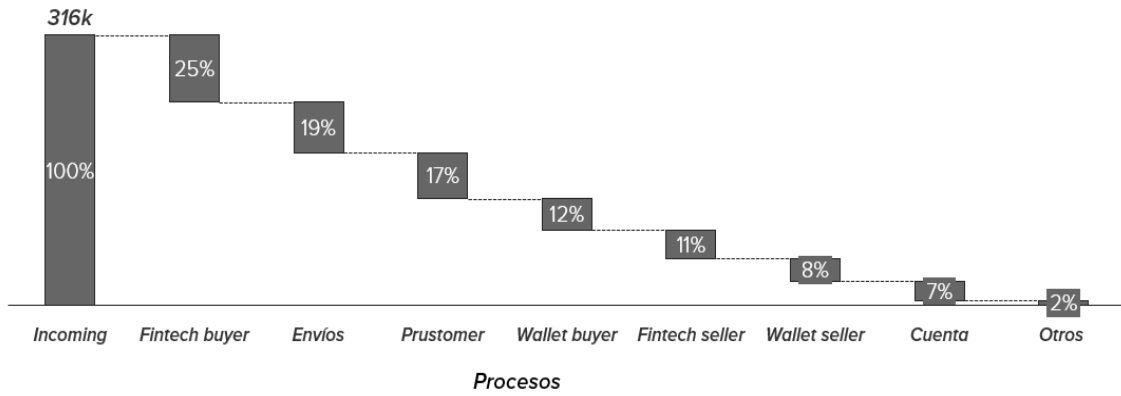


Figura 2.16: Distribución de incoming dependiendo del proceso

Para seguir con la comparación que se venía realizando en los cortes anteriores del dataset, se procede a mostrar la Figura 2.17 que permite comprender cuál es el porcentaje de casos de detracción que se genera en cada uno de los procesos mencionados.

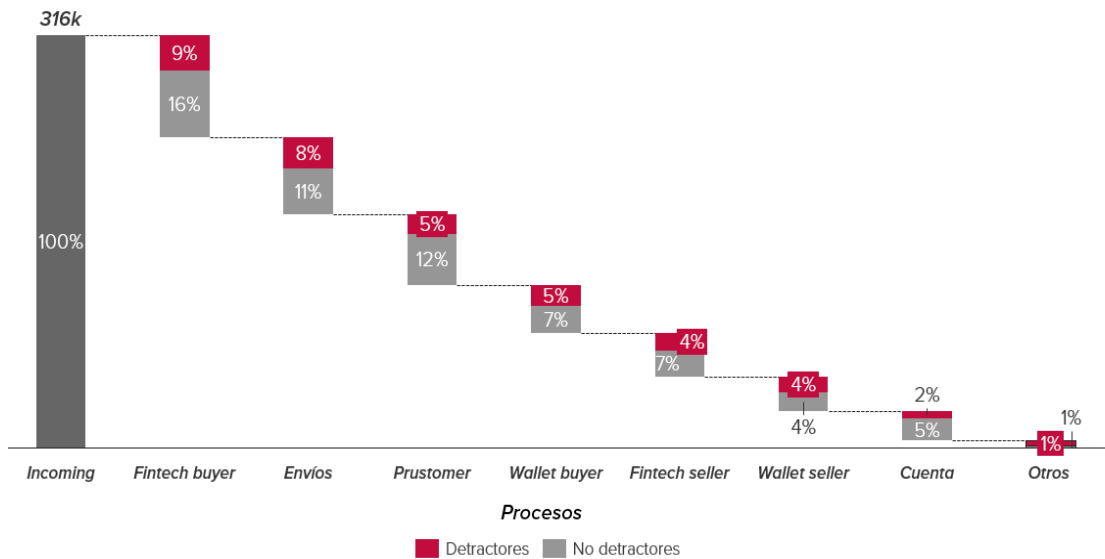


Figura 2.17: Distribución de incoming detractor absoluto, dependiendo del proceso

Para explicar a qué hacen referencia los procesos mencionados, como se mencionó en el Capítulo 1, hace algunos años la empresa comenzó a incursionar en el rubro Fintech, motivo por el cual tiene procesos para aquellos usuarios de tipo Buyer y Seller que operan a través de dicha plataforma, los cuales son llamados “Fintech buyer” y “Fintech seller”.

Algo similar ocurre con los procesos llamados “Wallet buyer” y “Wallet seller” que hacen referencias a consultas de usuarios provenientes de la plataforma de comercio electrónico que también pertenece a la compañía.

El proceso “Cuenta” como su nombre lo indica, gestiona todo tipo de consultas que tengan que ver con datos del perfil del usuario, como por ejemplo datos personales, datos de tarjetas de créditos asociadas a la plataforma Fintech, usuarios con multiplicidad de cuentas (algunas de ellas personales y algunas comerciales), etcétera.

El proceso denominado “Envíos” gestiona todo tipo de consultas relacionadas con el proceso logístico de entrega de productos, como ser plazos de entregas, tracking, problemas con las etiquetas identificatorias que se montan sobre el producto para identificarlos en el depósito, etcétera.

Como se puede apreciar en la Figura 2.17, el proceso Fintech Buyer es el proceso que por valor absoluto presenta mayor cantidad de casos de detracción. Sin embargo, como se observa en la Figura 2.18, al hacer foco en cada uno de los procesos de manera independiente, se puede concluir que el proceso Fintech Buyer no es aquel que tiene peor representatividad de casos detractores. Por ejemplo, si se analiza el incoming total que ingresa en el proceso de Wallet Seller, se observa que el 47% de los casos son detractores, lo que lo convierten en el proceso con mayor proporción de detractores.

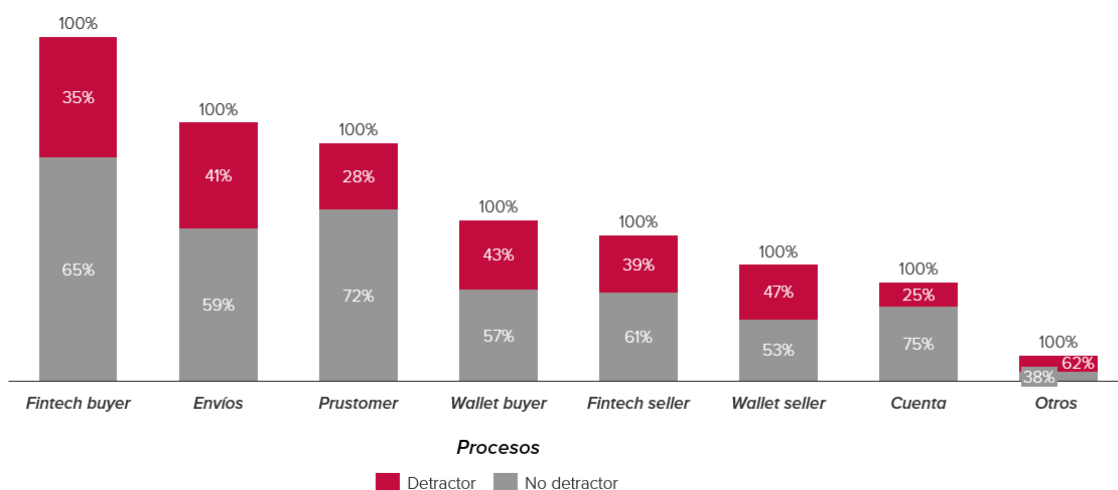


Figura 2.18: Distribución proporcional de incoming detractor por proceso

Continuando con la visión de usuarios detractores, se realiza a continuación la Figura 2.19 que permite comprender qué cantidad de casos de incoming resultaron detractores en cada uno de los países de habla hispana en donde tiene presencia la compañía.




Figura 2.19: Incoming de casos que fueron detractores por país

Luego de realizar el análisis sobre el dataset, se pudo dimensionar que existen distintos tipos de fricciones para un usuario lo que genera que se contacten por diferentes motivos, e incluso a través de diferentes canales de atención que tiene el equipo de Customer Service.

No todos los usuarios tienen el mismo comportamiento. Algunos de ellos son más exigentes que otros, lo cual depende del tipo de perfil que tengan y al tipo de segmento de usuarios al que pertenecen.

Teniendo estas consideraciones, se procede al diseño de los distintos modelos de asignación que tendrán como objetivo darle una mejor experiencia al usuario, y así lograr disminuir el nivel de detracción en las encuestas de NPS.

3. Estrategias de asignación

3.1. Definiciones

Se comenzará definiendo qué es un **modelo de programación lineal entera**. De acuerdo con lo que define Dantzig [13] se podría decir que un modelo de optimización es una representación de la realidad a través de expresiones matemáticas lógicas que se interrelacionan entre sí y son utilizados para optimizar el uso de recursos limitados de una empresa u organización.

Dicho modelo está formado por **variables de decisión**, que son aquellos valores que el proceso de resolución del modelo debe definir de modo tal de alcanzar el valor óptimo en una función objetivo.

Cuando se habla de **función objetivo** se hace referencia a una magnitud que se desea maximizar o minimizar. Dicho valor óptimo es aquel que se obtiene para un determinado conjunto de valores factibles de las variables en juego. Vale aclarar que un modelo de programación lineal entera puede tener un valor óptimo, puede tener más de uno, o puede no tenerlo (esto sucede cuando el modelo es no acotado o no factible).

Para que el modelo sea representativo, es necesario agregar **restricciones**, que son aquellas condiciones o limitaciones que se agregan al modelo que restringen el valor que pueden tomar las variables de decisión. Por ejemplo: una restricción podría ser que el tiempo de cierta actividad sea no negativo.

Como explican Sherman y Zhu [14], una de las principales ventajas que tiene un modelo de programación lineal entera, en este caso aplicable a equipos de Customer Service, es que permite tomar decisiones a través de mecanismos que no son visibles a través de otras metodologías. Además, permite traducir reglas o variables de negocio en relaciones matemáticas, al variar alguna de ellas, suelen ser de fácil adaptación a nuevas reglas.

Los modelos de programación lineal entera tienen múltiples funciones y entre ellas se podrían utilizar para determinar niveles de staff en función de la demanda, elegir las mejores rutas de transporte para optimizar alguna variable como ser kilometrajes, litros de combustible, entre otras.

Los modelos de programación lineal entera se pueden resolver y aplicar mediante distintos métodos, según explica Castillo [15].

El objetivo de la corriente tesis tiene como foco principal centrarse en la **creación y resolución de modelos de asignación de los respectivos casos de incoming de usuarios que se contactan con Customer Service hacia los respectivos Representantes**, quienes serán las personas que atiendan dichas consultas o reclamos de usuarios. El objetivo será encontrar esa dupla de incoming - representante de manera de optimizar la función objetivo, la cual será definida más adelante.

Se podría decir que un modelo de asignación consiste en asignar ciertos recursos a ciertas actividades, teniendo la consideración que cada recurso sólo puede hacer una actividad, y cada actividad puede ser realizada por un único recurso a la vez. Si relacionamos esta última definición con la definición general de un modelo de programación lineal entera, nos damos cuenta de que esto último podríamos modelarlo con restricciones, para luego con ellas lograr optimizar cierta función objetivo.

3.2. Modelado e implementación

Luego que el equipo de Customer Service recibe un caso de incoming generado por un usuario y el mismo es analizado a través del modelo NLP de Machine Learning se obtiene como resultado su probabilidad de detracción. El paso siguiente consiste en determinar a qué Representante se debe asignar dicho caso y con qué criterio, y para eso se realizarán diferentes estrategias de asignación para ver cuál de ellas es la adecuada para implementar.

Por un lado, se sabe que no todos los casos de incoming tienen la misma probabilidad de detracción, ya que depende del tipo de problema por el que se contacte un usuario y el nivel de stress este tenga. Por otro lado, se sabe que no todos los Representantes brindan la misma calidad de atención a los casos que gestionan a lo largo del turno en cual que atienden.

El desafío consiste en encontrar la dupla Representante - caso de incoming, que permita maximizar la experiencia de los usuarios que se contactan con el equipo de Customer Service y así mejorar su NPS.

Existen diversas técnicas y métodos para gestionar casos que ingresan a equipos de Customer Service. Henderson y Mason [16] explican algunas variables que deben considerarse y cómo utilizarlas para maximizar la métrica CGOS (Customer Grade of Service) a través de la implementación de modelos de programación lineal.

