UNIVERSIDAD CENTRAL
VICERRECTORÍA ACADÉMICA

ESCUELA DE INGENIERÍA INDUSTRIAL

EVALUACIÓN DEL MÉTODO ACTUAL DE SELECCIÓN DE MODELOS PREDICTIVOS INTEGRANDO CAMBIOS Y PARÁMETROS QUE OPTIMICEN LA PRECISIÓN DEL PRONÓSTICO EN EL PROYECTO BANCO

TRABAJO FINAL DE GRADUACIÓN PARA OPTAR POR EL GRADO ACADÉMICO DE BACHILLERATO EN INGENIERÍA INDUSTRIAL

ESTUDIANTE: ADRIEL ANDRÉS VILLALOBOS ESQUIVEL

TUTOR: ING. FRANCISCO HERNÁNDEZ VILLAGRA

SEDE METROPOLITANA, COSTA RICA

DICIEMBRE, 2025

CONTENIDO

CONTENIDO I
TABLAS V
FIGURAS VI
DEDICATORIA X
AGRADECIMIENTOS XI
EPÍGRAFE XII
RESUMEN XIII
CAPÍTULO I. PROBLEMA 1
1.1 PLANTEAMIENTO DEL PROBLEMA 2
1.2 OBJETIVOS 3
1.2.1 Objetivo general 3
1.2.2 Objetivos específicos 3
1.3 JUSTIFICACIÓN 3
1.4 ANTECEDENTES 4
1.4.1 Antecedentes nacionales 4
1.4.2 Antecedentes internacionales 7
1.5 PROYECCIONES 9
1.5.1 Alcances 9
1.5.2 Limitaciones 10
1.6 IDENTIFICACIÓN DE LA EMPRESA 10
1.6.1 Principios y propósito organizacional 11
1.6.2 Contexto empresarial 11
1.6.3 Estructura organizacional 12
1.6.4 Cantidad de empleados 13
1.6.5 Tipos de productos o servicios 13
CAPÍTULO II. MARCO TEÓRICO 17
2.1 FILOSOFÍA O MARCO DE REFERENCIA 18
2.2 METODOLOGÍA 19
2.3 HERRAMIENTAS 23

2.1.1 Project charter 23
2.1.2 Análisis de stakeholders, modelo Gardner 24
2.1.3 Diagrama de árbol CTQ 26
2.1.4 Mapa conceptual 27
2.1.5 Diagrama PEPSU (SIPOC) 28
2.1.6 Diagrama de flujo 30
2.1.7 Bases de datos o registros históricos 31
2.1.8 Medición del error de pronóstico 32
2.1.9 Histograma 33
2.1.10 Indicadores cuantitativos (KPI) 34
2.1.11 Gráfico de pastel y barras 38
2.1.12 Lluvia de ideas 40
2.1.13 Diagrama de Ishikawa 42
2.1.14 Multivoto 43
2.1.15 Diagrama de Pareto 45
2.1.16 5 porqués 46
2.1.17 Diagrama de dispersión 47
2.1.18 Matriz de decisión 48
2.1.19 Repositorio web 49
2.1.20 Auditoría interna 50
2.1.21 Reuniones 50
2.1.22 Diagrama de Gantt 52
CAPÍTULO III. MARCO METODOLÓGICO 54
3.1 ENFOQUE DE LA INVESTIGACIÓN 55
3.2 MÉTODO DE LA INVESTIGACIÓN 57
3.3 FUENTES DE INFORMACIÓN 58
3.3.1 Project charter 59
3.4 VARIABLES DE ANÁLISIS 60
3.5 INSTRUMENTOS 62
3.6 PROCESO PARA LA RECOLECCIÓN Y ANÁLISIS DE DATOS 62
CAPÍTULO IV. ANÁLISIS DE RESULTADOS 64

4.1 DEFINIR 65
4.1.1 Análisis de stakeholders 67
4.1.2 Diagrama de árbol de CTQ 68
4.1.3 Diagrama PEPSU (SIPOC) del pronóstico de llamadas 69
4.1.4 Mapa conceptual del dimensionamiento de personal 71
4.1.5 Diagrama de flujo del proceso de pronóstico de llamadas 72
4.2 MEDIR 74
4.2.1 Bases de datos y registros históricos 74
4.2.2 Histograma 75
4.2.3 Error de pronóstico 75
4.2.4 Impacto económico 80
4.3 ANALIZAR 88
4.3.1 Lluvia de ideas 88
4.3.2 Diagrama de Ishikawa 89
4.3.3 Multivoto 92
4.3.4 Diagrama de Pareto 94
4.3.5 5 porqués 94
CAPÍTULO V. PROPUESTA 97
5.1 MEJORAR 98
5.1.1 Lluvia de ideas 99
5.1.2 Tabla descriptiva de errores estadísticos 100
5.1.3 Matriz de decisión 101
5.1.4 Nuevo método de selección (PBF 2.0) 103
5.2 CONTROLAR 121
5.2.1 Control de versiones 121
5.2.2 Auditorías internas 123
5.2.3 Reuniones periódicas 124
5.3 RENTABILIDAD DE LAS SOLUCIONES 126
5.3.1 Diagrama de Gantt 128
CAPÍTULO VI. CONCLUSIONES Y RECOMENDACIONES 129
CONCLUSIONES 130

Recomendaciones 131
REFERENCIAS 132
APÉNDICES Y ANEXOS 141
APÉNDICE 1: Glosario de términos 142
APÉNDICE 2: Auditoría interna PBF 2.0 144
APÉNDICE 3: Plantilla de Excel para la revisión de resultados en las reuniones periódicas 145
APÉNDICE 4: Multivoto 146
ANEXO 1: Registro histórico, julio 2024 147
ANEXO 2: Registro histórico, agosto 2024 148
ANEXO 3: Registro histórico, septiembre 2024 149
ANEXO 4: Registro histórico, octubre 2024 150
ANEXO 5: Registro histórico, noviembre 2024 151
ANEXO 6: Registro histórico, diciembre 2024 152
ANEXO 7: Registro histórico, enero 2025 153
ANEXO 8: Registro histórico, febrero 2025 154
ANEXO 9: Registro histórico, marzo 2025 155
ANEXO 10: Registro histórico, abril 2025 156
ANEXO 11: Registro histórico, mayo 2025 157
ANEXO 12: Registro histórico, junio 2025 158

TABLAS

Tabla 1.1: Cantidad de empleados por área 13
Tabla 2.1: Ejemplo de una matriz de decisión 49
Tabla 3.1: Project charter para la investigación 59
Tabla 3.2: Variables de la investigación por objetivo específico 61
Tabla 4.1: Multas por el incumplimiento de un SLA 66
Tabla 4.2: Ejemplo de la combinación de modelos 73
Tabla 4.3: Registro histórico mensual, julio 2024–junio 2025 74
Tabla 4.4: Ejemplo de un error de precisión del pronóstico 76
Tabla 4.5: Consolidado de resultados del EPP 77
Tabla 4.6: Precisión del pronóstico por modelo predictivo 78
Tabla 4.7: Comparativo de pérdidas, escenarios 1 y 2 88
Tabla 4.8: Multivoto de las causas derivadas del diagrama de Ishikawa 93
Tabla 4.9: Multivoto ordenado 93
Tabla 5.1: Descripción de los parámetros estadísticos 100
Tabla 5.2: Criterios y peso para la matriz de decisión 102
Tabla 5.3: Puntaje de la matriz de decisión 102
Tabla 5.4: Puntaje ponderado de la matriz de decisión 103
Tabla 5.5 Comparativo de las pérdidas del método actual y el método nuevo 120

FIGURAS

Figura 1.1: Ubicación de la empresa NETCOM 12
Figura 1.2: Organigrama de NETCOM BUSINESS CONTACT CENTER 12
Figura 1.3: Tipos de productos 14
Figura 1.4: Diagrama de flujo del proceso productivo 15
Figura 2.1: DMAIC 20
Figura 2.2: Ejemplo de un project charter 24
Figura 2.3: Ejemplo de stakeholders 25
Figura 2.4: Ejemplo de un diagrama de árbol 27
Figura 2.5: Ejemplo de un mapa conceptual 28
Figura 2.6: Ejemplo de un diagrama PEPSU (SIPOC) 29
Figura 2.7: Ejemplo de un diagrama de flujo 31
Figura 2.8: Ejemplo de un histograma 34
Figura 2.9: Ejemplo de un gráfico de barras 40
Figura 2.10: Ejemplo de una lluvia de ideas 41
Figura 2.11: Diagrama de Ishikawa 43
Figura 2.12: Ejemplo de un multivoto 45
Figura 2.13: Ejemplo de un diagrama de Pareto 46
Figura 2.14: Ejemplo de un 5 porqués 47
Figura 2.15: Ejemplo de un gráfico de dispersión 48
Figura 2.16: Ejemplo de un diagrama de Gantt 53
Figura 3.1: Fases del proceso de la investigación cuantitativa 55
Figura 3.2: Fases del proceso de la investigación cualitativa 56
Figura 3.3: Método de la investigación 57
Figura 3.4: Diagrama de flujo del proceso de recolección de datos 63
Figura 4.1: Análisis de stakeholders 67
Figura 4.2: Diagrama de árbol de CTQ 69
Figura 4.3: Diagrama PEPSU (SIPOC) del pronóstico de llamadas 70
Figura 4.4: Mapa conceptual del dimensionamiento de personal 71
Figura 4.5: Diagrama de flujo del proceso de pronóstico de llamadas 72