3.2.1. Descripción de las variables y condiciones del modelo

Siguiendo el orden de las definiciones dadas, se comienzan definiendo a continuación los conjuntos que luego se utilizarán en el modelo.

- Se representará con el subíndice i a cada uno de los Representantes de Customer Service que forman parte del conjunto $\{1, 2, \dots, R\}$.
- Se representará con el subíndice j a cada caso de incoming generado por un usuario, los cuales forman parte del conjunto $\{1, 2, \dots, N\}$.

- Cada Representante del equipo de Customer Service atiende varios casos por día. Operativamente están organizados por turnos que se distribuyen a lo largo de la semana. Cuando ingresa un contacto a través del canal offline el mismo tiene un TMR mayor a un día, motivo por el cual podría ser gestionado en el mismo día que ingresa a la cola de atención o al día siguiente, dependiendo de la disponibilidad operativa que tengan los Representantes. Se representará con el subíndice d a los días hábiles en que se realizará la asignación de casos de incoming a los respectivos Representantes. Dicho subíndice d forma parte del conjunto $\{1, 2\}$ y será igual a 1 en aquellos casos en que el caso de incoming es asignado a un Representante en el mismo día que ingresó. Por consecuencia, el subíndice d será igual a 2, cuando dicho caso de incoming sea asignado a un Representante para el día siguiente.

Por otro lado, como se mencionó en el análisis descriptivo del dataset, el conjunto de Representantes no puede ser agrupado según su seniority, y es por eso por lo que una medida que se tomó para clasificarlos es aquella que mide su probabilidad de éxito de gestión.

Para cada Representante $i \in \{1, 2, \dots, R\}$ se llamará $Prep_i$ a la probabilidad de gestión de cada uno de dichos Representantes, y se define como se observa en (1).

$$Prep_i = \frac{\# \text{ casos gestionados por el Representante } i \text{ que resultaron promotores en NPS}}{\# \text{ total de casos gestionados por el Representante } i} \quad (1)$$

Se puede ver que cada Representante i tendrá una probabilidad de éxito de gestión. A su vez, cada caso de incoming j debe ser gestionado por un Representante motivo por el cual se procede a la creación de un nuevo parámetro, como se observa en (2).

$$C_{ij} = Pdc_j * Prep_i \quad (2)$$

Donde:

- Pdc_j = Probabilidad de detracción del caso entrante j , dato que se obtiene del modelo NLP
- $Prep_i$ = Performance del Representante i de CS, que en otras palabras es quien expresa la probabilidad de éxito de gestión del representante
- C_{ij} = Parámetro que vincula la probabilidad de detracción de un caso de incoming j con la probabilidad de éxito de gestión de un Representante i .

La interpretación del parámetro C_{ij} consiste en multiplicar dos probabilidades. Esto permite pensar que el valor resultante de dicha multiplicación idealmente debe ser lo más elevado posible. Esto implicaría que un caso de incoming con altas probabilidades de detracción debería ser atendido por un Representante que tenga buena probabilidad de éxito de gestión, para que así brinde una mejor experiencia al usuario al momento del contacto.

Como se mencionó anteriormente, no todos los Representantes brindan la misma calidad de atención. Por este motivo se toma la decisión de agrupar a los Representantes de Customer Service según dicha probabilidad de éxito de gestión, resultando así los conjuntos que se observan en la Tabla 3.1, lo cual será un concepto utilizado luego, cuando se desarrollen las restricciones del modelo de asignación.

Probabilidad de éxito (Prep)	Prep \leq 20%	20% < Prep < 40%	40% \leq Prep < 70%	70 \leq Prep
Perfil de Representante según performance	Bad performance	Low performance	Med performance	High performance

Tabla 3.1: Perfil del Representante según la probabilidad de éxito en gestión de casos. Ver ecuación (1) que determina dicha probabilidad.

Para tomar dimensión del peso ponderado de cada conjunto de Representantes, se muestra en la Tabla 3.2 la representatividad de cada uno de ellos.

Perfil del Rep	Dotación de representantes
Bad performance	1%
Low performance	22%
Med performance	71%
High performance	6%
Total general	100%

Tabla 3.2: Representatividad de la dotación de Representantes según su perfil en base a su probabilidad de éxito de gestión.

Vale mencionar que para dicha clasificación no se consideran aquellos Representantes que gestionaron menos de veinte casos en dos años, por considerarse no representativos. Por ejemplo: cuando analizamos el dataset, se encontraron perfiles con 100% de probabilidad de éxito, habiendo gestionado un único caso de incoming.

Por otro lado, luego de realizar reuniones en conjunto con el equipo de Customer Service de la compañía y comprender la operación de sus equipos, se menciona que los Representantes tienen turnos de 6 horas diarias (por contrato), de las cuales están operativos 5,3 horas (88% del tiempo), ya que cuentan con 40 minutos de break / turno.

Aproximadamente el 65% del tiempo operativo resultante se encuentran gestionando el canal online por ser el canal que tiene prioridad, mientras que el 35% restante del tiempo es el que tienen disponible para gestionar el canal offline, lo que resulta en aproximadamente 1,8 horas disponibles / turno para la gestión del canal offline.

Se define el parámetro D_{id} que representa la disponibilidad de un Representante i en el día d . Dependiendo de la cantidad de casos que se vayan gestionando a lo largo del turno por cada Representante, dicho parámetro luego será utilizado en las restricciones correspondientes para definir qué día un caso de incoming j podría ser gestionado.

Por otro lado, se sabe que en promedio, un Representante gestiona en promedio 40 casos / turno lo cual se puede expresar según (3).

$$\text{Capacidad total} = \frac{40 \text{ casos}}{\text{turno}} * \frac{1 \text{ turno}}{5,3 \text{ horas}} = \frac{7,5 \text{ casos}}{\text{hora}} \quad (3)$$

Al enfocarse únicamente en el canal offline se sabe de antemano que si un Representante tiene 1,8 horas disponibles para gestión del canal offline se plantea la ecuación (4).

$$\text{Capacidad offline} = \frac{7,5 \text{ casos}}{\text{horas}} * \frac{1,8 \text{ horas}}{\text{turno}} = \frac{13 \text{ casos}}{\text{turno}} \quad (4)$$

Como puede apreciarse en (4), cada Representante i podrá gestionar en promedio trece casos por turno, con lo que se puede determinar de antemano la capacidad de gestión que será necesaria.

Para estimar el tiempo que lleva gestionar cada caso offline, se plantea la ecuación (5).

$$\text{Tiempo de gestión promedio} = \frac{1}{\frac{7,5 \text{ casos}}{\text{hora}}} = \frac{8 \text{ minutos}}{\text{caso}} \quad (5)$$

Dicho tiempo que se visualiza en (5) es el tiempo promedio propio de gestión de un caso de incoming.

Si se quisiera considerar el tiempo total que un usuario demora en obtener una respuesta por parte del equipo de Customer Service se debe considerar una ecuación como la que se observa en (6), donde se expresa que el tiempo total de espera de un usuario resulta de la suma del tiempo de gestión del propio caso sumado al tiempo que se demoró en asignar un Representante a dicha gestión.

$$\text{Tiempo total } j = Tt_j = T\text{espera}_j + T\text{gestión}_j \quad (6)$$

Avramidis y L'Ecuyer [17] explican cómo se determinan en la práctica de los equipos de Customer Service el nivel de dotación necesaria para atender todos los casos de incoming ingresantes. En pos de organizar el staff y garantizar un nivel de servicio adecuado en el equipo de Customer Service, el equipo de Planning de la compañía determina de antemano el número mínimo de Representantes que debe haber disponibles para gestionar la totalidad de casos. Dicho de otra manera, independientemente que no haya ningún caso asignado a un Representante i , dicha persona debe estar disponible, y en todo caso, dichos tiempos ociosos se suelen utilizar para capacitaciones y /o formación de la persona.

Continuando con la definición de capacidad de Representantes en cada turno de atención, seguramente en términos operativos se desee que los casos de incoming que ingresan, se distribuyan de manera pareja entre los distintos perfiles de Representantes. De esta manera es posible asegurar que al comenzar una nueva tanda o lote de asignación de casos, se tendrá disponibilidad de Representantes de todos los perfiles.

Para que esto suceda, se deberá adicionar una restricción de equidad al modelo, la cual expresa que para cada Representante i , la suma de casos que debe gestionar es similar a la que gestiona otro colega. No tendría sentido, y no sería justo, que los casos de incoming sean asignados únicamente a los Representantes de mayor probabilidad de éxito mientras que haya colegas con tiempo ocioso de gestión.

Para explicar qué implica agregar restricciones de equidad al modelo, se procede a dar un ejemplo: se podría imaginar un Proceso de gestión de la compañía el cual en un determinado día tiene 100 casos de incoming para asignar entre sus Representantes disponibles. Si en el modelo no se consideran restricciones de equidad, el modelo asignará la mayor cantidad de casos de incoming entre los Representantes que tengan mayor probabilidad de éxito de gestión ya que en caso de una función objetivo de maximización será cuando se alcance un valor óptimo.

Recordando la máxima cantidad de casos que se pueden gestionar por cada turno de gestión de un Representante (13 casos por turno), el modelo asignará los casos de incoming ocupando a los Representantes que tengan mayor probabilidad de éxito de gestión, hasta agotar su capacidad. Luego, asignará los siguientes 13 casos de incoming al próximo Representante con mayor probabilidad de éxito de gestión, y así siguiendo hasta asignar la totalidad de casos. Una vez que haya asignado los N casos de incoming, se obtiene una gráfica similar a la que se ve en la Figura 3.1, en donde los Representantes, como se dijo anteriormente, están ordenados de manera decreciente en función de su probabilidad de éxito de gestión.




Figura 3.1: Cantidad de casos asignados por representante (quienes están ordenados según prob. de éxito decreciente) cuando no hay restricciones de equidad entre ellos.

Se puede observar en la Figura 3.1 que hay una siete Representantes que tienen 13 casos asignados, otro Representante tiene 9 casos asignados (hasta completar la totalidad restante de los 100 casos del ejemplo) mientras que hay otro conjunto de Representantes que no recibe casos, por ende, estos últimos serían personas que en la práctica no estarían gestionando casos durante ese mismo período de tiempo.

Al agregar restricciones de equidad entre Representantes sumado a la restricción de máxima cantidad de casos que puede gestionar cada uno de ellos como cota superior, el modelo comenzará a asignar casos de incoming de manera equitativa entre los Representantes hasta asignar la totalidad de casos, tal como puede verse en la Figura 3.2.




Figura 3.2: Comparación de cantidad de casos asignados por representante con modelos de asignación con restricciones versus modelo sin restricciones

En el ejemplo citado en la Figura 3.2 se cuenta con una totalidad de cien casos para asignar. Del lado izquierdo de la Figura se representa el ejemplo citado en la Figura 3.1. Del lado derecho de la Figura 3.2, al agregar condiciones de equidad, los mismos cien casos de incoming deben ser asignados entre los Representantes disponibles, pero en este caso, dicha asignación será de manera pareja, por lo que habrá mayor cantidad de Representantes gestionando casos (en la Figura 3.2 quedan representados como “Otros Representantes” en la última columna del gráfico y se supone que reciben 3 casos en promedio), y entre ellos habrá poca diferencia de cantidad de casos asignados.

Otro dato importante que facilitó el equipo de Customer Service para tener en cuenta en el desarrollo del modelo de asignación está relacionado a métricas operativas. Por un lado, el SLA (Service Level Agreement) del equipo expresa que el 100% de los casos de incoming debe ser respondido dentro de las 48 horas.

Por otro lado, existe una métrica aún más desafiante que expresa un SLA ajustado, y consiste en tener el 90% del incoming total gestionado dentro de las primeras 18 horas desde que ingresa el contacto.

Con fines de respetar el KPI de SLA ajustado descrito, es posible restringirlo expresando que los casos de incoming deben ser gestionados en el día que ingresan al equipo de Customer Service. Para llevarlo a la práctica, se debe proponer que el subíndice d esté seteado de antemano en 1, lo que podría expresarse como X_{ij1} . Algo que vale la pena mencionar es que no se considera el horario en que ingresa el incoming. Es decir, la compañía en caso de implementación de dicho modelo debería considerar en qué horario ingresa el incoming versus qué cantidad de representantes disponibles tiene en ese momento, ya que por ejemplo no es comparable la gestión que recibe un caso de incoming que ingresa a las 09:00 hs y se asigna para el “día 1” (será gestionado durante el mismo día) y un caso que ingresa a las 23:59 hs, que sin dudas será gestionado al día siguiente, lo que en el modelo es considerado como “día 2”.

Un dato adicional y totalmente operativo, es que una métrica conocida del canal offline de los equipos de Customer Service de habla hispana tienen un TMR promedio (tiempo medio de respuesta promedio) de 5 horas.

Dicho dato no será necesario agregarlo como una restricción al momento del diseño del modelo, pero sí podría ser tenido en cuenta luego para un algoritmo de asignación de tipo batching.

Además, así como se clasificaron y agruparon los Representantes de Customer Service, se propone una clasificación de los usuarios que generan dichos casos de incoming.

No todos los usuarios tienen el mismo nivel de actividad ni tampoco transaccionan los mismos montos de dinero. Es por esto, que se podría suponer que no todos ellos representan el mismo valor para la compañía. Así como sucede en algunos rubros, por ejemplo en los bancos, los usuarios pueden recibir diferentes tratos dependiendo de su categoría. Normalmente se brinda una atención preferencial para los usuarios de mayor valor para la compañía, como ser tasas e impuestos diferenciales, prioridad de atención, entre otros beneficios.

Para realizar esta clasificación se buscó en las bases de datos de la compañía una variable que mide el monto (en USD) que transaccionan dichos usuarios en cierto período de tiempo. Se consideró como dicho plazo a los 6 meses previos al momento en que ingresa el incoming de dicho usuario, y finalmente se tomó el criterio de clasificación que se observa en la Tabla 3.3.

Perfil del usuario	Monto transaccionado 6 meses previos al incoming generado
Long tail user	Monto \leq 100 USD
Gold user	100 USD \leq Monto $<$ 1.000 USD
Platinum user	1.000 USD \leq Monto $<$ 5.000 USD
Black user	5.000 USD \leq Monto $<$ 10.000 USD
VIP user	10.000 USD \leq Monto

Tabla 3.3: Perfil del usuario que genera el incoming según el monto de dinero transaccionado

Para tener dimensión de la representatividad que tiene cada uno de los conjuntos de usuarios que generan casos de incoming, se muestra la Tabla 3.4.

Perfil del usuario	Cantidad de usuarios
Long tail user	19%
Gold user	33%
Platinum user	34%
Black user	11%
VIP user	3%
Total general	100%

Tabla 3.4: Representatividad de cantidad de usuarios según su perfil, determinado por el monto transaccionado previo al contacto

Habiendo definido grupos de Representantes y grupos de usuarios que generan incoming, a continuación se proponen algunas asignaciones que de antemano se dejarán establecidas en el modelo.

Si bien no existe en la actualidad alguna regla de negocio establecida por la compañía para dicha asignación de casos de incoming, en pos de mejorar la experiencia de los usuarios de mayor valor para la compañía, se propone que si el inconveniente proviene de un usuario de categoría Black o VIP (los dos subconjuntos de mayor valor económico para la compañía), el mismo sea asignado únicamente entre los Representantes Medium y High performance (los dos subconjuntos de mayor probabilidad de éxito de gestión). En otras palabras, se dejará configurado en el modelo de asignación que el incoming de dichos segmentos de usuarios no puedan ser gestionados por Representantes que tengan Bad o Low performance.

De manera gráfica se puede expresar tal como se ve en la matriz de compatibilidad que se muestra en la Tabla 3.5.

		Performance del Representante de Customer Service			
		Bad performance	Low performance	Medium performance	High performance
Perfil del usuario que genera incoming	Long tail user	1	1	1	1
	Gold user	1	1	1	1
	Platinum user	1	1	1	1
	Black user	0	0	1	1
	VIP user	0	0	1	1

Tabla 3.5: Matriz de compatibilidad perfil de usuario que genera incoming versus la performance del Representante que gestionará el caso.

Como se puede apreciar en la Tabla 3.5 no se aplica ninguna restricción en los casos que pueden gestionar los Representantes. Esto quiere decir que es posible que el modelo asigne todo perfil de Representante a cualquier caso de incoming, independientemente del perfil del usuario. A modo de ejemplo, se puede ver que un Representante de categoría High puede gestionar casos de un usuario de categoría Longtail.

Por el contrario, se puede ver que existe una restricción dependiendo de la categoría a la que pertenezca el usuario que genere el incoming. A modo de ejemplo se puede apreciar que los usuarios de categoría Black y VIP únicamente podrán ser atendidos por los segmentos de Representantes Medium y High performance.

En base a esto, otra definición que se toma de antemano es que para cada asignación que realice el modelo, siempre se deje disponible a un porcentaje de Representantes High y Medium Performance (un buffer), de manera tal de puedan gestionar algún caso de incoming de algún usuario de alto valor que ingrese de manera inesperada a la cola de gestión en la próxima tanda de asignación de casos.

Por otro lado, como se vio en la Figura 2.16, los usuarios tienen distintos motivos de consultas, los cuales fueron agrupados por procesos dependiendo de la casuística del mismo. Es por eso, que al modelo se le debe poner la condición que a la hora de realizar la asignación considere qué Representantes tienen el know-how para la correspondiente gestión de un determinado caso de incoming. Vale mencionar que existen Representantes de Customer Service que están capacitados para gestionar uno o varios procesos. Es por eso por lo que se crea un conjunto de procesos P y se definen Procesos i y Proceso j que representan respectivamente al subconjunto de procesos que puede gestionar un Representante i , y a qué proceso corresponde cada caso de incoming j .

3.2.2. Modelado

Se define a continuación la variable binaria que será la principal decisión que deberá tomar el modelo al momento de decidir realizar la asignación o no.

$$X_{ijd} = \begin{cases} 1 & \text{si el caso } j \text{ es asignado al Representante } i \text{ en el día } d \\ 0 & \text{en caso contrario} \end{cases}$$

Como se observa, la variable binaria X_{ijd} no podría tomar valores decimales debido a que no se podría asignar una fracción de caso de incoming a un determinado Representante de Customer Service.

En otras palabras y a modo de ejemplo se podría decir que la variable X_{ij1} es la variable binaria que se considera para asignar el caso de incoming j al Representante i en el mismo día en que ingresa al equipo de Customer Service. Por otro lado, X_{ij2} es la variable binaria que se considera para asignar el caso de incoming j al Representante i para el siguiente día al que ingresa al equipo de Customer Service.

Se parte de una función objetivo, como se observa en (7).

$$\max \sum_{i=1}^R \sum_{j=1}^N C_{ij} * X_{ijd} \quad (7)$$

Es importante mencionar que la función objetivo expresada (7) no es penalizada por realizar la asignación de un caso j para el día $d=2$ debido a que la mayoría de los casos suelen ser asignados y gestionados en el día $d=1$.

Como se observa en (7), la función objetivo es una función de maximización, lo que quiere decir que buscará su valor más alto, estando sujeta a una serie de restricciones que se definirán a continuación.

$$\sum_{d=1}^D \sum_{i=1}^R X_{ijd} = 1 \quad j = 1, \dots, N \quad (8)$$

En términos prácticos la restricción (8) expresa que todos los casos de incoming que llegan a Customer Service deben que ser asignados exactamente a un único representante. En otras palabras, se puede apreciar que la sumatoria de las variables X_{ijd} únicamente vale 1 cuando todas las otras asignaciones valen 0.

Por otro lado, la restricción (9) representa la capacidad de gestión diaria de cada uno de los Representantes de Customer Service.

$$\sum_{j=1}^N T_{\text{gestión } j} * X_{ijd} \leq D_{id}, \quad i = 1, \dots, R, \quad d \in \{1,2\} \quad (9)$$

En palabras, la restricción (9) quiere decir que el tiempo total de gestión de casos asignados a lo largo de un turno de trabajo no puede ser mayor que el tiempo disponible que tiene un Representante en dicho turno. Ese tiempo disponible por turno se considera una cota superior. Por otro lado, es importante mencionar que aquellos casos que no sean asignados en alguno de los días seguramente terminen afectando la disponibilidad de gestión de los Representantes en el día posterior. En términos prácticos, el parámetro D_{id} irá variando a lo largo del día, en función de la cantidad de casos que se vayan asignando a un Representante.

Para asegurar el cumplimiento del SLA ajustado que se describió en la sección anterior, se impone la restricción (10), donde se observa que el 90% del total de casos N que ingresan deben ser gestionados en el mismo día.

$$\sum_{i=1}^R \sum_{j=1}^N X_{ij1} \geq 0,9 * N \quad (10)$$

La restricción de equidad que se plantea en el modelo es la que se observa en (11), la cual expresa que para cada Representante, la suma de casos que debe gestionar es similar a la que gestiona otro colega, lo cual en términos matemáticos se logra poniendo que cada uno de ellos gestiona aproximadamente el promedio de casos que ingresan.

$$\sum_{j=1}^N X_{ijd} \geq \left\lfloor \frac{N}{R * D} \right\rfloor, \quad i = 1, \dots, R, \quad d \in \{1,2\} \quad (11)$$

Vale destacar que del lado derecho de la inecuación (11) se pide que dicho cociente sea redondeado al número entero inmediato inferior.

Algo a destacar es que luego de ejecutar distintas instancias y estrategias del modelo, se descubre que si se deja únicamente la restricción (11) tal como se ve hasta el momento, cuando el número de Representantes disponibles R que se observa del lado derecho es muy alto versus la cantidad de casos de incoming, dicho lado de la inecuación termina siendo cero, lo que termina asignando los casos de incoming a un único Representante (al de mayor performance).

Es por esto, que se agrega la nueva restricción (12) como cota superior al modelo, donde se adiciona una constante K (número entero) al modelo, de manera tal que cada Representante gestione a lo sumo una cantidad máxima de casos.

$$\sum_{j=1}^N X_{ijd} \leq \left\lfloor \frac{N}{R * D} \right\rfloor + K, \quad i = 1, \dots, R, \quad d \in \{1,2\} \quad (12)$$

Vale destacar que luego de ejecutar las estrategias de tipo batching del modelo se descubre que las restricciones (11) y (12) son débiles cuando se realizan en batches pequeños. Esto ocurre por tener pocos casos para repartir entre todos los Representantes disponibles (lo cual se detallará en la Sección 5.2 cuando se analicen los resultados obtenidos).

Para que en todo momento exista un determinado porcentaje disponible de Representantes Medium y High Performance se agrega la restricción (13).

$$\sum_{j=1}^N T_{\text{gestión } j} * X_{ijd} \leq Z * D_{id}, \quad i \in \text{MP} \cup \text{HP}, \quad d \in \{1,2\} \quad (13)$$

En la restricción (13), que está expresada en unidad de tiempo y no en cantidad de Representantes, MP y HP representan aquellos subconjuntos que fueron presentados en la Tabla 3.1 como Representantes Medium y High performance respectivamente. Por su lado, $Z \in (0; 1]$ y representa un parámetro del modelo el cual se podrá ajustar dependiendo de qué porcentaje de Representantes se desee tener con capacidad ociosa para lograr así mejores asignaciones futuras.

A modo de ejemplo, la restricción (13) permite que al menos el $(1 - Z)$ % de los Representantes de los dos subconjuntos de mayor performance (Medium y High performance) permanezcan disponibles para gestionar posible incoming de usuarios de alto valor para la compañía.

Merece la pena destacar que la restricción (13) reemplaza a la restricción (9) para $i \in \text{MP} \cup \text{HP}$ con parámetro $Z=1$.