Figura 4.6: Histograma de los datos históricos de llamadas, julio 2024–junio 2025 75
Figura 4.7: Gráfico de barras de la precisión del pronóstico diaria por mes del método actual 77
Figura 4.8: Gráfico de barras de la precisión del pronóstico diaria por mes del método actual 78
Figura 4.9: Gráfico de la precisión de los modelos predictivos del año 2024 79
Figura 4.10: Gráfico de la precisión de los modelos predictivos del año 2025 80
Figura 4.11: Función SLA en Excel 82
Figura 4.12: Gráfico de barras del dimensionamiento del método actual (A) vs. el dimensionamiento necesario real (B) 84
Figura 4.13: Gráfico de barras de la diferencia de agentes en el dimensionamiento del método actual (A) vs. el dimensionamiento necesario real (B) 84
Figura 4.14: Costos por sobre- y subdimensionamiento del método actual (A) vs. el dimensionamiento necesario real (B) 85
Figura 4.15: Gráfico de barras del dimensionamiento necesario real (B) vs. el personal real (C) 86
Figura 4.16: Gráfico de barras del dimensionamiento necesario real (B) vs. el personal real (C) 87
Figura 4.17: Gráfico de los costos por sobre- y subdimensionamiento necesario real (B) vs. personal real (C) 87
Figura 4.18: Lluvia de ideas 89
Figura 4.19: Diagrama de Ishikawa 90
Figura 4.20: Diagrama de Pareto 94
Figura 5.1: Lluvia de ideas 99
Figura 5.2: Ejemplo de selección de la fecha en la Hoja de Entrenamiento en el PBF 2.0 104
Figura 5.3: Ejemplo de una tabla de datos reales en la Hoja de Entrenamiento en el PBF 2.0 105
Figura 5.4: Ejemplo de la tabla de precisión del pronóstico en la Hoja de Entrenamiento en el PBF 2.0 106
Figura 5.5: Ejemplo de la tabla MAD en la Hoja de Entrenamiento en el PBF 2.0 107

Figura 5.6: Ejemplo de la tabla MAPE en la Hoja de Entrenamiento en el PBF 2.0 108
Figura 5.7: Ejemplo de la tabla RMSE en la Hoja de Entrenamiento en el PBF 2.0 109
Figura 5.8: Ejemplo de la tabla de resultados de los parámetros estadísticos en la Hoja de Entrenamiento en el PBF 2.0 110
Figura 5.9: Ejemplo de la tabla de resultados de los parámetros estadísticos en la Hoja de Entrenamiento en el PBF 2.0 111
Figura 5.10: Ejemplo de la tabla de consolidado de los resultados de los modelos predictivos en la Hoja de Selección del Modelo en el PBF 2.0..... 112
Figura 5.11: Ejemplo de las tablas del histórico por mes en la Hoja de Selección del Modelo en el PBF 2.0 113
Figura 5.12: Ejemplo de la tabla de selección y ajuste del modelo predictivo en la Hoja de Selección del Modelo en el PBF 2.0..... 114
Figura 5.13: Ejemplo de la Hoja de Histórico en el PBF 2.0 115
Figura 5.14: Ejemplo de la tabla de entrenamiento en la Hoja de BD Forecast PRO en PBF 2.0..... 116
Figura 5.15: Ejemplo de la tabla de pronóstico de la Hoja de BD Forecast PRO en PBF 2.0..... 117
Figura 5.16: Ejemplo de la Hoja de Vínculos en el PBF 2.0 117
Figura 5.17: Gráfico de barras del dimensionamiento necesario real (B) vs. el dimensionamiento con el modelo de selección experta 119
Figura 5.18: Gráfico de barras de la diferencia de agentes, dimensionamiento necesario real (B) vs. dimensionamiento con el modelo de selección experta..... 119
Figura 5.19: Costos por sobre- y subdimensionamiento necesario real (B) vs. dimensionamiento con el modelo de selección experta 120
Figura 5.20: Gráfico de barras comparativo del método actual vs. el método nuevo (PBF 2.0) 121
Figura 5.21: Formato de nombre para el almacenamiento del nuevo PBF 2.0..... 122
Figura 5.22: Estructura de almacenamiento del nuevo PBF 2.0..... 123
Figura 5.23: Ejemplo del apéndice 2 correspondiente al formato de auditoría del nuevo PBF 2.0..... 124

Figura 5.24: Ejemplo de las tablas en la plantilla de control de las reuniones periódicas 125
Figura 5.25: Ejemplo de las tablas en la plantilla de control de las reuniones periódicas 126
Figura 5.26: Diagrama de Gantt del desarrollo del proyecto e implementación 128

DEDICATORIA

A Dios, fuente de sabiduría y fortaleza, por guiarme en todo.

A mi esposa, por su amor, paciencia y apoyo constante en cada proyecto.

A mi madre, por darme el privilegio de que mi única preocupación fuera estudiar.

A mi familia, por su apoyo incondicional.

A mis jefes, por su guía, así como por escuchar mis propuestas y creer en mí.

A mi amigo Mario Castro, quien me enseñó todo lo que sé de este gremio.

Y a todos los que creyeron en mí y me motivaron a seguir adelante.

AGRADECIMIENTOS

En primer lugar, agradezco a Dios por permitirme cumplir una meta más.

A la Universidad Central y a los docentes de la Escuela de Ingeniería Industrial, por el conocimiento y la orientación brindada durante el desarrollo de la carrera.

A la empresa NETCOM BUSINESS CONTACT CENTER, por permitir el desarrollo de este estudio.

Al tutor Francisco Hernández Villagra, por su tiempo, orientación, disponibilidad y acompañamiento en el desarrollo de este proyecto.

A la profesora Joel Picado Sanabria, por su dedicación, tutoriales e instrucción; además, por impulsarnos a realizar trabajos de excelencia y prepararnos para este proyecto.

A mi esposa, por apoyarme, acompañarme e impulsarme con cada proyecto en esta carrera.

Finalmente, a mi familia, por ser mi base, mi inspiración y mi fuente de fortaleza.

EPÍGRAFE

Las técnicas estadísticas son inútiles si no se combinan con el conocimiento y la experiencia adecuados en la materia. Son un complemento, no un sustituto.

George Box.

RESUMEN

El proyecto se realizó en la empresa NETCOM BUSINESS CONTACT CENTER, ubicada en San Pedro de Montes de Oca, en el Departamento de Workforce Management (WFM). El estudio se centró en el método actual de selección del pronóstico de llamadas utilizado en el proceso de dimensionamiento y planeamiento de personal del Proyecto Banco.

Al respecto, durante el desarrollo del capítulo 4, se identificó que el actual método de selección del pronóstico de llamadas basado en la combinación diaria de modelos predictivos generaba un error de pronóstico considerable en los resultados, lo que afectaba directamente los procesos derivados como el dimensionamiento de personal. Así, mediante herramientas como el *stakeholder*, diagramas de flujo e Ishikawa, se definieron los requerimientos operativos y las causas que limitan la precisión del pronóstico. Los resultados del análisis evidenciaron inconsistencias en el pronóstico de la demanda, además de un sobre- y subdimensionamiento de personal en diferentes meses, esto representó un impacto económico aproximado de $ 462 411 durante el periodo de julio 2024–junio 2025.

En la fase de mejora, se llevó a cabo un nuevo método de selección del pronóstico (PBF 2.0) que integra parámetros estadísticos de referencia como EPP, MAD, MAPE, RMSE y R^2, lo cual permite comparar objetivamente el desempeño de los modelos predictivos y seleccionar el más preciso. Con la implementación del nuevo método, se consiguió una reducción en el error medio y una mayor estabilidad en los resultados. Sumado a lo anterior, se establecieron herramientas de control como auditorías internas, reuniones periódicas y un control de versiones, con la finalidad de sostener el proceso y la trazabilidad de los datos. De este modo, los resultados obtenidos confirman que el objetivo general del estudio se cumplió, al optimizar la selección del pronóstico de llamadas, logrando una mejora en la precisión de llamadas con la integración de parámetros identificados tras la evaluación del actual método.

Palabras clave: DMAIC, pronóstico de llamadas, parámetros estadísticos, Workforce Management.

CAPÍTULO I. PROBLEMA

1.1 PLANTEAMIENTO DEL PROBLEMA

El presente estudio se realiza en la empresa especializada en el área de telecomunicaciones NETCOM BUSINESS CONTACT CENTER, ubicada en San Pedro de Montes de Oca, San José, Costa Rica, específicamente en el Departamento de Workforce Management (WFM), encargado de dimensionar el personal necesario para atender la demanda de llamadas pronosticada.

Ahora bien, el problema en el que se centra este proyecto es el error de precisión del pronóstico de llamadas, las cuales son la variable base en el cálculo del requerimiento de personal necesario, proceso que se efectúa con la herramienta estadística Forecast PRO.

Al respecto, el procedimiento establecido por la jefatura es utilizar un archivo de Excel en el que se consolida todo el resultado de Forecast PRO y se discrimina el mejor modelo de pronóstico por día. Lo anterior provoca una mezcla de modelos de pronóstico que predice tendencias y estacionalidades modeladas por cada uno de estos.

Debido a la estructura de costos de la empresa y los requisitos de cada contrato, cada agente necesario tiene un costo aproximado de $ 2 200 por mes. Por consiguiente, si la desviación en el dimensionamiento se sobredimensiona, puede provocar sobrecostos; no obstante, si se subdimensiona por una demanda mayor a la pronosticada, puede ocasionar ganancias no percibidas y posibles multas por incumplimiento. Adicional, los agentes no pueden ser compartidos con otros proyectos por cláusulas del contrato.

Por lo tanto, se lleva a cabo un estudio de errores estadísticos con el fin de optimizar el método de selección de pronósticos (archivo de Excel llamado PBF), para que discrimine cada modelo estadístico completo y, así, escoger de una manera estandarizada y con bases matemáticas el que mejor se adapte a la demanda histórica del proyecto, que ronda en promedio las 159 264 llamadas mensuales.

1.2 OBJETIVOS

1.2.1 Objetivo general

Evaluar el actual método de selección del modelo predictivo de llamadas de la empresa NETCOM BUSINESS CONTACT CENTER, identificando oportunidades de mejora y parámetros que optimicen la selección del modelo predictivo.

1.2.2 Objetivos específicos

- Analizar el actual método de selección del modelo predictivo de llamadas mediante la revisión detallada de los datos históricos de los últimos 12 meses, cuantificando el error del modelo generado y potenciando áreas de mejora.
- Validar oportunidades de mejora, incluyendo cambios y parámetros al modelo actual, que optimicen la selección y el pronóstico del modelo predictivo.
- Recomendar la implementación de un método de selección del modelo predictivo de llamadas que integre cambios y mejoras que optimicen el pronóstico de llamadas de la empresa NETCOM BUSINESS CONTACT CENTER.

1.3 JUSTIFICACIÓN

Cuando la capacidad de un sistema de producción de servicios se atribuye totalmente al recurso humano, la desviación que presente el dimensionamiento de personal necesario para atender la demanda es crítica, ya que de este recurso no se puede prescindir o apagar por un tiempo como se haría con una máquina. Asimismo, este recurso está amparado por la ley y tiene un costo intrínseco por formación, curva de aprendizaje, cargas sociales, entre otros.