La restricción (14) expresa que todo incoming proveniente de usuarios de categoría Black y VIP no podrán ser gestionados por Representantes de categoría Bad y Low performance (subconjuntos BP y LP respectivamente).

$$X_{ijd} = 0, \quad i \in \text{BP} \cup \text{LP}, j \in \text{Black} \cup \text{VIP}, d \in \{1,2\} \quad (14)$$

Por otro lado, se desea que todo caso de incoming que ingresa al equipo de Customer Service sea asignado a un determinado Representante que tenga el conocimiento adecuado para gestionar dicho caso, por lo que se define la restricción (15).

$$X_{ijd} = 0, \quad \text{Proceso } j \notin \text{Procesos } i, \quad i = 1, \dots, R, \quad j = 1, \dots, N, \quad d \in \{1,2\} \quad (15)$$

Como se puede ver en la restricción (15), todo caso de incoming j deberá pertenecer a un proceso tal como se observa en la Figura 2.16. Al momento de realizar la asignación, el modelo considerará asignarlo únicamente entre aquellos Representantes que tengan el conocimiento para su correspondiente gestión. En caso de que dichos procesos no coincidan, la variable X_{ijd} valdrá cero, lo cual hace sentido. No colocar esta restricción podría generar errores en la operación tras asignar casos de incoming a Representantes que no tengan el conocimiento para gestionar el caso, y según los datos utilizados, la restricción (15) no se convierte en restrictiva para el modelo generando así resultados factibles.

Finalmente se adiciona la restricción (16) donde se pide que la variable X_{ijd} sea una variable binaria.

$$X_{ijd} \in \{0,1\}, \quad i = 1, \dots, r, \quad j = 1, \dots, N, \quad d \in \{1,2\} \quad (16)$$

4. Marco experimental

4.1. Tipos de asignación

Antes de presentar las posibles estrategias de asignación, se presentan algunas definiciones: Se hará referencia al “mejor Representante de Customer Service” cuando se hable de aquella persona que tenga mayor probabilidad de éxito en la gestión de sus casos, tal como se vio en (1).

Se define al “usuario más importante” para hacer referencia sobre aquel usuario que más cantidad de dinero transacciona en un cierto tiempo, según la clasificación que se muestra en la Tabla 3.3.

El paso siguiente es describir las distintas estrategias de asignación que se llevan a cabo.

4.1.1. Estrategias de asignación sin utilizar modelos de programación lineal entera

4.1.1.1. Asignación aleatoria entre todos los Representantes

Se define como estrategia de asignación A1 a la que realiza la asignación de cada caso de incoming que ingresa de manera aleatoria entre el total de Representantes disponibles. Esta estrategia representa la asignación implementada hasta el momento por el equipo de Customer Service.

4.1.1.2. Asignación FIFO al mejor Representante disponible

La estrategia de asignación A2 consiste en asignar el primer caso de incoming que ingresa al mejor Representante de Customer Service disponible (ordenados de manera decreciente según probabilidad de éxito de gestión), siempre que tenga el conocimiento para gestionar dicho caso. Esto último quiere decir que antes de realizar la asignación se valida que el Representante asignado conozca el proceso del cual se trata el caso de incoming y así pueda gestionar dicho caso.

4.1.1.3. Asignación Greedy según probabilidad de éxito de gestión del Representante, considerando un batching de turno de operación completo

Cuando se habla de asignaciones de tipo *batching* se hace referencia a aquellos tipos de asignación que consideran un tiempo determinado durante el cual no se realiza ninguna asignación, y tiene como finalidad acumular una determinada cantidad de casos de incoming a asignar y finalmente pasado dicho tiempo se realiza la asignación de casos acumulados de mayor probabilidad de detracción entre los mejores representantes disponibles.

Dicho tiempo de batching es un valor que puede ir variando, para así poder realizar la comparación entre los distintos escenarios para finalmente recomendar aquel modelo que sea más beneficioso para la compañía.

Como se mencionó, el equipo de Customer Service brindó información acerca del TMR del canal offline es de 5 horas, lo cual podría considerarse como un buen punto de partida para tomar dicho plazo como el tiempo de batching máximo, es decir, el tiempo durante el cual se acumularán casos de incoming para poder realizar luego una mejor asignación.

Sin embargo, como se vio en la restricción (4), cada Representante de Customer Service cuenta con 1,8 horas / turno (o 108 minutos / turno) para atender casos de incoming que ingresan por el canal offline, lo que quiere decir que dicho KPI siempre se podrá cumplir.

Un detalle importante a destacar en estos modelos de asignación por batching, es que cuanto mayor sea el tiempo del batch, seguramente mejor será la asignación que se puede hacer con el modelo. Esto sucede ya que se conoce el universo completo de casos a asignar, por ende se puede maximizar el valor de la función objetivo. No obstante, en aquellos casos que el tiempo de batching sea demasiado alto se perjudica a aquellos usuarios que se contactaron antes, debido a que tendrán que esperar más tiempo hasta que son asignados con su respectivo Representante.

La última estrategia de asignación llevada a cabo sin la utilización de un modelo de programación lineal entera se denomina A3. Dicha estrategia se caracteriza por no realizar ningún tipo de asignación hasta que se conoce la totalidad de casos de incoming. Una vez conocida la totalidad de casos de incoming en un determinado turno, los mismos se ordenan de manera decreciente según su probabilidad de detracción. En paralelo se ordenan los Representantes de Customer Service de manera decreciente según su probabilidad de éxito de gestión (1). Una vez ordenados los casos de incoming y los Representantes se realizan las asignaciones Greedy correspondientes respetando dicho orden.

4.1.2. Estrategias de asignación utilizando modelos de programación lineal entera

4.1.2.1. Asignaciones de tipo batching, ajustando el tiempo del batch

Dicha estrategia de asignación de tipo batching será denominada A4 la cual se subdividirá en distintos subconjuntos, dependiendo del tiempo de batching considerado.

La estrategia de asignación A4 - 1 será aquella que considera que cada batch tiene una duración de $\frac{1}{4}$ del tiempo total disponible para gestión de casos offline por cada turno cuya duración puede apreciarse en (17).

$$\text{Batch A4 - 1} = \frac{\text{Tiempo total de gestión de casos offline}}{4} = \frac{108 \text{ minutos}}{4} = 27 \text{ minutos} \quad (17)$$

Por otro lado, la estrategia de asignación A4 - 2 considera que cada batch tiene una duración de la mitad del tiempo total disponible para gestión de casos offline, como se ve en (18).

$$\text{Batch A4 - 2} = \frac{\text{Tiempo total de gestión de casos offline}}{2} = \frac{108 \text{ minutos}}{2} = 54 \text{ minutos} \quad (18)$$

Vale aclarar que tanto en la estrategia A4 - 1 y la estrategia A4 - 2 consideran que luego de finalizar cada asignación, todos los Representantes tienen la misma capacidad de trabajo disponible para comenzar el siguiente batch de asignación. Si bien en la restricción de equidad (11) se determina que la asignación de casos sea de manera pareja entre los distintos Representantes, dicha aclaración se realiza ya que en términos prácticos dependiendo de la cantidad de casos de incoming podría suceder que entre Representantes se tenga una pequeña diferencia entre la cantidad de casos de incoming asignados.

Finalmente, la estrategia de asignación a la que se denomina A4 - 3 es aquella que considera que cada tamaño de batch coincide con la totalidad del tiempo diario disponible que tiene un Representante de Customer Service para gestionar el canal offline. En otras palabras, sería considerar los 108 minutos / turno para acumular la totalidad de casos de incoming y luego realizar la asignación. Entonces el tiempo de batching de la estrategia A4 - 3 se observa en (19).

$$\text{Batch A4 - 3} = \text{Tiempo total de gestión de casos offline} = 108 \text{ minutos} \quad (19)$$

4.1.2.2. Asignación con máximo tiempo de batching, sin restricciones de equidad entre Representantes de Customer Service

Se plantea una estrategia de asignación denominada A5, la cual desde el punto de vista teórico, debería dar como resultado la mayor función objetivo, ya que si bien considera restricciones de capacidad de cada Representante, no considera restricciones de equidad entre ellos. Esto significa que el modelo tendrá en cuenta todas las restricciones excepto la de equidad, asignando la mayor cantidad de casos posibles entre Representantes que tengan mayor probabilidad de éxito de gestión hasta agotar su capacidad.

La estrategia A5 al igual que la estrategia de asignación llamada A4 - 3, considera los 108 minutos de disponibilidad de gestión del canal offline que se vio en (19) para luego realizar la asignación.

Dicha estrategia A5 si bien es poco recomendada para llevar a la práctica por no contar con restricciones de equidad entre Representantes y el máximo tiempo de batching, permite finalmente hacer una comparación contra la mejor asignación posible que se pueda llegar a obtener con los datos planteados y ver cuán lejos está la propuesta realizada de aquella estrategia de asignación que logra la máxima función objetivo alcanzable.

4.2. Procedimiento de ejecución

Para ejecutar el modelo y analizar resultados, se consideran diez instancias diferentes, las cuales provienen de días de incoming representativos a lo largo de los años 2020 y 2021 (cinco instancias por cada año). Estos son:

- Un día de enero 2020 y un día de enero 2021, para de esta manera ver si hay alguna diferencia de comportamiento entre el incoming que llegó en enero 2020 versus el incoming que ingresó al año siguiente, en la misma época del año.
- Un día de abril 2020 y un día de abril 2021, para ver qué sucedió con el incoming apenas comenzó la pandemia (abril 2020) y cómo evolucionó luego de un año.
- Para evaluar distintos momentos del año, se toma el incoming de días de junio 2020 y 2021, septiembre 2020 y 2021, y finalmente de diciembre de 2020 y 2021.

Dependiendo de los datos, se podrían sacar conclusiones más robustas si se prueban días consecutivos a lo largo de determinados meses del año. Sin embargo, como se verá más adelante, se consideran aceptables los resultados obtenidos en los días seleccionados ya que permiten sacar conclusiones.

Hasta el momento se determinó en qué meses del año se toma el muestreo de casos para asignar. Resta determinar qué días particulares.

Históricamente, los sábados y domingos se reduce la cantidad de transacciones de la compañía en cuestión, y por esto suelen ser los días de menor cantidad de casos de incoming. Por el contrario, los lunes y martes suelen ser los días de mayor actividad, por ende, se toma como criterio analizar y correr el modelo para el primer martes hábil de cada uno de los meses anteriormente mencionados.

Como se mencionó anteriormente, las estrategias de asignación A1, A2 y A3 son aquellas que fueron ejecutadas sin la implementación de un modelo de programación lineal entera. En todas ellas, luego de obtener la dupla resultante de la asignación Representante – caso de incoming, se procede a calcular el valor de las funciones objetivo correspondientes al multiplicar la probabilidad de detracción de cada caso de incoming asignado (determinada mediante el modelo NLP) por la probabilidad de éxito de gestión del Representante correspondiente.

Por su parte, la función objetivo de la estrategia A1 es la que se considera función objetivo real, ya que como se mencionó anteriormente, es la estrategia implementada actualmente por la compañía.

Por otro lado, el valor de la función objetivo de la estrategia A2 se determinó asignando los casos de incoming a los respectivos Representantes, considerando una asignación FIFO. Para cada una de las instancias determinadas, se ordenaron los casos de incoming según su horario de ingreso al equipo de Customer Service, los cuales luego fueron asignados a los respectivos Representantes.

Para calcular la función objetivo de la estrategia A3 se consideraron cada una de las instancias mencionadas y luego de finalizar cada una de ellas y contar con la totalidad de casos, se asignan aquellos casos de mayor probabilidad de detracción entre los Representantes con mayor probabilidad de éxito.

Por otro lado, las estrategias A4 - 1, A4 - 2, A4 - 3 y A5 fueron ejecutadas resolviendo el modelo de programación lineal entera presentado en el capítulo anterior, por medio de un software denominado SCIP (Solving Constraint Integer Programs). SCIP es actualmente uno de los solvers no comerciales más rápidos para resolver problemas de programación lineal entera y de programación no lineal entera mixta.

Para ejecutar cada una de las instancias en SCIP se deben escribir cada una de las restricciones presentadas en el Capítulo 3.2.2 de la corriente tesis en un archivo de formato .zpl (que corresponde al lenguaje de modelado ZIMPL, que SCIP puede interpretar) para luego ser ejecutado desde la consola de un computador.

Para que dicho software pueda interpretar la información que debe consumir, se deben generar diferentes archivos .txt que contengan la información que necesitan las restricciones del modelo, como ser el listado Representantes disponibles y cómo se conforman cada uno de sus subconjuntos (Bad, Low, Medium y High performance), listados de usuarios aperturados también por su respectiva clasificación (Longtail, Gold, Premium, Black y VIP), listado de casos de incoming a asignar, listado de los diferentes procesos de gestión de la compañía, etcétera. Luego de obtener la información y el modelo con restricciones cargado, se ejecuta una corrida del modelo de asignación para cada una de las distintas instancias generadas.