Además de los costos directos de los recursos humanos mencionados previamente, existe un impacto asociado al *burnout* de los agentes por los altos niveles de ocupación producto de un subdimensionamiento. Lo anterior desencadena un decrecimiento de la productividad por un aumento en el tiempo promedio de atención de llamadas y en la rotación, resultado de este agotamiento.

Por lo expuesto, el estudio pretende crear métodos de selección del modelo predictivo de llamadas agregando parámetros estadísticos que optimicen dicha selección y el error en la precisión del pronóstico, para establecer un proceso estandarizado de selección con una base matemática y estadística que lo respalde, a fin de mejorar la precisión del pronóstico y, a su vez, disminuir el error en la precisión del pronóstico y las pérdidas causadas por este, las cuales rondan los $ 462 411 desde julio 2024 hasta junio 2025.

1.4 ANTECEDENTES

1.4.1 Antecedentes nacionales

Cargill (Costa Rica)

Guerrero et al. (2019), en su proyecto final de graduación para optar al grado de Licenciatura en Ingeniería Industrial en la Universidad de Costa Rica, titulado: *Rediseño de los procesos de planificación y administración de inventarios del CEDI Metropolitano de la empresa Cargill,* plantean como objetivo de la investigación rediseñar los procesos de planificación y administración de inventarios del CEDI Metropolitano, de tal manera que esto permita mejorar el error de pronóstico y los costos de las actividades logísticas, así como obtener un nivel de satisfacción del cliente aceptable por la compañía. En conclusión, desarrollan métodos de pronóstico y mediciones comparativas de errores estadísticos como el MAPE (error porcentual absoluto medio) en el proceso de planificación para medir los resultados del pronóstico.

Este antecedente aporta al desarrollo de este proyecto una referencia directa acerca del uso de mediciones estadísticas para la validación y medición de los resultados de pronóstico utilizados en el proceso de planificación, lo que resulta en una similitud con el proceso principal de este proyecto.

Laboratorios Faryvet S. A. (Costa Rica)

Alfaro et al. (2019), en su tesis para optar al grado de Licenciatura en Ingeniería Industrial en la Universidad Costa Rica, denominada: *Rediseño del sistema de planificación y*

control de la producción del área de premezclas de la empresa Laboratorios Faryvet S. A., establecen como objetivo rediseñar el sistema de planificación y control de la producción de la división de premezclas en Laboratorios Faryvet S. A., con el fin de disminuir el error de pronóstico, el desabastecimiento de materias primas y los costos de mano de obra directa de la empresa. En conclusión, elaboran un rediseño del sistema de planificación y, dentro de sus indicadores de éxito, utilizan el porcentaje del error de pronóstico, el cual mejora hasta en un 60,25 %.

En este antecedente se evidencia la importancia que tiene el error de pronóstico en el desempeño de los procesos dependientes de la proyección de la demanda y las mejoras posibles al reducir la variación de este.

Grupo CIISA Food Service (Costa Rica)

Alán et al. (2022), en su proyecto de graduación para optar al grado de Licenciatura en Ingeniería Industrial en la Universidad de Costa Rica, llamado: *Diseño de un sistema de planificación y control de inventario del Grupo CIISA Food Service,* formulan como objetivo diseñar un sistema de planificación y control de inventario en Grupo CIISA Food Service, con la finalidad de disminuir las pérdidas por producto dañado, mejorar la exactitud del inventario y satisfacer el nivel de servicio del cliente. En conclusión, durante el desarrollo de su estudio, se utiliza el error de pronóstico (MAPE) como indicador de éxito para seleccionar el mejor modelo para cada serie de datos, resultando Winters el más recurrente.

Este antecedente refuerza el uso de parámetros estadísticos para medir el desempeño de los modelos predictivos y como métrica para seleccionar el indicado, concluyendo con un modelo para cada serie de datos, lo que refuerza la necesidad de seleccionar solo un modelo y no la combinación de estos.

Empresa ALRO (Costa Rica)

Alfaro y Rodríguez (2017), en su proyecto de graduación para optar al grado de Licenciatura en Ingeniería Industrial en la Universidad de Costa Rica, titulado: *Rediseño*

del sistema de administración de la cadena de suministro interna de la empresa ALRO, plantean como objetivo rediseñar el sistema de administración de la cadena de suministro interna de ALRO, para mejorar el uso de los recursos y la liquidez de la empresa. En conclusión, desarrollan su estudio abarcando temas de pronósticos por lo cual clasifican los datos según el tipo de demanda, esto les permite una mejor selección de los métodos utilizados para el cálculo de pronósticos y mejoran el porcentaje de un 59 % a un 73 %, con un error de pronóstico MAPE menor al 30 %.

Este antecedente emplea parámetros estadísticos para medir el desempeño de los pronósticos y la mejora que hay en estos al aplicar la clasificación de datos por tipo, lo que refleja la importancia de estos parámetros para la medición del desempeño del modelo predictivo.

Distribuidora del Caribe S. A. (Costa Rica)

Castillo et al. (2018), en su proyecto de graduación para optar al grado de Licenciatura en Ingeniería Industrial, llamado: *Diseño de un sistema de planificación de la demanda y del inventario en Distribuidora del Caribe S. A.*, formulan como objetivo diseñar un sistema de planificación de la demanda y del inventario que disminuya los costos innecesarios y las ventas pérdidas ocasionadas por los excedentes y faltantes de producto, así como mejore el nivel de servicio a los clientes reduciendo los atrasos en la entrega de pedidos. En conclusión, elaboran un sistema de planificación de demanda basado en el error de pronóstico MAPE, que les permite disminuir el error de pronóstico en más de un 50 % en el 60 % de los casos en el 93,33 % de los productos bajo estudio.

En este antecedente se plantea un método de planificación que disminuya los sobre- y subdimensionamientos de la demanda, basando el método en el parámetro estadístico MAPE, lo que posibilita reducir el error de pronóstico.

1.4.2 Antecedentes internacionales

Comercializadora de alimentos (Ecuador)

Castro (2020), en su trabajo de grado previo a la obtención del título de Ingeniero, titulado: *Modelos de pronósticos*, formula como objetivo determinar cuál modelo de pronósticos de la demanda es el más eficiente en una distribuidora de alimentos. En conclusión, desarrolla modelos de pronóstico y aplicación de errores estadísticos para identificar el mejor modelo con una menor desviación; de este modo, establece que el 71,15 % de los productos tiene una desviación media absoluta mucho menor que los demás, con el modelo de pronósticos media móvil simple.

Este antecedente muestra una base de referencia al realizar un análisis comparativo de diferentes modelos de pronóstico y la aplicación de parámetros estadísticos para determinar el modelo con menos desviación.

Botica San Carlos (Perú)

Montenegro (2019), en su tesis para optar a la Licenciatura en Administración de Empresas, denominada: *Evaluación de métodos de pronósticos para predecir las ventas de los productos de la línea cardiológica de la Botica San Carlos,* señala como objetivo principal evaluar los métodos de pronóstico más adecuados para predecir las ventas de los fármacos de la línea cardiológica de la empresa Botica San Carlos. En conclusión, evalúa los modelos de pronóstico más adecuados para predecir la demanda, lo que resulta en distintas configuraciones del modelo ARIMA, la mejor para cada tipo de producto.

Este antecedente refuerza la metodología y la importancia de evaluar los modelos de pronóstico, además de seleccionar el más adecuado para el tipo de datos que presenta cada proceso.

Estudio comparativo de pronósticos (México)

Peña (2020), en su tesis para obtener el título de Ingeniero Industrial, llamada: *Pronósticos con algoritmos de aprendizaje automático. Estudio comparativo,* evalúa diferentes modelos de pronóstico comparándolos con los errores estadísticos. Así, formula como objetivo principal abordar el problema de pronósticos de múltiples pasos de series de tiempo desde el enfoque del aprendizaje automático. Por lo tanto, busca determinar y comparar las precisiones de los algoritmos de aprendizaje automático más relevantes, las técnicas de validación de los modelos y las técnicas de pronósticos de múltiples pasos, incluyendo las precisiones de los modelos estadísticos más significativos. Adicional, destaca la superioridad de los métodos estadísticos y la metodología de Box Jenkins.

Este antecedente posee una similitud con el proyecto actual en la comparación de las precisiones de los modelos y técnicas de pronóstico, también destaca la metodología de Box Jenkis para el ajuste del modelo ARIMA, modelo utilizado en este proyecto.

Publimetro (México)

Torres (2015), en su tesis para obtener el título de Ingeniera Industrial, denominada: *Teoría de pronósticos y modelos de inventario aplicados en el consumo de papel para la impresión de un periódico*, plantea como objetivo seleccionar un modelo de inventario y un modelo de pronóstico para definir el momento exacto en el que se debe hacer un pedido de papel, conocer la cantidad que se debe solicitar y disminuir los costos debido a faltantes o sobreinventario, además de evitar estos últimos dos problemas. Concluye que el método de pronóstico por usar es el suavizamiento exponencial simple con estacionalidad.

Este proyecto aporta un antecedente de un estudio con una problemática de sobre- y subdimensionamiento del inventario, de igual modo utiliza una variación del modelo de suavización exponencial, también empleado en el desarrollo de este proyecto.

Institución estudiantil (México)

Rodríguez et al. (2024), en su artículo: “Estimación de demanda estudiantil en una institución educativa para calcular capacidad docente y aulas utilizando modelo de pronósticos” para la *Revista Iberoamericana para la Investigación y el Desarrollo Educativo,* establecen como objetivo analizar el comportamiento histórico de la matrícula estudiantil en un bachillerato tecnológico de Ciudad Juárez, Chihuahua, con la finalidad de estimar la demanda futura. El propósito es determinar la capacidad requerida de infraestructura en la institución en lo referente a aulas y personal docente, y calcular las proporciones *alumnos-maestro y alumnos-aula* para compararlas con las proporciones medias internacionales y de México. En el estudio desarrollan modelos de pronósticos multiplicativos y Winters, así como una comparación basada en un error de pronóstico, con la intención de estimar la demanda futura. Concluyen que los pronósticos por periodo muestran que el error varía desde 0.21 % hasta 8.88 %, lo cual se considera bajo, especialmente al compararlo con el rango aceptable de errores, que varía entre el 20 % y el 30 %.

Este antecedente posee una similitud con el proyecto actual en cuanto al proceso de pronosticar la demanda con un modelo multiplicativo y Winters, además de comparaciones basadas en el error de pronóstico.

1.5 PROYECCIONES

A continuación, se detallan los alcances y limitaciones presentes en el desarrollo del estudio.

1.5.1 Alcances

El estudio se realiza en NETCOM BUSINESS CONTACT CENTER, en el Departamento de WFM, específicamente en el proceso de pronóstico de llamadas, utilizado en el dimensionamiento de personal necesario para atender la demanda del Proyecto Banco.

El alcance de este proyecto se centra en analizar y proponer mejoras al **método** de selección de modelos de pronósticos del volumen de llamadas (PBF), usado dentro del

proceso de dimensionamiento. El estudio se limita a evaluar el método actual, identificar áreas de mejora y plantear alternativas o ajustes que permitan optimizar la selección del modelo, sin modificar los demás factores o componentes del modelo actual de pronóstico, como los modelos predictivos utilizados, herramientas y configuraciones de Forecast PRO. Asimismo, se excluyen del alcance de este proyecto los pronósticos de AHT (tiempo promedio de manejo), auxiliar, ausentismo y rotación, ya que no se efectúan en Forecast PRO.

En cuanto al dimensionamiento de personal, se encuentran otras variables que se pronostican, como el tiempo de atención, reductores y ausentismo; estas no se abarcan en el desarrollo del estudio. Al respecto, se elige el pronóstico del volumen de llamadas entrantes debido a la importancia que tienen las jefaturas sobre este al ser el de mayor impacto en las desviaciones del recurso humano necesario y la base de las validaciones que aplica el cliente contratante.

Se proyecta que la propuesta del método de selección del mejor modelo de pronóstico que se adapte a los datos históricos del proyecto disminuya el error de pronóstico y esto, a su vez, reduzca la desviación en el dimensionamiento del recurso humano necesario.

1.5.2 Limitaciones

No se visualizan limitaciones durante el desarrollo del presente estudio.

1.6 IDENTIFICACIÓN DE LA EMPRESA

Seguidamente, se exponen los detalles más significativos de la empresa NETCOM BUSINESS CONTACT CENTER, donde se realiza el estudio.

1.6.1 Principios y propósito organizacional

Visión

"Ser la empresa líder en servicios especializados de telecomunicaciones y centros de contacto, a nivel nacional y regional, reconocida por la calidad de sus soluciones y la satisfacción de sus clientes" (NETCOM BUSINESS CONTACT CENTER, 2025).

Misión

"Desarrollar ventajas competitivas, a través de la asesoría especializada en telecomunicaciones y centros de contacto, así como el diseño e implementación de soluciones integrales que permitan mejorar la eficiencia, productividad y rentabilidad de los negocios de nuestros clientes" (NETCOM BUSINESS CONTACT CENTER, 2025).

1.6.2 Contexto empresarial

Network Communications S. A. (NETCOM) es un grupo empresarial con casa matriz en Panamá y oficinas en Costa Rica, que se dedica a la comercialización de soluciones de infraestructura de voz, datos, video, *contact center* y *carrier class*.

Cuenta con una vertical de servicios de *call center* ubicada en Costa Rica, con más de 1200 posiciones de agentes y desde la cual les brinda servicio a varios clientes en la región. Es Partner Platinum y Partner Services Expert de AVAYA para la región, lo que la habilita como un canal altamente especializado para proporcionar servicios de implementación y mantenimiento en comunicaciones unificadas y *contact center* en plataformas AVAYA.

Ubicación geográfica

La empresa se localiza 150 m al oeste del Tacobell de San Pedro de Montes de Oca en la provincia de San José.

Figura 1.1: Ubicación de la empresa NETCOM

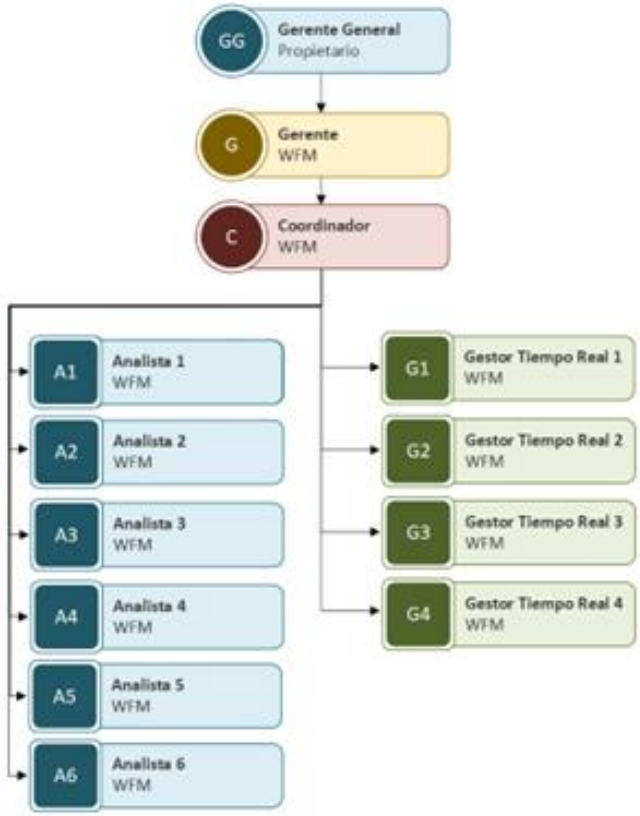


Fuente: Google Maps, 2025.

1.6.3 Estructura organizacional

El extracto del organigrama correspondiente al Departamento de WFM de la empresa se muestra a continuación:

Figura 1.2: Organigrama de NETCOM BUSINESS CONTACT CENTER



Fuente: Elaboración propia, 2025.

1.6.4 Cantidad de empleados

La cantidad de empleados por área se muestra en la siguiente tabla:

Tabla 1.1: Cantidad de empleados por área

Puesto o área	Cantidad
Gerencia General	1
Coordinador WFM	1
Analistas WFM	6
Gestores en tiempo real	4
Total	**12**

Fuente: Elaboración propia, 2025.

1.6.5 Tipos de productos o servicios

NETCOM BUSINESS CONTACT CENTER posee el centro de contactos más moderno del país, equipado con plataformas AVAYA de última generación para operaciones de *inbound*, *outbound*, chat, email, SMS, redes sociales, grabación de voz y de pantallas, IVR (portales de voz) con reconocimiento de voz y *text to speech*.

Otras características que ofrece el servicio de centro de contactos son las siguientes:

- Enlaces redundantes de datos e Internet de alta velocidad.
- Personal certificado COPC (Customer Operations Performance Centre), ITIL (Information Technology Infrastructure Library) y PMP (Project Management Professional).
- Personal certificado por AVAYA en IP PBX, *contact center*, grabación, IVR (respuesta de voz interactiva) y datos.
- Unidad Especializada de Calidad y Formación.
- Unidad Especializada de Workforce Management.

Algunos de los servicios que brinda son los siguientes:

Figura 1.3: Tipos de productos



Fuente: NETCOM, 2025.

- Servicio al cliente.
- Servicios de gestión de cobro.
- Especialistas en *service desk*.
- Televenta.
- Servicios de centro de contactos desde la nube.

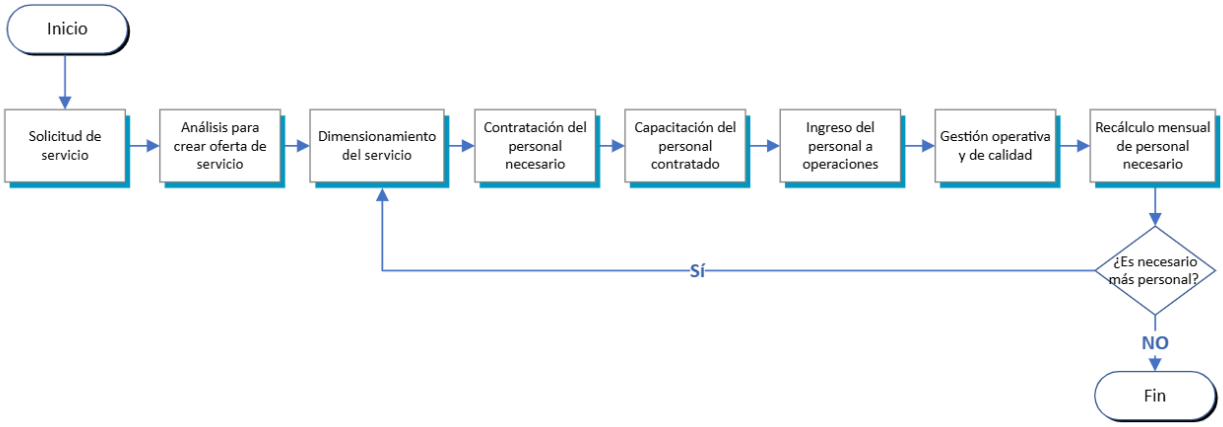
Mercado de exportación

Gracias a la diversidad de servicios que brinda la empresa NETCOM BUSINESS CONTACT CENTER, puede atender a empresas que desarrollan sus actividades en diversos sectores y regiones geográficas; esto facilita la expansión en el mercado de exportación.

En la actualidad tiene oficinas y operaciones en 3 países de Latinoamérica y Suramérica, además de un representante comercial en Miami. Adicional, sus alianzas internacionales le han permitido ofrecer servicios tercerizados a empresas de logística de Canadá.

Descripción general del proceso productivo

Figura 1.4: Diagrama de flujo del proceso productivo



Fuente: Elaboración propia, 2025.

El diagrama de flujo mostrado anteriormente explica de manera general los procesos más relevantes de los servicios ofrecidos por NETCOM CONTACT BUSSINES CENTER, los mismos se detallan a continuación:

Solicitud de servicio: corresponde a una licitación o cotización de un nuevo servicio. Siendo este el punto de inicio, la empresa se centra en buscar licitaciones para ofrecer servicios de telecomunicaciones al Estado, o bien, clientes privados que requieran de un centro de contactos, de esto se encarga el Departamento Comercial de la empresa.

Análisis para crear una oferta de servicio: luego de identificar un posible cliente, se realiza un análisis financiero y de cumplimiento de requisitos, el cual es fundamental para definir el precio por minuto, interacción o posición.

Dimensionamiento del servicio: este paso se desarrolla en el Departamento de WFM, encargado de hacer el cálculo del personal necesario para cumplir con la demanda de interacciones del cliente, mediante pronósticos de variables como llamadas entrantes, tiempo auxiliar, tiempo de manejo operativo, ausentismo, entre otras, además de un análisis de teoría de colas.

Contratación del personal necesario: esto lo lleva a cabo RR.HH. al buscar el personal que cumpla con el perfil estipulado en el contrato, a quienes les realiza las pruebas pertinentes y la respectiva entrevista.