A modo de ejemplo, cuando se ejecutó la estrategia A4 - 3, se procedió a ejecutar una corrida del modelo para cada instancia de tiempo seleccionada. Cuando se realizan corridas de la estrategia A4 - 1 para las mismas instancias de tiempo, como el tiempo de batching es la cuarta parte del tiempo de batching del modelo A4 - 3, la cantidad de corridas se cuadruplica, ya que para cada lote o tiempo de batching se debe ejecutar una corrida particular. Luego se deben sumar las cuatro funciones objetivo de cada batch de la estrategia A4 - 1 para poder comparar con la función objetivo obtenida en la estrategia A4 - 3.

5. Resultados de las estrategias de asignación

Como se mencionó en el Capítulo 4, se pueden apreciar diferentes estrategias de asignación.

- Resultados de la estrategia A1, que como se explicó anteriormente fue la asignación real del caso realizada en 2020 y 2021 por el equipo de Customer Service nos permitirá luego hacer comparaciones del estilo *what if*.
- Resultados de las estrategias de asignación A2 y A3, generan funciones objetivo que permitirán compararse con estrategias en donde sí se haya realizado la implementación de un modelo de programación lineal entera (estrategias A4, por ejemplo)
- Resultados de las estrategias A4 – 1, A4 – 2 y A4 – 3, todas ellas resultantes de la ejecución con un modelo de programación lineal entera utilizando SCIP.
- Resultados de la estrategia A5 que como se mencionó en el capítulo anterior, es aquella ejecutada con el modelo de programación lineal entera y permitirá luego comparar contra la máxima función objetivo alcanzable para cada una de las instancias y medir cuán lejos de ella se encuentra la estrategia recomendada.

5.1. Impacto de resultados sobre la función objetivo

Para determinar cuál de las estrategias de asignación es la ideal para recomendar a la compañía en cuestión, se deben hacer comparaciones entre las funciones objetivo obtenidas en cada una de ellas.

Se muestra a continuación la Tabla 5.1 donde se expresan los resultados de las funciones objetivo de cada una de las estrategias de asignación ejecutadas para cada una de las instancias.

Instancias	Asignaciones sin utilizar modelos de programación lineal entera			Asignaciones utilizando modelos de programación lineal entera			
	Asignación implementada hasta el momento	Asignación FIFO al mejor Representante Disponible	Asignación Greedy con batching (108 minutos)	Asignaciones Batching, con restricciones de equidad			Asignaciones Batching, sin restricciones de equidad
				Batching (27 minutos)	Batching (54 minutos)	Batching (108 minutos)	
	A1	A2	A3	A4 - 1	A4 - 2	A4 - 3	A5
ene-20	250,92	270,18	280,48	302,66	304,44	305,95	328,82
abr-20	405,62	418,76	429,78	460,94	462,29	465,99	497,87
jun-20	632,19	641,89	678,14	713,90	723,40	725,22	783,76
sep-20	437,72	451,86	479,12	530,83	531,19	531,36	566,93
dic-20	493,18	531,78	556,49	617,32	617,63	617,78	656,28
ene-21	331,22	390,14	412,64	450,19	452,45	457,66	463,44
abr-21	382,54	419,54	449,05	501,04	502,66	504,47	536,68
jun-21	414,89	458,31	490,83	534,00	534,33	534,64	570,15
sep-21	292,49	360,41	375,82	394,33	394,78	395,08	422,05
dic-21	252,19	290,31	302,74	346,87	347,27	347,55	371,50

Tabla 5.1: Comparación de funciones objetivo de cada una de las estrategias ejecutadas en cada instancia

Cada una de las celdas de la Tabla 5.1 representa la función objetivo de cada instancia, dependiendo de la estrategia ejecutada, la cual está expresada como suma de valores porcentuales de cada una de las asignaciones realizadas, ya que resulta de la multiplicación de la probabilidad de éxito de gestión de cada Representante (%) con la probabilidad de detracción de cada uno de los casos de incoming (%).

Como se mencionó en (7), la función objetivo que se plantea corresponde a una función de maximización, lo que significa que si comparamos una determinada instancia, cuanto mayor sea el valor de la función objetivo indica una mejor asignación del caso de incoming al respectivo Representante.

Como se observa en la Tabla 5.1, independientemente de la instancia que se observe, la estrategia A1 es aquella que siempre logra valores menores en la función objetivo versus las otras estrategias utilizadas.

Por otro lado, si se hace foco en el resultado obtenido en la estrategia A2 de la Tabla 5.1, desde el punto de vista teórico, tiene sentido que resulte una función objetivo mayor que la obtenida en la estrategia A1, ya que no se está asignando aleatoriamente sino que se está considerando una asignación FIFO entre los mejores Representantes disponibles, lo cual es algo que no sucede en la estrategia A1.

Por otro lado, la función objetivo resultante de la estrategia A3 expuesta en la Tabla 5.1 es mayor que la funciones objetivo obtenidas en las estrategias A1 y A2, y esto se debe a que considera un tiempo de batching de 108 minutos (un turno completo de operación), y como se dijo anteriormente, tiene sentido que genere mejores resultados ya que contempla el universo completo de casos a asignar.

Si se consideran además los resultados de las estrategias A4 expuestos en la Tabla 5.1, de asignación de tipo batching con restricciones de equidad entre Representantes, se puede apreciar que efectivamente resultan valores aún superiores a los obtenidos al ejecutar los modelos A1, A2 y A3, lo cual tiene sentido ya que el solver analiza entre múltiples asignaciones cuál es aquella que maximiza la función objetivo según las restricciones impuestas.

Una comparación interesante surge de analizar los resultados de las diferentes estrategias A4 ya que independientemente del tiempo considerado para el batching de cada una de ellas se observan resultados similares entre sí.

A modo de ejemplo: si se compara la función objetivo que se obtiene al ejecutar el modelo batching el primer martes hábil del mes de enero 2020, independientemente del tiempo de batching que se considere, tal como se vio anteriormente en las ecuaciones (17), (18) y (19), los valores de la función objetivo son similares entre sí (tienen una diferencia del 1% entre ellas), lo que resulta ser beneficioso ya que significa que no se está penalizando la función objetivo al reducir el tiempo de batching. En términos prácticos es ideal que suceda esto, ya que significa que se pueden tomar tiempos de batching relativamente pequeños (lo que quiere decir que el usuario será asignado en un tiempo relativamente corto) sin penalizar la función objetivo, es decir, haciendo una asignación similar a la que se obtendría con tiempos de batching mayores.

Si se deja de lado el ejemplo puntual de la instancia de enero 2020, se puede observar en la Tabla 5.1 que dicho comportamiento se mantiene constante, independientemente de la instancia ejecutada. La variación en la función objetivo se mantiene con valores menores al 2% independientemente de la instancia ejecutada, lo que representa un valor sumamente aceptable.

Finalmente, como se puede validar en la Tabla 5.1, la estrategia de asignación A5 es aquella cuya función objetivo es mayor que el resto de las asignaciones, lo que no quiere decir que sea la asignación a recomendar a la empresa para su implementación. Como se mencionó anteriormente, dicha estrategia además de no considerar restricciones de equidad en los Representantes (como se vio en la Figura 3.2), estaría penalizando a un usuario que realice un reclamo apenas comienza el momento del batching, quien deberá esperar 108 minutos (tiempo que dura el batching) hasta recibir atención y así una respuesta a su consulta.

Realizadas las comparaciones, se puede concluir en que **la estrategia de asignación recomendada es la denominada A4 – 1**. Como se vio en la Tabla 5.1, es aquella estrategia que logra una función objetivo mayor a las obtenidas en las estrategias A1, A2 y A3. Por otro lado, si se compara con otras estrategias de batching con tiempos de asignación mayores, por ejemplo A4 – 2 y A4 – 3, no presenta grandes pérdidas en la función objetivo (sólo -2%). Esto último no solo implica un porcentaje bajo de pérdida en la función objetivo, sino también resulta beneficioso para el usuario que genera el caso de incoming, ya que recibe atención en un menor tiempo que si se hubieran utilizado estrategias de mayor tiempo de batching.

Luego de haber recomendado la estrategia de asignación A4 – 1, se procede a compararla en primer lugar con la asignación realizada por la compañía de manera aleatoria en la Figura 5.1.




Figura 5.1: Porcentaje de variación de función objetivo de la asignación aleatoria realizada por la compañía versus la función objetivo de la estrategia propuesta A4 – 1

Como puede apreciarse en la Figura 5.1, se puede determinar qué porcentaje de incremento en la función objetivo se habría obtenido, si en lugar de realizar una asignación aleatoria se hubiera realizado con un modelo de asignación de tipo batching con las restricciones consideradas.

En el Capítulo 4 se explicó por qué la estrategia de asignación A5 no es práctica a la hora de implementar, más allá que sea aquella con la que se obtenga la mayor función objetivo. Sin embargo, una comparación entre dicha estrategia y el modelo A4 - 1 es aquella que se presenta en la Figura 5.2. la que permite dar noción de cuán lejos se encuentra la función objetivo obtenida con la estrategia de asignación propuesta respecto de la función objetivo máxima que se pudiera haber logrado con las condiciones impuestas.




Figura 5.2: Porcentaje de variación de función objetivo de la estrategia propuesta versus función objetivo de la estrategia A5

Al ser la estrategia de asignación A5 aquella que no presenta restricciones de equidad entre Representantes y además considera el máximo tiempo de batching, tiene total sentido que a medida que se agregan restricciones al modelo, dicha función objetivo comience a disminuir, por ende, se podría decir que tanto las estrategias A4 - 1, A4 - 2 y A4 - 3, podrían considerarse como subconjuntos de la asignación realizada en la estrategia A5.

De la Figura 5.2 también se puede concluir que el costo o penalidad en la función objetivo tras agregar restricciones de equidad al modelo oscila entre el 3% y el 9%, dependiendo de la instancia que se analice.

5.2. Características de las soluciones obtenidas

En la sección 5.1 se mencionaron las diferentes estrategias de asignación y el impacto en las funciones objetivo que generó cada una de ellas. A continuación se realiza un análisis que explora la estructura de las soluciones que se obtuvieron al ejecutar las estrategias de asignación mencionadas.

Se muestra a continuación la Tabla 5.2 que permite obtener dimensión de la cantidad de casos a asignar en cada una de las instancias, la cantidad de Representantes disponible para la gestión y qué cantidad de ellos fueron efectivamente asignados, dependiendo de la estrategia de asignación utilizada.

Instancias	Cantidad de casos a asignar	Cantidad de Representantes disponibles	Porcentaje de representantes asignados según estrategia de asignación						
			A1	A2	A3	A4 - 1	A4 - 2	A4 - 3	A5
ene-20	741	353	98,0%	90,0%	97,0%	35,8%	37,1%	67,4%	18,1%
abr-20	1239	567	95,6%	84,0%	97,0%	26,8%	28,6%	69,4%	18,5%
jun-20	2277	969	98,6%	78,9%	97,3%	29,6%	31,1%	74,6%	28,4%
sep-20	1391	807	98,0%	85,4%	97,0%	44,0%	45,2%	54,6%	14,5%
dic-20	1554	954	98,0%	78,7%	96,6%	31,9%	35,0%	51,8%	13,8%
ene-21	998	733	99,3%	87,2%	97,4%	35,1%	38,7%	51,3%	11,7%
abr-21	1211	869	98,0%	80,8%	96,7%	16,3%	18,8%	44,3%	15,2%
jun-21	1248	890	98,0%	80,7%	97,4%	33,6%	36,0%	44,5%	12,0%
sep-21	945	735	96,6%	81,4%	97,1%	34,6%	35,7%	41,1%	13,3%
dic-21	872	657	96,0%	63,2%	97,1%	35,4%	39,0%	42,4%	11,4%

Tabla 5.2: Porcentaje de Representantes asignados en cada instancia de tiempo, según la estrategia de asignación utilizada

Como conclusión de lo que se observa en la Tabla 5.2 se puede decir que tanto las estrategias A1, A2 y A3 tienen un elevado porcentaje de Representantes asignados (se puede ver la cantidad de Representantes precisamente asignados en el Anexo 1, Sección 9.1.1). Esto quiere decir que gran parte de la dotación tendrá casos de incoming para gestionar.