Capacitación del personal contratado: el Departamento de Capacitación desarrolla esta función de formar al personal contratado en las ocupaciones pertinentes al cargo. Este proceso formativo también evalúa si el personal es apto y, mediante un proceso de integración gradual a la operación, lo prepara para su ingreso a producción.

Ingreso del personal a operaciones: en este paso el personal pasa a ser responsabilidad total de la operativa, que debe asignar metas de indicadores y al supervisor.

Gestión operativa y de calidad: el día tras día lleva consigo la gestión de los indicadores clave para la producción, como el control del tiempo no útil (auxiliar); la ocupación de los agentes; el cumplimiento de la hora de salida, entrada y recesos; además del respectivo control de calidad del servicio ofrecido.

Recálculo mensual del personal necesario: para cada mes se efectúa un cálculo del personal necesario, en el que se determina si se debe contratar más personal o el actual es suficiente para cubrir la demanda.

CAPÍTULO II. MARCO TEÓRICO

2.1 FILOSOFÍA O MARCO DE REFERENCIA

La filosofía de estudio del presente trabajo se fundamenta en la metodología seis sigma, orientada a la mejora continua al reducir la variabilidad de los procesos y eliminar las causas de error que afectan el desempeño y la satisfacción del cliente, mediante herramientas ingenieriles y estadísticas para la toma de decisiones informadas con el fin de lograr resultados consistentes y medibles; como lo explican Herrara y Fontalvo (2011):

> El método de seis sigma es una filosofía que inicia en los años ochenta como estrategia de mercado y de mejoramiento de la calidad en la empresa Motorola, cuando el ingeniero Mikel Harry promovió, como meta estimable en la organización, la evaluación y el análisis de la variación de los procesos de Motorola, como una manera de ajustarse más a la realidad. Es en esta época, con el auge de la globalización, las empresas del sector industrial y comercial, que se empezaron a desarrollar técnicas más eficientes que le permitieran optimizar los procesos para mejorar su competitividad y productividad, lo que involucró como objetivo principal reducir la variabilidad de los factores o variables críticas que de una u otra forma alteraban el normal desempeño de los procesos. Por lo que se tomó como medida estadística confiable la evaluación de la desviación estándar del proceso, representada por el símbolo σ, como indicador de desempeño y a su vez permita determinar la eficiencia y eficacia de la organización. Esta iniciativa se convirtió en el punto central del esfuerzo para mejorar la calidad en Motorola, llamando la atención al director ejecutivo Bob Galvin; con su apoyo, se hizo énfasis no sólo en el análisis de la variación, sino también en la mejora continua. Observó que cuando se realiza el control estadístico a un proceso, se toma como variabilidad natural cuando este valor de sigma σ oscila a tres desviaciones del promedio. Criterio que se modifica con el método seis sigma, en donde se exige que el proceso se encuentre a cuatro puntos cinco desviaciones de la media. Esto implica que una considerable información del proceso debe estar dentro de este intervalo, lo que estadísticamente implica que se considera normal que 34 elementos del proceso no cumplan los criterios de calidad exigidos por el cliente, de cada millón de oportunidades (1 000 000). Esta es la causa del origen filosófico

> del método seis sigma como medida de desempeño de toda una organización. Fue así como con el transcurrir del tiempo ha surgido esta nueva filosofía de calidad como evolución de las normas de calidad que actualmente muchas empresas aplican (pp. 2-3).

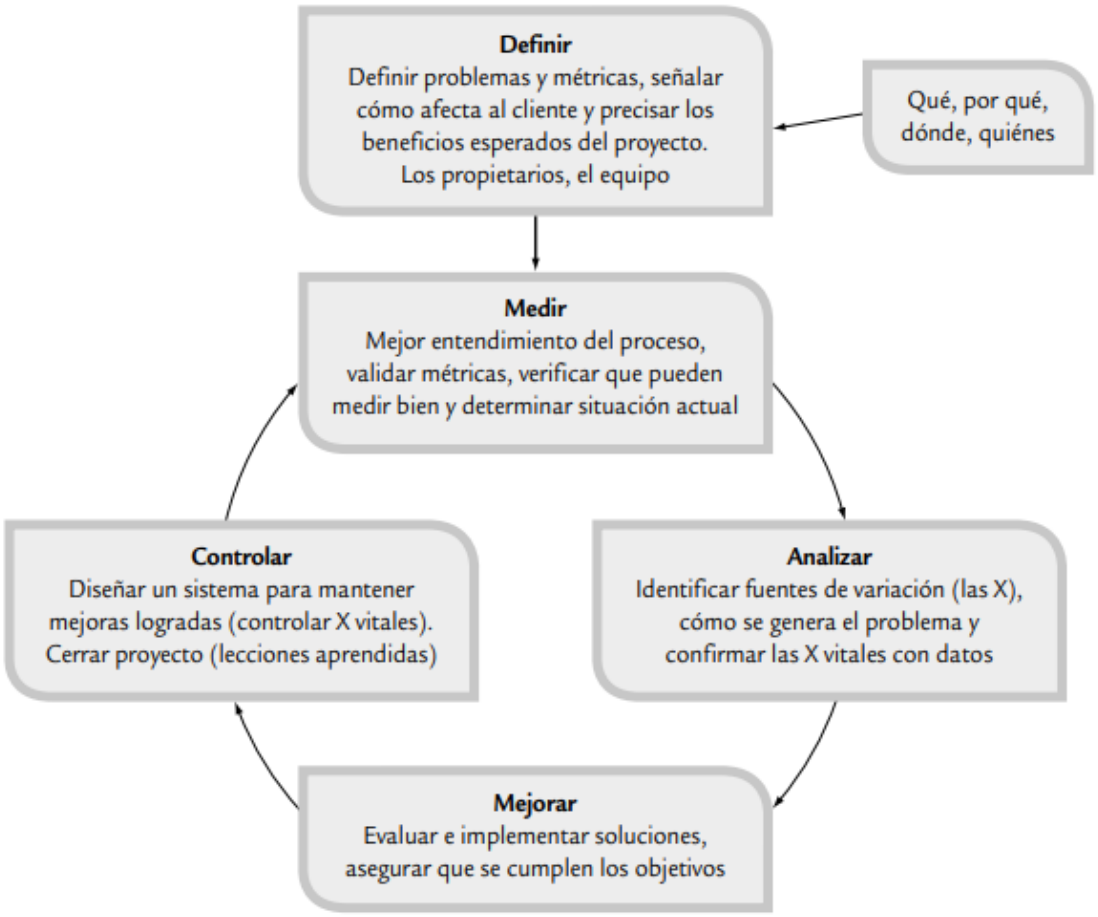
2.2 METODOLOGÍA

En este proyecto se utiliza la metodología de investigación DMAIC, por sus siglas en inglés *define* (definir), *measure* (medir), *analyze* (analizar), *improve* (mejorar) y *control* (controlar). También se hace referencia al DMAIC como DMAMC en varias fuentes de literatura en español.

Con relación a esta metodología, Socconini (2025) argumenta:

> La metodología DMAIC es un enfoque sistemático y basado en datos que permite a las organizaciones alcanzar la excelencia en los procesos y la mejora continua. Mediante la definición de problemas, la medición del rendimiento, el análisis de las causas raíz, la implantación de mejoras y el establecimiento de medidas de control. DMAIC sirve como marco de referencia que permite a las organizaciones maximizar la eficiencia, reducir los defectos, mejorar la calidad y, en última instancia, ofrecer un valor superior a los clientes y las partes interesadas.

Figura 2.1: DMAIC



Fuente: Gutiérrez y De la Vara, 2009.

A continuación, se detalla cada fase de la metodología DMAIC de acuerdo con Gutiérrez y De la Vara (2009):

Definir (*define*)

En la etapa de definición se enfoca el proyecto, se delimita y se sientan las bases para su éxito. Por ello, al finalizar esta fase se debe tener claro el objetivo del proyecto, la forma de medir su éxito, su alcance, los beneficios potenciales y las personas que intervienen en este. Todo lo anterior se resumirá en el marco del proyecto (*project charter*). [...]

Medir (*measure*)

El objetivo general de esta segunda fase es entender y cuantificar mejor la magnitud del problema o situación que se aborda con el proyecto. Por ello, el proceso se define a un nivel más detallado para entender el flujo del trabajo, los puntos de decisión y los detalles de su funcionamiento; asimismo, se establecen con mayor detalle las métricas (las Y) con las que se evaluará el éxito del proyecto. Además, se analiza y valida el sistema de medición para garantizar que las Y pueden medirse en forma consistente. Además, con el sistema de medición validado, se mide la situación actual (o línea base) para clarificar el punto de arranque del proyecto con respecto a las Y. [...]

Analizar (*analyze*)

La meta de esta fase es identificar la(s) causa(s) raíz del problema (identificar las X vitales), entender cómo es que estas generan el problema y confirmar las causas con datos. Entonces, se trata de entender cómo y por qué se genera el problema, buscando llegar hasta las causas más profundas y confirmarlas con datos. Obviamente, para encontrar las X vitales primero es necesario identificar todas las variables de entrada y/o posibles causas del problema. [...]

Mejorar (*improve*)

El objetivo de esta etapa es proponer e implementar soluciones que atiendan las causas raíz; es decir, asegurarse de que se corrige o reduce el problema. Es recomendable generar diferentes alternativas de solución que atiendan las diversas causas, apoyándose en algunas de las siguientes herramientas: lluvia de ideas, técnicas de creatividad, hojas de verificación, diseño de experimentos, *poka-yoke*, etc. La clave es pensar en soluciones que ataquen la fuente del problema (causas) y no el efecto. [...]

Controlar (*control*)

Una vez que las mejoras deseadas han sido alcanzadas, en esta etapa se diseña un sistema que mantenga las mejoras logradas (controlar las X vitales) y se cierra el proyecto. Muchas veces esta etapa es la más dolorosa o difícil, puesto que se trata de que los cambios realizados para evaluar las acciones de mejora se vuelvan permanentes, se institucionalicen y generalicen. Esto implica la participación y adaptación a los cambios de toda la gente involucrada en el proceso, por lo que se pueden presentar resistencias y complicaciones. Al final de cuentas, el reto de la etapa de control es que las mejoras soporten la prueba del tiempo. En este sentido es necesario establecer un sistema de control para:

- Prevenir que los problemas que tenía el proceso no se vuelvan a repetir (mantener las ganancias).
- Impedir que las mejoras y conocimiento obtenido se olviden.
- Mantener el desempeño del proceso.
- Alentar la mejora continua (pp. 426, 428-430).