En la Tabla 5.2 se puede observar también que tanto en las estrategias A4 - 1, A4 - 2, A4 - 3 y A5 se reduce el porcentaje de Representantes asignados en cada una de las instancias. Esto se debe a que dichas asignaciones corresponden a estrategias en donde sí fue utilizado el modelo de programación lineal entera.

Como se puede ver en la Tabla 5.2, los resultados de las estrategias A4 - 1 y A4 - 2 difieren poco entre sí, y a su vez, ambas difieren considerablemente de los resultados obtenidos según la estrategia A4 - 3. Luego de analizar los resultados se comprende que en las estrategias A4 - 1 y A4 - 2 las restricciones de equidad son débiles. En ellas sucede que al reducir el tiempo de batching resultan batches de asignación más chicos con menor cantidad de casos a asignar entre los Representantes disponibles. Esto genera que el porcentaje de ocupación de Representantes en cada batch sea bajo. Luego, al ejecutarse el siguiente batch dichos Representantes asignados en batches anteriores vuelven a ser asignados por el modelo, y así siguiendo. La estrategia de asignación A4 - 3 al presentar el mayor tiempo de batching acumula mayor cantidad de casos a asignar, y dadas las restricciones de equidad del modelo, termina asignando a mayor cantidad de Representantes que las estrategias A4 - 1 y A4 - 2.

Por otro lado, se debe recordar que la estrategia de asignación A5 es aquella que no considera las restricciones de equidad entre Representantes. Dicha estrategia es la que se presenta en la Tabla 5.2 como aquella que tiene menor porcentaje de Representantes asignados. Esto es debido a que el modelo intentará maximizar la función objetivo, y asignará la totalidad de casos de incoming entre los mejores Representantes, hasta agotar su capacidad.

El análisis realizado hasta el momento sobre los resultados de la Tabla 5.2 se puede complementar analizando la forma en que están distribuidos dichos casos de incoming dependiendo de los distintos perfiles de Representantes. Esto se puede ver en la Figura 5.3 donde se observa el porcentaje promedio de casos asignados por cada una de las estrategias de asignación en función del perfil de los Representantes.




Figura 5.3: Porcentaje promedio de casos asignados en cada una de las estrategias de asignación, según el perfil del Representante

Las referencias de las leyendas (y del eje de abscisas) de la Figura 5.3 son:

- BP: Bad Performance
- LP: Low Performance
- MP: Medium Performance
- HP: High Performance

En la Figura 5.3 se representa el porcentaje promedio de casos asignados según el perfil del Representante. Para su elaboración se considera el promedio de casos asignados por cada estrategia de la totalidad de instancias ejecutadas. En el Anexo 1 Sección 9.1.2 se presentan los porcentajes de casos asignados en las diferentes instancias por cada una de las estrategias utilizadas, según el perfil del Representante asignado para gestionar cada caso de incoming.

La primera conclusión que puede sacarse del gráfico es que los Representantes de categoría Medium Performance, son aquellos que independientemente de la estrategia de asignación utilizada son aquellos que mayor cantidad de casos reciben.

Por otro lado, como se puede ver en la Figura 5.3, las estrategias A1, A2 y A3 son las únicas que asignan casos entre los Representantes Bad y Low Performance. Al hacer foco en las estrategias A4 - 1, A4 - 2 y A4 - 3 se puede observar que la asignación de casos deja de realizarse entre los segmentos de Representantes antes mencionados y comienzan a distribuirse únicamente entre Representantes Medium y High Performance.

Si se hace foco en la estrategia de asignación A5 representada en la Figura 5.3 se puede sacar la conclusión que es aquella que asigna la mayor cantidad de casos a los Representantes High Performance, lo cual hace sentido. Esto, sumado a lo que se explicó respecto de dicha estrategia anteriormente observando la Tabla 5.2, podría concluir en que la estrategia de asignación A5 es aquella que intenta asignar la mayor cantidad de casos posible a los Representantes High Performance y es por este motivo que el porcentaje de Representantes utilizados es menor que comparado con el resto de las estrategias.

Para concluir con las características de las soluciones obtenidas al ejecutar las distintas estrategias de asignación, se adjunta a continuación la Tabla 5.3 que permite tomar dimensión de los tiempos aproximados para la obtención de las funciones objetivo de cada una de ellas. Vale aclarar que para la ejecución de las instancias se utiliza y computadores Hp Elitebook, con procesador Intel Core i7 8565U con 16 GB de RAM.

Instancias	Cantidad de casos a asignar	Cantidad de Representantes disponibles	Tiempo aproximado (en minutos) para la obtención de resultados de la función objetivo correspondiente							
			Estrategias de asignación sin utilizar modelo de programación lineal entera			Estrategias de asignación utilizando modelo de programación lineal entera				
			A1	A2	A3	A4 - 1	A4 - 2	A4 - 3	A5	
ene-20	741	353		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos
abr-20	1239	567		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos
jun-20	2277	969		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos
sep-20	1391	807		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos
dic-20	1554	954		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos
ene-21	998	733		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos
abr-21	1211	869		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos
jun-21	1248	890		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos
sep-21	945	735		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos
dic-21	872	657		Despreciable			~ 20 minutos	~ 22 minutos	~ 45 minutos	~ 12 minutos

Tabla 5.3: Tiempos aproximados para obtención de funciones objetivo de cada estrategia de asignación considerada, en cada una de las instancias.

Como se puede ver en la Tabla 5.3, las estrategias de asignación A1, A2 y A3 tienen tiempo de ejecución despreciable ya que para la ejecución de las mismas no se utilizó un modelo de programación lineal entera.

Si hacemos foco en las estrategias de asignación A4 - 1, A4 - 2, A4 - 3 y A5 son aquellas en donde se cuantifica el tiempo aproximado para obtener las funciones objetivo correspondiente al utilizar el modelo de programación lineal entera. La estrategia A4 - 1 requiere un tiempo conformado por cuatro instancias de batching de ~5 minutos de ejecución cada una. Por su parte, la estrategia A4 - 2 está conformada por dos instancias de batching de ~11 minutos de ejecución cada una. La estrategia A4 - 3 es aquella que tiene una única instancia de batching donde se considera la totalidad de los casos y es por eso por lo que es la instancia más lenta, demorando ~45 minutos en la obtención de la función objetivo de cada instancia de tiempo ejecutada. La estrategia de asignación A5, si bien tiene una única instancia de batching, al no contar con restricciones de equidad, el modelo asigna los casos en mucho menor tiempo que las estrategias anteriores, demorando ~12 minutos para cada instancia ejecutada.

6. Conclusiones

Tal como se mencionó en la Introducción dada en el Capítulo 1, la compañía de e-commerce objetivo de análisis de la corriente tesis, en la actualidad realiza la asignación de casos de incoming generado por usuarios de manera aleatoria entre los Representantes del equipo de Customer Service. El motivo por el cual la asignación de casos se realiza de manera aleatoria se debe a que nunca se propuso una mejor alternativa.

Tras el análisis efectuado en el corriente Trabajo Final de Maestría, se estaría en condiciones de recomendar el reemplazo de la asignación aleatoria que se realiza en la actualidad, por un modelo de programación lineal entera que asigne casos de manera inteligente.

Cuando en su momento se pensó en el posible tema a desarrollar para la corriente tesis no se tenía certeza que proponer un modelo de programación lineal entera para asignación de casos al equipo de Customer Service sería beneficioso por sobre el modelo de asignación aleatoria que se tiene actualmente. Sin embargo, como se puede evidenciar en el Capítulo 5, Figura 5.1, en caso de implementar la estrategia recomendada A4 - 1, se logran funciones objetivo mayores versus las obtenidas con la asignación aleatoria actual (A1) lo cual quiere decir que los resultados son satisfactorios. Por otro lado, dicha estrategia de asignación recomendada, como se observa en la Tabla 5.2 ocupa un porcentaje menor al 50% de Representantes disponibles, lo que significa que en caso de implementación se podría necesitar de menor cantidad de Representantes o bien, aquellas personas no asignadas en casos de incoming del canal offline podrían dedicar más gestión del canal online y/o aprovechar dicho tiempo para recibir capacitaciones y perfeccionarse.

Si bien la función objetivo lograda tras haber seleccionado la estrategia de asignación a recomendar no puede ser traducida directamente en términos económicos, el paso siguiente será presentar el análisis dentro de los equipos correspondientes de la compañía para que tomen la decisión sobre la implementación de dicha propuesta.

Una alternativa que se propone a priori es realizar un A/B testing, en donde se aplique la estrategia de asignación A4 - 1 (recomendada) únicamente en un determinado porcentaje del total del incoming de manera tal de poder medir (y comparar versus un grupo de control) el impacto generado en valores de NPS tras la respuesta que brindan los usuarios en la correspondiente encuesta tras la atención a su consulta.

7. Trabajo futuro

7.1. Posibles alternativas y ajustes sobre el modelo propuesto

Con fines de seguir mejorando el modelo de asignación propuesto hasta el momento se plantean a continuación una serie de alternativas que podrían ser tenidas en cuenta como trabajo futuro. Tal como se puede ver en la restricción (14) del modelo, los usuarios Black y Vip deben ser atendidos exclusivamente por los Representantes Medium y High performance. Por otro lado, lo que se observa en la Tabla 3.4 donde se habla de la representatividad que tienen los diferentes clusters de usuarios, es que los usuarios Black y VIP representan sólo el 14% del total de usuarios.

La alternativa que se propone experimentar a futuro es aquella que implica ajustar dicha restricción (14) del modelo, de manera tal que, por una cuestión de volumen, los usuarios Platinum quienes representan el 34% de los usuarios como se observa en la Tabla 3.4, sean aquellos usuarios que son atendidos exclusivamente por Representantes Medium y High performance. De esta manera, por tratarse de un volumen mayor de usuarios Platinum, podría ser que se logren funciones objetivo mayores. No obstante, en caso de ajustar esta restricción, se correría el riesgo que un usuario de mayor valor para la compañía sea gestionado por un Representante de menor performance, lo que podría generar también una peor experiencia.

Otra propuesta que se plantea en pos de buscar un modelo de asignación que alcance funciones objetivo de mayor valor, podría ser aquel en el que se vayan realizando iteraciones sobre el coeficiente Z de la restricción (13) de manera tal que se reserven distintos porcentajes de Representantes Medium y High Performance para un conjunto posterior de casos de incoming, y con ello brindar una mejor atención a usuarios de mayor valor para la compañía.

Por otro lado, se propone ajustar los tiempos de batches de asignación que se arman para “acumular” casos de incoming. Algunas variantes que se pensaron a modo de ejemplo podrían ser, como primera medida, seguir iterando el tiempo de batching. En la estrategia A4 se plantearon tiempos de batching de 108, 54 y 27 minutos. Una alternativa podría ser ajustar dichos tiempos de batching y ver qué sucede con la función objetivo del modelo.

Otra alternativa que se propone es armar batches y asignar diferente cantidad de usuarios de alto valor para la compañía (por ejemplo usuarios Black y VIP) entre los mejores Representantes de Customer Service disponibles. Se podría ir variando el porcentaje de usuarios Black y VIP que se designan a los mejores Representantes y ver como se ajustan los valores de las funciones objetivo.

7.2. Nuevas propuestas a desarrollar

A continuación se plantean algunas ideas que fueron surgiendo al momento del armado del modelo propuesto, en donde habría que invertir tiempo para profundizar sobre cómo y cuáles podrían ser los caminos correctos a transitar para una posterior implementación. Para ello, también habría que considerar qué esfuerzo estaría dispuesta a hacer la compañía para poder llevarlo a la práctica.

Se podría analizar el nivel de stress del usuario que se contacta y considerarlo como una variable adicional a colocarse dentro la función objetivo. Cuando se hace referencia al nivel de stress de un usuario se piensa en comprender la situación actual del usuario al momento del contacto con la compañía. A modo de ejemplo, algunas variables que podrían ser parte de dicho nivel de stress podrían tener que ver con la cantidad de consultas que hizo dicho usuario en el último tiempo. Esto hablaría del nivel de dificultad que está presentando al operar con la compañía.