En el caso del estudio, cada fase se lleva a cabo de la siguiente manera:

Definir las partes interesadas por medio del análisis de los *stakeholders*, mapear el proceso con el diagrama de flujo y realizar las entrevistas con las partes interesadas.

Medir los resultados de los modelos utilizados mediante gráficos, histogramas y KPI basados en datos históricos, para obtener los resultados del error de pronóstico del modelo actual.

Analizar los resultados obtenidos en la fase anterior, con la finalidad de identificar los errores estadísticos óptimos para los tipos de datos que representan el volumen de llamadas. Además, comparar los modelos en la matriz de decisión para así determinar el más adecuado.

Mejorar el modelo actual con los resultados más importantes de la etapa anterior, con la intención de proponer un modelo mejorado con la integración de los errores estadísticos que ofrecen una base matemática para escoger el mejor modelo predictivo.

Controlar mediante reuniones periódicas de análisis de resultados empleando un reporte en Tableau y los indicadores del error de pronóstico. Asimismo, en caso de ser necesario, realizar un plan de acción para mejorar la precisión.

2.3 HERRAMIENTAS

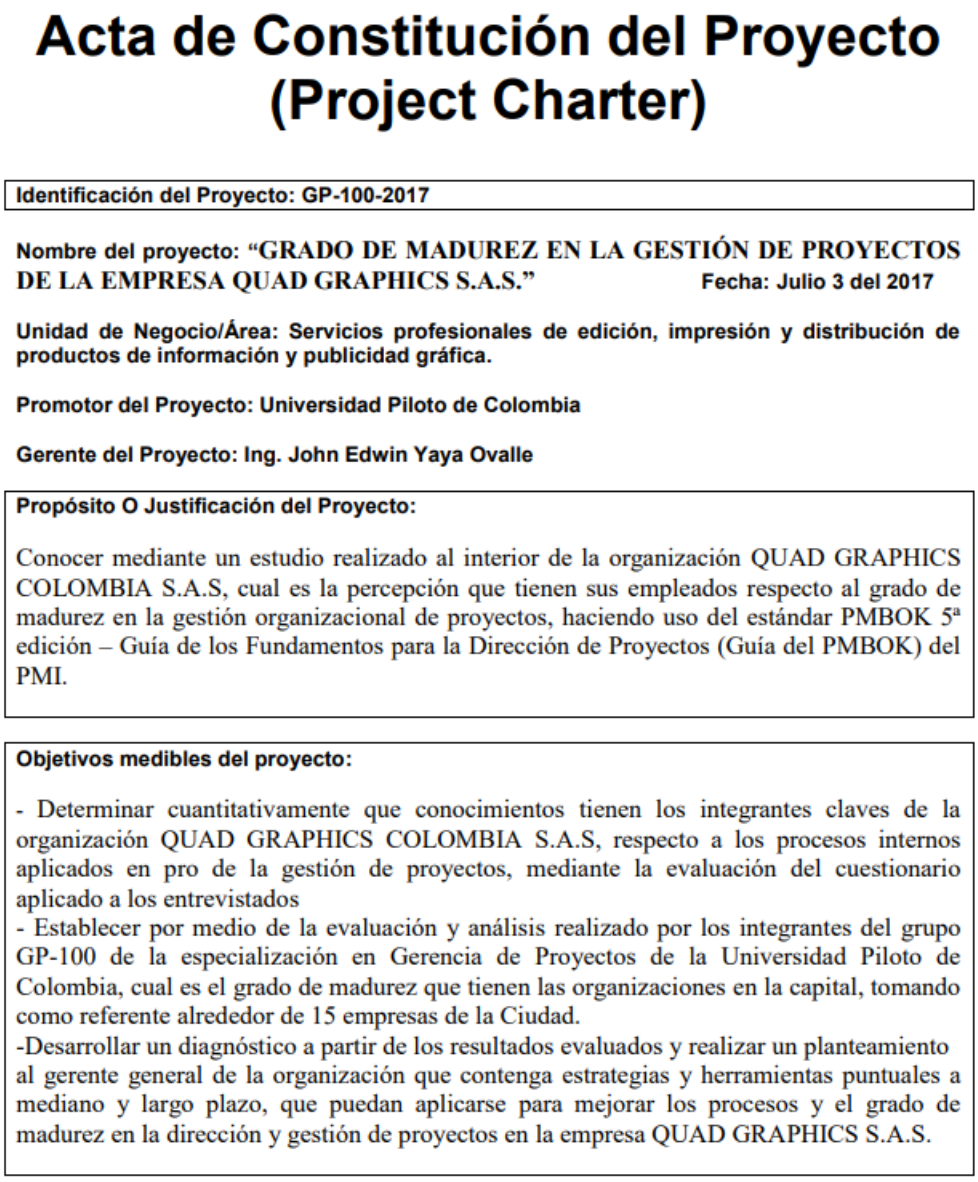
Seguidamente, se describen las herramientas y técnicas consideradas para el desarrollo del estudio.

2.1.1 Project charter

En cuanto al *project charter*, Santos (2023) explica:

> Cuando un proyecto se convierte en algo significativo, contar con un documento que reúna toda la información necesaria antes de llevarlo a cabo de manera eficaz es un recurso importante para alcanzar el éxito del mismo.
>
> Para ejecutar cualquier proyecto se requiere tiempo, esfuerzo y recursos, por lo que la creación de un acta de constitución de proyecto, o *project charter*, es un pilar fundamental para facilitar los procesos y despejar cualquier duda antes de comenzarlo.
>
> En una organización es importante establecer el valor comercial de un proyecto y comprender los procesos y recursos necesarios para llevarlo a cabo. El *project charter* ayuda a los equipos a iniciar un proyecto con el pie derecho; incluso si un nuevo integrante entra al equipo, este documento le ayudará a conocer toda la información sobre el proyecto que se está realizando.

Figura 2.2: Ejemplo de un project charter



Acta de Constitución del Proyecto (Project Charter)

Identificación del Proyecto: GP-100-2017

Nombre del proyecto: "GRADO DE MADUREZ EN LA GESTIÓN DE PROYECTOS DE LA EMPRESA QUAD GRAPHICS S.A.S." **Fecha: Julio 3 del 2017**

Unidad de Negocio/Área: Servicios profesionales de edición, impresión y distribución de productos de información y publicidad gráfica.

Promotor del Proyecto: Universidad Piloto de Colombia

Gerente del Proyecto: Ing. John Edwin Yaya Ovalle

Propósito O Justificación del Proyecto:

Conocer mediante un estudio realizado al interior de la organización QUAD GRAPHICS COLOMBIA S.A.S, cual es la percepción que tienen sus empleados respecto al grado de madurez en la gestión organizacional de proyectos, haciendo uso del estándar PMBOK 5ª edición – Guía de los Fundamentos para la Dirección de Proyectos (Guía del PMBOK) del PMI.

Objetivos medibles del proyecto:

- Determinar cuantitativamente que conocimientos tienen los integrantes claves de la organización QUAD GRAPHICS COLOMBIA S.A.S, respecto a los procesos internos aplicados en pro de la gestión de proyectos, mediante la evaluación del cuestionario aplicado a los entrevistados
- Establecer por medio de la evaluación y análisis realizado por los integrantes del grupo GP-100 de la especialización en Gerencia de Proyectos de la Universidad Piloto de Colombia, cual es el grado de madurez que tienen las organizaciones en la capital, tomando como referente alrededor de 15 empresas de la Ciudad.
-Desarrollar un diagnóstico a partir de los resultados evaluados y realizar un planteamiento al gerente general de la organización que contenga estrategias y herramientas puntuales a mediano y largo plazo, que puedan aplicarse para mejorar los procesos y el grado de madurez en la dirección y gestión de proyectos en la empresa QUAD GRAPHICS S.A.S.

Fuente: Arce, 2013.

2.1.2 Análisis de stakeholders, modelo Gardner

Acuña (2012) describe cómo funciona este modelo y sus ventajas:

> En esta matriz elaborada por Gardner se orienta a clasificar a los *stakeholders* de acuerdo a las variables de "poder que poseen" y de "grado de interés" que demuestran por las estrategias de la empresa. Se utiliza para indicar qué tipo de

relación debe desarrollar la empresa con cada uno de esos grupos y de esta manera ayudan a definir estrategias específicas de relaciones con los *stakeholders*.

Con estos resultados se pueden mejorar las estrategias de negociación y tomar decisiones más efectivas. Se obtiene una adecuada estrategia de relacionamiento efectivo (de acuerdo al tipo de *stakeholder*) que contribuye la gestión de la empresa. También se logra una mejor recepción de las estrategias de la organización y, por ende, su factible acompañamiento. Es una matriz sumamente sencilla, lo que se destaca es que ofrece estrategias organizacionales según el interés/poder del interesado (p. 9).

Figura 2.3: Ejemplo de stakeholders



Fuente: Mendoza, s.f.