Otra de dichas variables podría ser el monto económico que un usuario tiene afectado al momento de contactarse con Customer Service. Se considera a priori que no es el mismo nivel de stress que tiene un usuario que se contacta tras sufrir un error de cobro de cuota por una diferencia de 10 USD, que si el error de cobro fuera de una diferencia de 1000 USD.

Probablemente, esta variable influya en la respuesta de NPS que dé dicha persona. No sería para nada recomendable que una persona estresada sea detractora, ya que es candidata a ser una persona que en el futuro realice churn de la compañía.

Por otro lado, se propone analizar y profundizar también en patrones de comportamiento de la asignación que se realiza a lo largo de diferentes momentos del año (o del día, o de un determinado turno). A modo de ejemplo se propone investigar acerca de qué porcentaje de Representantes de High (o Medium, o Low) performance se ocupan durante el turno mañana versus qué porcentaje de ellos se ocupan en el turno tarde para comprender el motivo que hay detrás de ello. Dicho análisis podría proponer una agrupación diferente del staff dependiendo del momento del año (o del día, o del turno).

También se propone analizar cuál es el incoming que generan los diferentes perfiles de usuarios a lo largo del año, y entender el motivo que hay detrás de ello. En ciertas ocasiones, se conoce de antemano que durante determinados momentos del año, por ejemplo Navidad, día del niño, etcétera, la cantidad de transacciones que se realiza en dicha compañía de e-commerce aumenta. Las preguntas que podrían surgir de dicho análisis podrían ser:

- ¿Qué tipos de usuarios generan mayor incoming en esos días particulares?
- ¿Se tienen los perfiles de Representantes adecuados para gestionar esos casos de incoming dependiendo del perfil del usuario? En este caso, se podría verificar si los perfiles de usuarios que se contactan son Longtail, Platinum, Black o VIP, y en base a ello, determinar qué tipo de staff se desea tener disponible en estos días o eventos particulares.

Otra propuesta que a priori parece ser muy interesante para desarrollar es aquella que se enfoque en el canal online, principalmente en aquellas conversaciones que se generen a través de llamadas telefónicas entre un usuario y un Representante de Customer Service. Tal como expresan Vaikole, Mulajkar, More, Jayaswal, Dhas [18], se podrían utilizar conceptos de Machine Learning para detectar emociones y niveles de stress en usuarios. En lugar de predecir la detracción de un usuario a través del análisis de palabras que se escriben a través del canal offline, como se realizó en la corriente tesis, de manera análoga se podría considerar el nivel de stress detectado en la voz del usuario al momento de generar el caso de incoming como un parámetro para aplicar al modelo y así asignar aquellos usuarios estresados entre los mejores Representantes de Customer Service para evitar una futura detracción en la encuesta de NPS.

8. Referencias

- [1] Madan Batra, 2016, Customer Experience--An Emerging Frontier in Customer Service Excellence, University of Pennsylvania, USA.
(Link: <https://www.researchgate.net/profile/Madan-Batra/publication/341667795>)
- [2] Christopher Meyer and André Schwager, 2007, Understanding Customer Experience, Harvard Business Review, USA.
(Link: https://idcexed.com/wp-content/uploads/2021/01/Understanding_Customer_Experience.pdf)
- [3] Neeraj Sahu, Hepu Deng, Alemyehu Mollah, 2008, ABCD framework, RMIT University, Australia.
(Link: <https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1020&context=confirm2018>)
- [4] Frederick F. Reichheld, 2003, The one number you need to grow, Harvard Business Review, USA.
(Link: <https://hbr.org/2003/12/the-one-number-you-need-to-grow>)
- [5] Juan José Miranda Bront, 2019, Ride-sharing y matching centralizado, Cátedra de “Modelos de Decisión”, Universidad Torcuato Di Tella, Argentina
- [6] Lucas Novo, Modelo predictivo de detractores de casos de Customer Service, 2021, Universidad Torcuato Di Tella, Argentina.
(Link: <https://drive.google.com/drive/u/1/folders/152zXWTE0sHaYQNE5eBZ27G2m6FqZk43>)
- [7] Caren Marzban, 2004, The ROC Curve and the Area under It as Performance Measures, University of Washington, USA.
(Link: https://journals.ametsoc.org/view/journals/wefo/19/6/825_1.xml)
- [8] Sofia Visa, Brian Ramsay, Anca Ralescu, Esther van der Knaap, 2011, Confusion Matrix-based Feature Selection, University of Cincinnati, USA.
(Link: <https://www.researchgate.net/profile/Jennifer-Seitzer-2/publication/220833258>)
- [9] Bill Dimm, 2013, Accuracy and F1, Internet, Blog.
(Link: <https://blog.cluster-text.com/tag/f1-score/>)
- [10] María Gómez López, 2007, SQL - Gestor de Bases de Datos - Objeto - Relacionales de Restricciones, Sevilla, España.
(Link: <http://www.lsi.us.es/docs/doctorado/tesis/Memoria-Tesis-MTGomez.pdf>)

- [11] Hugo Manriquez, 2018, Implementación de esquema de bases de datos híbrido, México.
(Link: <https://www.researchgate.net/profile/Rommel-Toledo-Ramirez/publication/331742086>)
- [12] Luis Beccaria, 2020, Delivery en pandemia, Argentina.
(Link: https://www.ilo.org/wcmsp5/groups/public/---americas/---ro-lima/---ilo-buenos_aires/documents/publication/wcms_765155.pdf)
- [13] George B. Dantzig, 2002, Linear Programming, Department of Management Science and Engineering, Stanford University, USA.
(Link: <https://pubsonline.informs.org/doi/pdf/10.1287/opre.50.1.42.17798>)
- [14] David Sherman, Joe Zhu, 2013, Analyzing Performance in Service Organizations, Massachusetts Institute of Technology, MIT, USA.
(Link: <https://drive.google.com/drive/u/1/folders/1aArJ755v3RVKTX2BILcrWSaXt9SfQY4K>)
- [15] Deyna Castillo, 2019, Modelo de asignación de recursos limitados, Universidad Autónoma de Occidente.
(Link: <https://red.uao.edu.co/bitstream/handle/10614/11140/T08555.pdf?sequence=5&isAllo wed=y>)
- [16] Shane Henderson, Andrew Mason, 1999, Rostering By Iterating Integer Programming And Simulation, University of Auckland, New Zealand.
(Link: <https://www.researchgate.net/publication/2520240>)
- [17] Athanassios N. Avramidis, Pierre L'Ecuyer, 2005, Modeling and simulation of call centers, University of Southampton, Université de Montréal.
(Link: <https://www.researchgate.net/publication/221529841>)
- [18] S. Vaikole, S. Mulajkar, A. More, P. Jayaswal, S. Dhas, 2020, Stress Detection through Speech Analysis using Machine Learning, Department of Computer Engineering, India. (Link: <https://www.ijcrt.org/papers/IJCRT2005299.pdf>)

9. Anexos

9.1. Anexo 1: detalles de las soluciones resultantes tras la ejecución de las diferentes estrategias de asignación en cada una de las instancias consideradas

9.1.1. Cantidad de Representantes asignados en cada instancia, según el tipo de estrategia considerada

Instancias	Cantidad de casos a asignar	Cantidad de Representantes disponibles	Cantidad de representantes asignados según estrategia de asignación						
			A1	A2	A3	A4 - 1	A4 - 2	A4 - 3	A5
ene-20	741	353	346	318	342	126	131	238	64
abr-20	1239	567	542	476	550	152	162	393	105
jun-20	2277	969	955	765	943	286	301	722	275
sep-20	1391	807	791	689	783	355	365	441	117
dic-20	1554	954	935	751	922	305	334	494	132
ene-21	998	733	728	639	714	258	283	376	59
abr-21	1211	869	852	702	840	141	164	385	132
jun-21	1248	890	872	718	867	299	320	396	107
sep-21	945	735	710	598	714	254	262	302	98
dic-21	872	657	631	415	638	232	256	279	75

Tabla 9.1: Cantidad de Representantes asignados en cada instancia de tiempo, según la estrategia de asignación utilizada

9.1.2. Porcentaje de casos asignados en cada una de las estrategias utilizadas, según el perfil del Representante asignado

Instancias	Cantidad de casos a asignar	Porcentaje de casos asignados según perfil del Representante Estrategia de asignación A1			
		Bad Performance	Low Performance	Medium Performance	High Performance
ene-20	741	0,4%	10%	89%	1%
abr-20	1239	0,1%	11,8%	87,9%	0,2%
jun-20	2277	0,3%	21,8%	77,8%	0,1%
sep-20	1391	0,1%	14,9%	84,8%	0,2%
dic-20	1554	0,0%	12,6%	87,1%	0,3%
ene-21	998	0,0%	16,7%	82,4%	0,9%
abr-21	1211	0,1%	18,5%	80,3%	1,2%
jun-21	1248	0,0%	18,8%	78,5%	2,6%
sep-21	945	0,1%	24,1%	72,9%	2,9%
dic-21	872	0,2%	38,2%	60,2%	1,4%

Tabla 9.2: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A1, clasificados según el perfil del Representante asignado

		Porcentaje de casos asignados según perfil del Representante Estrategia de asignación A2			
Instancias	Cantidad de casos a asignar	Bad Performance	Low Performance	Medium Performance	High Performance
ene-20	741	0,1%	10,5%	87,7%	1,6%
abr-20	1239	0,2%	12,2%	87,2%	0,5%
jun-20	2277	0,4%	18,3%	81,2%	0,1%
sep-20	1391	0,0%	13,1%	86,2%	0,7%
dic-20	1554	0,0%	10,9%	88,7%	0,3%
ene-21	998	0,0%	15,3%	83,5%	1,2%
abr-21	1211	0,0%	17,2%	81,6%	1,2%
jun-21	1248	0,0%	16,9%	79,8%	3,3%
sep-21	945	0,1%	21,1%	75,8%	3,1%
dic-21	872	0,1%	33,1%	64,6%	2,2%

Tabla 9.3: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A2, clasificados según el perfil del Representante asignado

		Porcentaje de casos asignados según perfil del Representante Estrategia de asignación A3			
Instancias	Cantidad de casos a asignar	Bad Performance	Low Performance	Medium Performance	High Performance
ene-20	741	0,0%	4,6%	94,1%	1,3%
abr-20	1239	0,0%	7,2%	92,3%	0,6%
jun-20	2277	0,2%	13,6%	86,0%	0,1%
sep-20	1391	0,0%	5,3%	93,7%	0,9%
dic-20	1554	0,0%	9,4%	90,2%	0,5%
ene-21	998	0,0%	13,9%	85,0%	1,1%
abr-21	1211	0,0%	14,7%	84,0%	1,3%
jun-21	1248	0,0%	11,7%	85,2%	3,1%
sep-21	945	0,0%	15,1%	81,5%	3,4%
dic-21	872	0,0%	24,4%	72,8%	2,8%

Tabla 9.4: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A3, clasificados según el perfil del Representante asignado

		Porcentaje de casos asignados según perfil del Representante Estrategia de asignación A4 - 1			
Instancias	Cantidad de casos a asignar	Bad Performance	Low Performance	Medium Performance	High Performance
ene-20	741	0,0%	0,0%	94,0%	6,0%
abr-20	1239	0,0%	0,0%	97,6%	2,4%
jun-20	2277	0,0%	1,6%	97,3%	1,1%
sep-20	1391	0,0%	0,0%	95,4%	4,6%
dic-20	1554	0,0%	0,0%	90,2%	9,8%
ene-21	998	0,0%	0,0%	92,8%	7,2%
abr-21	1211	0,0%	0,0%	76,4%	23,6%
jun-21	1248	0,0%	0,0%	69,8%	30,2%
sep-21	945	0,0%	0,0%	68,5%	31,5%
dic-21	872	0,0%	0,0%	75,6%	24,4%

Tabla 9.5: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A4 - 1, clasificados según el perfil del Representante asignado