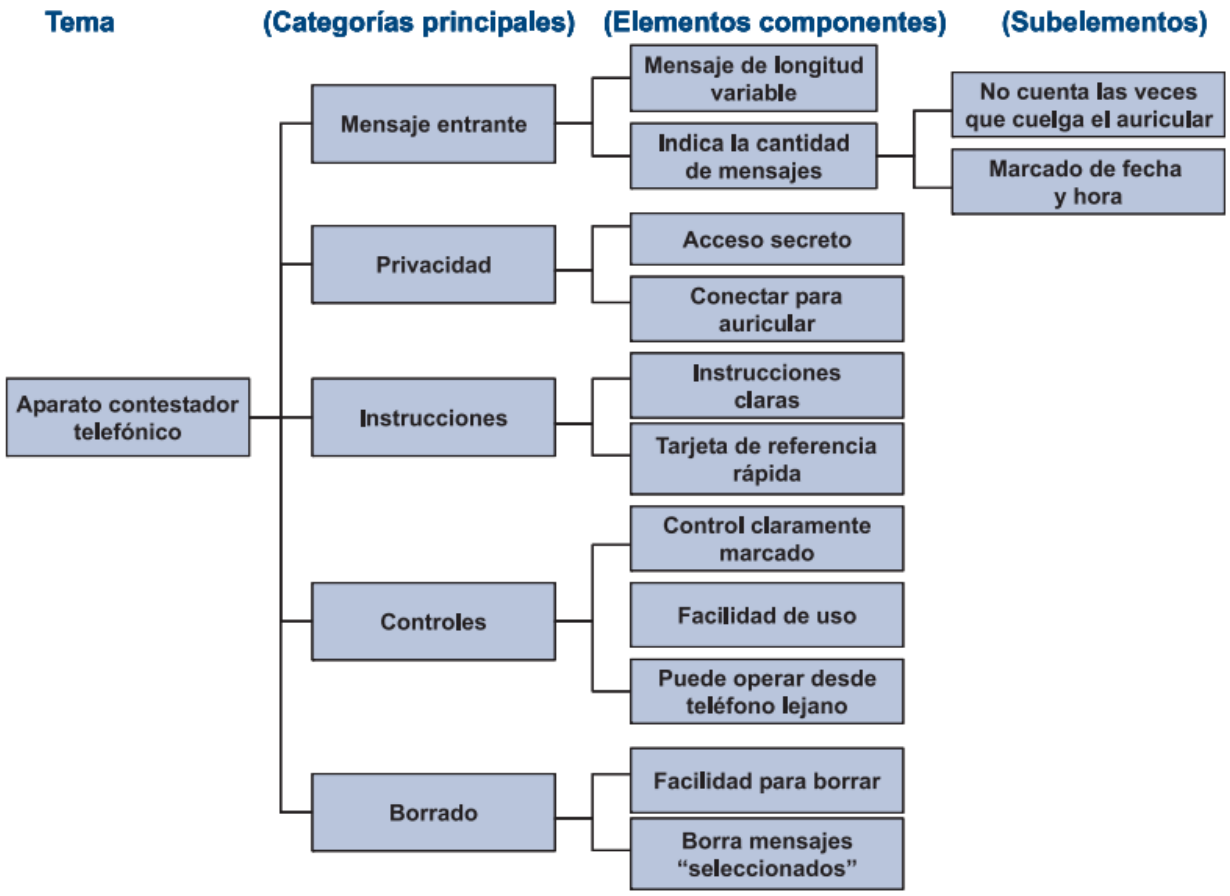
Este análisis se utiliza en el desarrollo del proyecto para identificar y clasificar las partes interesadas dentro del proceso de pronóstico y, así, determinar su nivel de influencia e interés, además de aportar un contexto del nivel de involucramiento de las partes interesadas.

2.1.3 Diagrama de árbol CTQ

El Instituto Uruguayo de Normas Técnicas (2009) detalla esta herramienta y la metodología para llevarla a cabo:

> Se usa el diagrama de árbol para indicar las relaciones entre un tema y sus elementos componente. El diagrama en árbol separa los componentes primarios, secundarios y terciarios que contribuyen a una situación relacionada con la calidad, de modo de estudiarlos con cierto grado de profundidad.
>
> Las ideas generadas por un torbellino de ideas y agrupadas en un diagrama de afinidad, pueden convertirse en un diagrama de árbol para indicar relaciones lógicas y secuenciales.
>
> La presentación es diferente al diagrama de Ishikawa, sin embargo, los principios para su establecimiento son similares.
>
> Metodología
>
> - establecer clara y simplemente el problema a ser estudiado
> - definir las categorías principales del problema (se efectúa un torbellino de ideas o se usa las tarjetas de encabezamiento del diagrama de afinidad)
> - construir el diagrama colocando el problema en una casilla en el lado izquierdo
> - colocar las categorías principales como ramas laterales a la derecha
> - definir, para cada categoría principal, los elementos componentes y cualesquiera subelementos
> - colocar para cada categoría principal, como ramas laterales a la derecha, los elementos y subelementos componentes
> - revisar el diagrama para asegurarse de que no hay vacíos, ya sea de secuencia o de lógica (pp. 25-26).

Figura 2.4: Ejemplo de un diagrama de árbol



Fuente: Instituto Uruguayo de Normas Técnicas, 2009, p. 26.

La inclusión de este diagrama en el estudio facilita representar en indicadores cuantificables de calidad las necesidades derivadas del proceso de pronóstico tanto del cliente interno dentro de la operativa de la empresa como de los clientes externos contratantes.

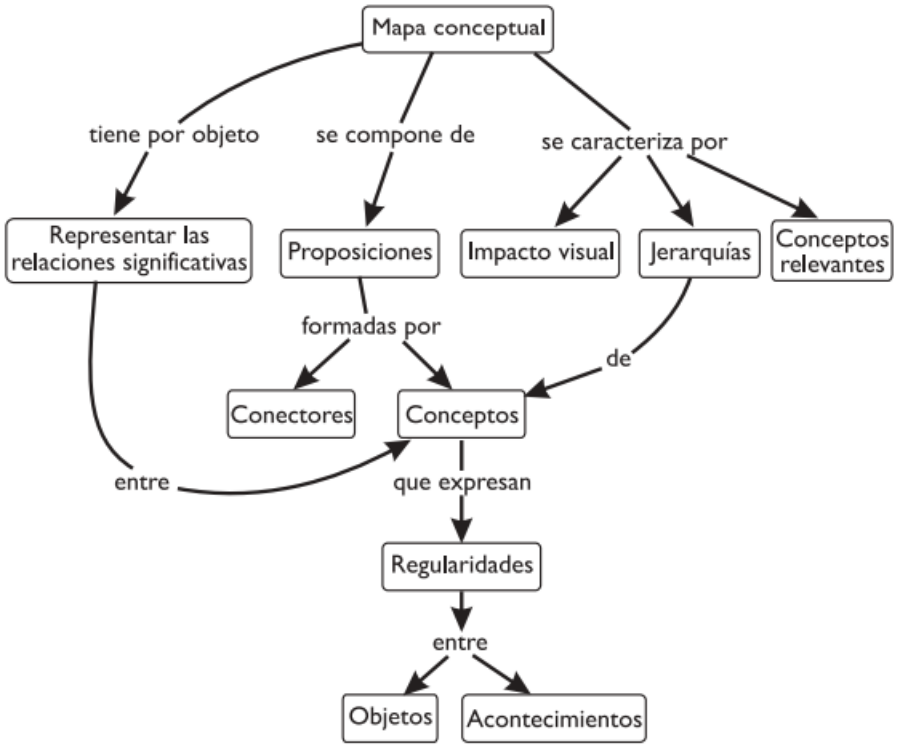
2.1.4 Mapa conceptual

Referente a este mapa, Aguilar (2006) señala:

> El mapa conceptual es una red de conceptos ordenados jerárquicamente, esto quiere decir que los conceptos de mayor generalidad ocuparán los espacios superiores. El mapa conceptual puede ser elaborado a partir de un texto, como notas de clase, para ordenar y representar los conocimientos que las personas

tienen respecto a un tema o para representar conocimientos y teorías. La jerarquía de los conceptos depende muchas veces del contexto o tema del mapa conceptual, es por esta razón que un mismo concepto puede ocupar lugares distintos en diferentes mapas conceptuales (pp. 7-8).

Figura 2.5: Ejemplo de un mapa conceptual



Fuente: Aguilar, 2006, p. 8.

Mediante la aplicación de esta herramienta en el desarrollo del proyecto, se pretende explicar y dar un contexto de los procesos asociados al pronóstico de llamadas, el cual es el objeto de estudio. Su uso ayuda a mostrar conceptos y las jerarquías necesarias para una correcta comprensión.

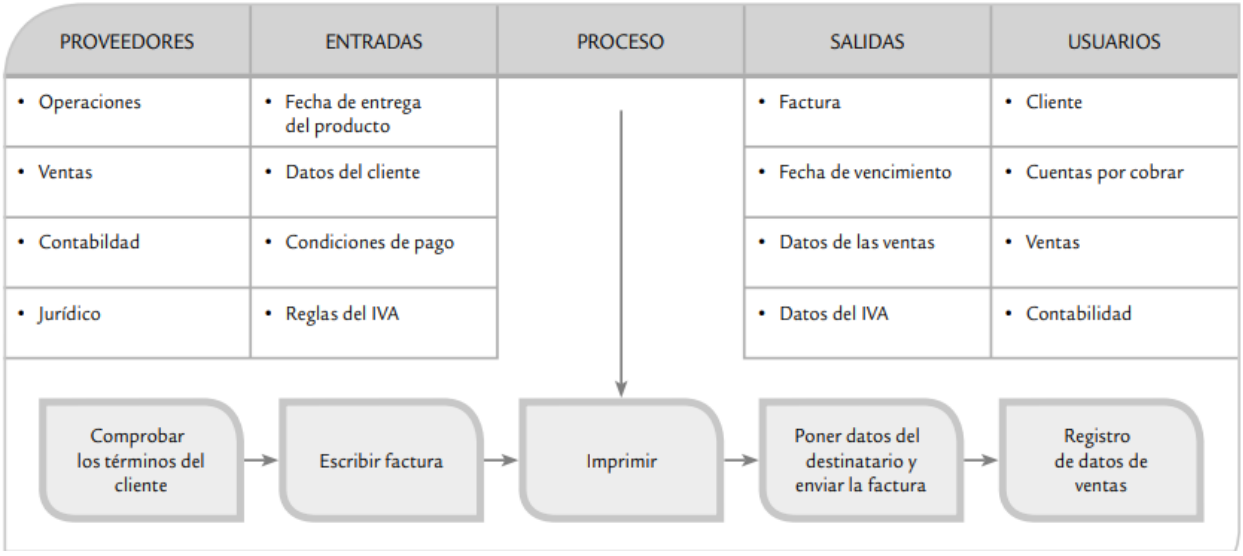
2.1.5 Diagrama PEPSU (SIPOC)

Gutiérrez y De la Vara (2009) indican la finalidad de este diagrama, sus componentes y el proceso para crearlo:

Este diagrama de proceso tiene el objetivo de analizar el proceso y su entorno. Para ello se identifican los proveedores (P), las entradas (E), el proceso mismo (P), las salidas (S) y los usuarios (U). El acrónimo en inglés de este diagrama es SIPOC (*suppliers*, *inputs*, *process*, *outputs and customers*). [...] Los pasos para realizar un diagrama PEPSU son los siguientes:

1. Delimitar el proceso y hacer su diagrama de flujo general donde se especifiquen las cuatro o cinco etapas principales.
2. Identificar las salidas del proceso, las cuales son los resultados (bienes o servicios) que genera el proceso.
3. Especificar los usuarios/clientes, que son quienes reciben o se benefician con las salidas del proceso.
4. Establecer las entradas (materiales, información, etc.) que son necesarias para que el proceso funcione de manera adecuada.
5. Por último, identificar proveedores, es decir, quienes proporcionan las entradas (p. 166).