		Porcentaje de casos asignados según perfil del Representante Estrategia de asignación A4 - 2			
Instancias	Cantidad de casos a asignar	Bad Performance	Low Performance	Medium Performance	High Performance
ene-20	741	0,0%	0,0%	72,0%	28,0%
abr-20	1239	0,0%	0,0%	95,5%	4,5%
jun-20	2277	0,0%	0,0%	97,9%	2,1%
sep-20	1391	0,0%	0,0%	95,4%	4,6%
dic-20	1554	0,0%	0,0%	72,7%	27,3%
ene-21	998	0,0%	0,0%	71,6%	28,4%
abr-21	1211	0,0%	0,0%	60,7%	39,3%
jun-21	1248	0,0%	0,0%	69,9%	30,1%
sep-21	945	0,0%	0,0%	68,1%	31,9%
dic-21	872	0,0%	0,0%	75,0%	25,0%

Tabla 9.6: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A4 - 2, clasificados según el perfil del Representante asignado

		Porcentaje de casos asignados según perfil del Representante Estrategia de asignación A4 - 3			
Instancias	Cantidad de casos a asignar	Bad Performance	Low Performance	Medium Performance	High Performance
ene-20	741	0,0%	0,0%	92,7%	7,3%
abr-20	1239	0,0%	1,0%	96,4%	2,6%
jun-20	2277	0,0%	1,4%	97,6%	1,1%
sep-20	1391	0,0%	1,2%	94,2%	4,6%
dic-20	1554	0,0%	1,1%	90,2%	9,8%
ene-21	998	0,0%	0,0%	67,4%	32,6%
abr-21	1211	0,0%	0,0%	76,2%	23,8%
jun-21	1248	0,0%	0,0%	69,2%	30,8%
sep-21	945	0,0%	0,0%	68,3%	31,7%
dic-21	872	0,0%	0,0%	74,9%	25,1%

Tabla 9.7: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A4 - 3, clasificados según el perfil del Representante asignado

		Porcentaje de casos asignados según perfil del Representante Estrategia de asignación A5			
Instancias	Cantidad de casos a asignar	Bad Performance	Low Performance	Medium Performance	High Performance
ene-20	741	0,0%	0,0%	82,1%	17,9%
abr-20	1239	0,0%	0,0%	93,8%	6,2%
jun-20	2277	0,0%	0,0%	97,1%	2,9%
sep-20	1391	0,0%	0,0%	88,1%	11,9%
dic-20	1554	0,0%	0,0%	77,9%	22,1%
ene-21	998	0,0%	0,0%	72,4%	27,6%
abr-21	1211	0,0%	0,0%	50,3%	49,7%
jun-21	1248	0,0%	0,0%	42,3%	57,7%
sep-21	945	0,0%	0,0%	37,5%	62,5%
dic-21	872	0,0%	0,0%	51,9%	48,1%

Tabla 9.8: Porcentaje de casos asignados en cada instancia de tiempo por la estrategia de asignación A5, clasificados según el perfil del Representante asignado

9.2. Anexo 2: queries utilizadas

9.2.1. Query utilizada para descargar incoming con su respectiva información [1]:

```
create multiset volatile table DET, no log as (  
  
SELECT  
  
NPS.cas_case_id as CASE_ID, -- número de caso de contacto  
CUS_CUST_ID, -- id del usuario que se contacta  
CAST (INC.contact_date_id AS DATE)/100+190000 as MES_ID, -- mes del año  
INC.USER_LDAP, -- rep ID  
INC.INCOMING_TYPE, -- tipo de incoming  
INC.CS_BU as BU, -- unidad de negocio  
INC.CS_CENTRO as CENTRO,  
INC.sit_site_id as SITE, -- País donde se origina el contacto  
INC.cas_contact_origin as ORIGEN_CONTACTO, -- origen de contacto (chat, click to call, mail =  
FORM)  
INC.cas_form_id as FORM_ID, -- numero de mail  
(CASE WHEN BODY_TXT is null then 'Sin texto'  
    WHEN BODY_TXT is not null then 'Con texto'  
    ELSE 'NA' end) as Flag_texto,  
(CASE WHEN INC.CAS_USER_SEGMENT in (INC.ML_SELLER_NAME, INC.MP_SELLER_NAME)  
then 'SELLER'  
    WHEN INC.CAS_USER_SEGMENT=INC.ML_BUYER_NAME then 'BUYER'  
    ELSE 'REVISAR' end) as Rol,  
INC.cas_user_segment as NIVEL_USUARIO, -- tipo de usuario  
INC.proceso_agrupado_NPS as PROCESO_AGRUPADO, -- tipo de proceso  
INC.user_team_channel,  
INC.USER_ROLE as EXPERIENCIA_REP,  
NPS.RES_NPS,  
(CASE WHEN NPS.RES_NPS in (0,1,2,3,4,5,6) then '-1'  
    WHEN NPS.RES_NPS in (7,8) then '0'  
    WHEN NPS.RES_NPS in (9,10) then '1'  
    ELSE 'NA' end) AS NPS,  
TXT.fc_body_txt as BODY_TXT  
  
FROM  
  
WHOWNER.BT_CX_CONTACTS INC  
INNER JOIN WHOWNER.BT_CX_NPS_DETAIL NPS on NPS.CAS_CASE_ID = INC.CAS_CASE_ID  
INNER JOIN WHOWNER.LK_CX_FIRST_CONTACT TXT on TXT.CAS_CASE_ID = NPS.CAS_CASE_ID  
  
WHERE
```

```
CENTRO= 'Hispanos'-- únicamente nos quedamos con análisis de texto de habla hispana
And
MES_ID in
('202001','202002','202003','202004','202005','202006','202007','202008','202009','202010','2
02011','202012','202101','202102','202103','202104','202105','202106','202107','202108','202
109','202110','202111','202112') -- filtro meses y años del período 2020 y 2021 --
and INC.INCOMING_TYPE in ('OUTGOING_FIRST_CONTACT') -- únicamente los contactos que
generaron OFC
and INC.QUEUE_ID not in ('109','110') -- excluyo casos de uso de bugs
and INC.FLAG_EXCLUDE_NUMERATOR_CR = '0' -- excluyo los casos que no se consideran en el
Contact Rate
and INC.ORIGIN_TABLE in ('BT_CX_INCOMING_CR')
and proceso_agrupado is not null
and ORIGEN_CONTACTO in ('FORM')
and TXT.FC_TYPE in ('FORM') -- filtro para excluir aquellos casos en que solo el rep es quien
escribe, sin tener ninguna respuesta del usuario
and Rol not in ('REVISAR')
and Flag_texto = 'Con texto'
and USER_TEAM_CHANNEL is not null
and USER_TEAM_CHANNEL not in ('SIN CLASIFICAR')
and FORM_ID is not null

) with data primary index (CASE_ID) on commit preserve rows;

SELECT count (*) from DET;
SELECT * from DET;
```

9.2.2. Query utilizada para descargar el monto transaccionado para un determinado cluster de usuarios:

```
SELECT

cus_cust_id_buy,
tpv_segment_id,
tpv_segment_detail,
pay.pay_ope_mlibre_flag transaccion_on,
sum(pay.tpv_dol_amt) TPV, – suma del TPV en dólares de cada usuario
count(*) TPN

FROM

WHOWNER.LK_MP_PAY_PAYMENTS pay
inner join WHOWNER.APP_USER_LOADER_CUST_ID lc
on pay.cus_cust_id_buy = lc.cus_cust_id

WHERE

pay_status_id in ('approved')
and pay.pay_move_date BETWEEN '2021-07-01' and '2021-12-27'
and lc.loader_code = "xxx"
GROUP BY 1,2,3,4;
```

A modo de comentario de la query anterior que vale mencionar es que aquello que se menciona como “loader_code” en la anteúltima fila de la query, es un filtro utilizado cuando únicamente se quiere filtrar por un determinado número de usuarios. En nuestro caso, se generó un loader_code del cluster total de usuarios que generaron incoming entre 2020 y 2021, y a ellos se les determinó el TPV (monto transaccionado) en USD para generar luego los cluster de usuarios correspondientes.

9.3. Anexo 3: software de gestión de bases de datos

A continuación, se muestran screenshots de tablas (sus respectivos campos) que fueron utilizados para realizar las consultas en las bases de datos, como ser el número de caso, el país al que corresponde un determinado caso de incoming, qué Representante de Customer Service fue quien gestionó el caso, el NPS del caso, el Body_Text del mismo (texto que se analizó durante la ejecución del modelo NLP), etcétera.

9.3.1. Tabla de incoming:

Teradata - DW / HOWNER . BT_CX_INCOMING_CR

☆ Star Watch Compose More

Tabla de Incoming para Contact Rate
BT_CX_INCOMING_CR

1 Warning 1 Endorsement

Overview Columns 48 Samples 100 Filters 857 Joins 399 Lineage Queries 298

#1	★	✓	Column	Title	Type	Popularity
1	☆	+1	CAS_CASE_ID	Número de caso		
2	☆		CLA_CLAIM_ID	ID del reclamo (Mediaciones)		
3	☆	+1	CI_ID	ID de la interacción.		
4	☆		USER_LDAP	LDAP del rep que gestionó el caso		
5	☆		USER_TEAM_ID	ID del equipo del Rep. que gestionó el caso		
6	☆		INCOMING_CASE_DATE	Fecha de creación del caso		
7	☆		INCOMING_CASE_DT	Fecha de creación del caso sin hora		
8	☆		FIRST_OUTGOING_CASE_DATE	Fecha de primer outgoing		
9	☆		FIRST_OUTGOING_CASE_DT	Fecha de primer outgoing sin hora		
10	☆		WOM_CONT_ID	ID Solución de primer respuesta		
11	☆		CI_REASON_ID	Reason de Cierre sin respuesta		
12	☆		PROCESS_ID	ID Proceso del primer outgoing		
13	☆		QUEUE_ID	ID Equipo del primer outgoing		
14	☆		INCOMING_TYPE	Tipo de incoming		
15	☆		SOU_ID	Source ID de ingreso del caso		

9.3.2. Tabla de NPS:

Teradata - DW / HOWNER . BT_CX_NPS_DETAIL

☆ Star Watch Compose More

NPS detallado por encuesta
BT_CX_NPS_DETAIL

Overview Columns 50 Samples 100 Filters 348 Joins 93 Lineage Queries 48

#1	★	✓	Column	Title	Type	Popularity
1	☆		RES_RESPONSE_ID			
2	☆		RES_END_DATE	Novinhos Jan.20		
3	☆		SIT_SITE_ID			
4	☆		CAS_CASE_ID	Cuyas Case Id		
5	☆		CLA_CLAIM_ID			
6	☆		SURVEY_DATE_SURVEY	Survey Date Survey		
7	☆		SRV_SENT_BY			
8	☆		QUE_QUEUE_ID			
9	☆		QUE_QUEUE_NAME	Que Queue Name		
10	☆		CX_TEAM_ID			
11	☆		CX_TEAM_NAME	Caixa Team Name		
12	☆		PRO_PROCESS_ID			
13	☆		PRO_PROCESS_NAME	encuestas btc 2		
14	☆		CX_USER_LDAP	Caixa User Ldap		
15	☆		CX_USER_NAME	Caixa User Name		

9.3.3. Tabla con el detalle del contenido del contacto de usuario:

Teradata - DW / WHOWNER . LK_CX_FIRST_CONTACT

Please provide a title
LK_CX_FIRST_CONTACT

☆ Star Watch Compose More

Overview Columns 16 Samples 100 Filters 206 Joins 26 Lineage Queries 21

Contenido de la tabla

Tabla con detalle del contacto (textos en nuestro caso)

Frecuencia de uso

#	★	✓	Column	Title	Type	Popularity
1	☆		FC_ID	First contact ID		
2	☆		FC_BODY_TXT	Body text		
3	☆		FC_DATE_CREATED	Date created		
4	☆		FC_EMAIL_FROM	Email from		
5	☆		FC_FROM_NAME	From Name		
6	☆		FC_HEADERS	Headers		
7	☆		FC_INCOMING_DATE	Incoming date		
8	☆		CAS_SUBJECT	Subject		
9	☆		FC_TYPE	Type		
10	☆		CAS_CASE_ID	Case ID		
11	☆		FC_EXTRA_DATA	Extra data		
12	☆		FC_MAIL_ID	Mail ID		
13	☆		FC_EMAILS_CC	Emails CC		
14	☆		AUD_INS_DT	Fecha de auditoria - Insert		
15	☆		AUD_IPO_DT	Fecha de auditoria - Update		