Figura 2.6: Ejemplo de un diagrama PEPSU (SIPOC)



Fuente: Gutiérrez y De la Vara, 2009, p. 166.

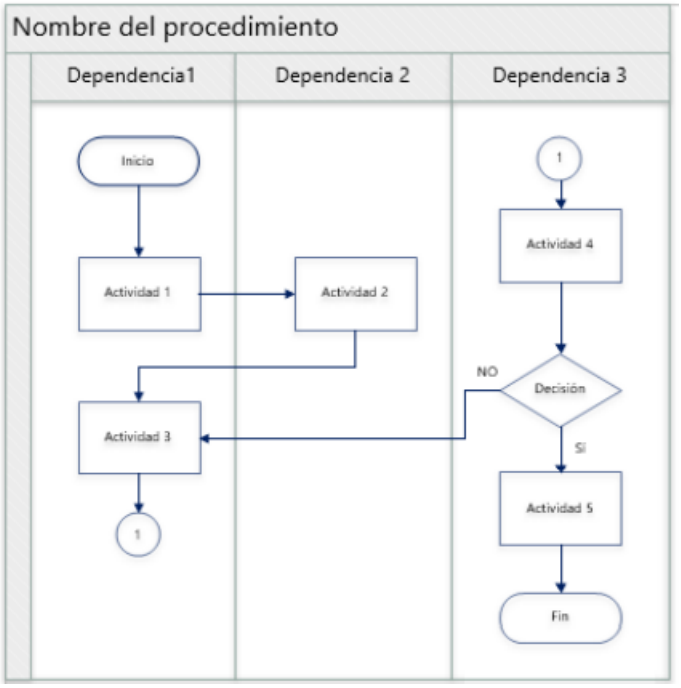
Este diagrama facilita visualizar y determinar de una manera general los proveedores y entradas necesarios, el proceso actual, además de las salidas y usuarios dentro de este, lo que ayuda a comprender las interacciones entre las partes involucradas.

2.1.6 Diagrama de flujo

Respecto a esta herramienta, el Instituto Uruguayo de Normas Técnicas (2009) menciona:

> El diagrama de flujo es una representación gráfica que indica las actividades que constituyen un proceso dado y en el cual se da la ordenación de los elementos. Es la forma más fácil y mejor de comprender cómo se lleva a cabo cualquier proceso.
>
> Se puede dibujar tanto el diagrama de flujo del proceso primario como el de procesos paralelos o alternativos.
>
> De esta manera se puede representar la sucesión de acontecimientos que ocurren para la realización de un producto (desde los materiales hasta los productos). Esto permite, asimismo, que cada persona sepa qué se hace antes y qué se va a hacer después de la actividad o la tarea que ejecuta.
>
> Se utiliza indistintamente, según el caso considerado, la simbología ingenieril o la simbología informática. También pueden usarse simplemente cuadrados o rectángulos para interrelacionar las fases. En este caso se hace referencia a la representación gráfica como diagrama de bloques.
>
> En cualquier caso, lo más importante es que la representación gráfica sea comprensible y útil para los fines para los cuales se realiza.
>
> El diagrama de flujo puede ser usado para describir un proceso existente o para diseñar un proceso nuevo (p. 56).

Figura 2.7: Ejemplo de un diagrama de flujo



Fuente: García y Sánchez, 2021.

En este caso, el uso del diagrama de flujo permite representar de manera ordenada, secuencial y con estructura las actividades que componen el proceso de pronóstico de llamadas, así como explicar otros procesos derivados o subprocesos en específico dentro del mismo.

2.1.7 Bases de datos o registros históricos

Marqués (2011) expone la siguiente información acerca de los registros históricos:

> Una base de datos es un conjunto de datos almacenados en memoria externa que están organizados mediante una estructura de datos. Cada base de datos ha sido diseñada para satisfacer los requisitos de información de una empresa u otro tipo de organización, por ejemplo, una universidad o un hospital. [...]
>
> Una base de datos se puede percibir como un gran almacén de datos que se define y se crea una sola vez, y que se utiliza al mismo tiempo por distintos usuarios. En una base de datos todos los datos se integran con una mínima

> cantidad de duplicidad. De este modo, la base de datos no pertenece a un solo departamento, sino que se comparte por toda la organización. Además, la base de datos no sólo contiene los datos de la organización, también almacena una descripción de dichos datos. Esta descripción es lo que se denomina metadatos, se almacena en el diccionario de datos o catálogo y es lo que permite que exista independencia de datos lógica-física (p. 2).

Las bases de datos se utilizan como fuente de información principal para el desarrollo del estudio, tanto en la medición de errores de pronóstico como en el análisis estadístico, pruebas en los posibles cambios generados y la realización de distintos escenarios.

2.1.8 Medición del error de pronóstico

Hanke y Wichern (2010) detallan en cuanto a la medición del error de pronóstico lo siguiente:

> Debido a que las técnicas cuantitativas de elaboración de pronósticos a menudo incluyen datos de series de tiempo, se desarrolló una notación matemática para referirse a cada periodo específico. La letra Y se usa para representar una variable de serie de tiempo, a menos que haya más de una variable. [...]
>
> Hay varios métodos cuya finalidad es resumir los errores generados por una técnica específica de pronósticos. La mayoría de estas medidas son el promedio de alguna función de la diferencia entre su valor real y su valor pronosticado. Estas diferencias se conocen como residuos. Un residuo es la diferencia entre un valor real observado y su valor de pronóstico (pp. 81-82).

Además, brindan las siguientes fórmulas:

- “Error de pronóstico o residuo
- Desviación media absoluta MAD
- Error cuadrático medio MSE

- Raíz cuadrada del error cuadrático medio RMSE
- Error porcentual absoluto medio MAPE
- Error porcentual medio MPE
- Estadístico Q de Ljung-Box
- Error estándar del coeficiente de autocorrelación” (Hanke y Wichern, 2010, pp.87-88).

Esta medición de precisión o error de pronóstico se realiza a lo largo de todo el estudio, siendo el indicador principal y decisivo para seleccionar el modelo actualmente. Se usa para poder comparar la efectividad de los modelos por medio del tiempo y, con la medición de este indicador, se validan los resultados de las propuestas y ciertos escenarios en donde se plantea qué hubiera pasado si, por ejemplo, se escoge otro modelo.

2.1.9 Histograma

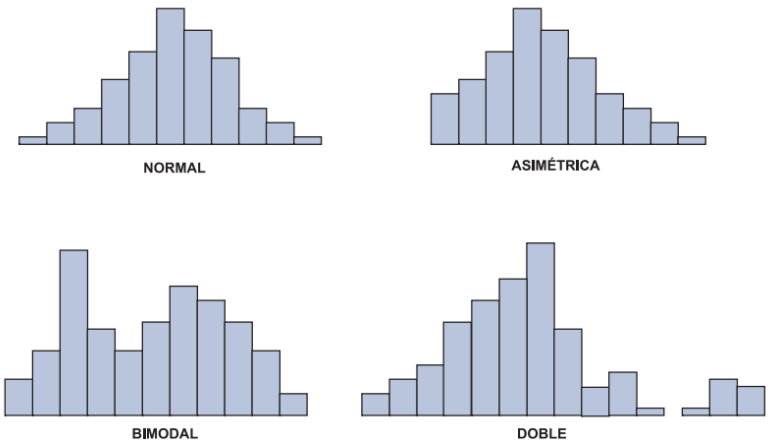
El Instituto Uruguayo de Normas Técnicas (2009) describe qué es un histograma, sus usos y su representación:

> Los histogramas son diagramas de barras que muestran un conjunto de datos en un intervalo específico. Este ordenamiento de la información hace más fácil de interpretar el gráfico. El diagrama de Pareto es un clásico ejemplo de un histograma.
>
> Los histogramas se usan para:
>
> - presentar un perfil de variación
> - comunicar visualmente información relacionada con el desempeño del proceso
> - tomar decisiones acerca de dónde enfocar los esfuerzos de mejora.

En los histogramas los datos son presentados como una serie de rectángulos de igual ancho y variadas alturas. El ancho representa un intervalo dentro del rango de datos. La altura representa la cantidad de datos numéricos.

Al observar estos perfiles, se puede obtener mayor conocimiento acerca del comportamiento del proceso o servicio en estudio (p. 45).

Figura 2.8: Ejemplo de un histograma



Fuente: Instituto Uruguayo de Normas Técnicas, 2009, p. 46.

Para el desarrollo del estudio, se disponen grandes lotes de datos, por lo que se utiliza el histograma para determinar la frecuencia de los rangos de llamadas en los datos históricos, con la intención de identificar los rangos predominantes del volumen de llamadas y *outliers* provocados por averías, lo cual aporta más contexto a la continuidad del estudio.

2.1.10 Indicadores cuantitativos (KPI)

El Consejo Nacional de Evaluación de la Política de Desarrollo Social (2014) los entiende de la siguiente manera: “Un indicador es un instrumento que provee evidencia de una determinada condición o el logro de ciertos resultados. Esta información puede cubrir aspectos cuantitativos y cualitativos sobre los objetivos de un programa o proyecto” (p. 14).

Adicional, el Consejo Nacional de Evaluación de la Política de Desarrollo Social (2014) se refiere a la dimensión general de un indicador:

> Los indicadores deben permitir monitorear el logro de los objetivos a los que se encuentran asociados; sin embargo, es posible medir diferentes dimensiones del desempeño para un mismo objetivo. La dimensión del indicador se define como el aspecto del logro del objetivo a cuantificar, esto es, la perspectiva con que se valora cada objetivo. Se consideran cuatro dimensiones generales para los indicadores: eficacia, eficiencia, calidad y economía (p. 20).

Y agrega la explicación de cada dimensión:

> a) Indicadores de eficacia
> Los indicadores de eficacia miden el grado del cumplimiento del objetivo establecido, es decir, dan evidencia sobre el grado en que se están alcanzando los objetivos descritos.
>
> b) Indicadores de eficiencia
> Los indicadores de eficiencia miden la relación entre el logro del programa y los recursos utilizados para su cumplimiento.
>
> c) Indicadores de economía
> Los indicadores de economía miden la capacidad del programa para administrar, generar o movilizar de manera adecuada los recursos financieros.
>
> d) Indicadores de calidad
> Estos miden los atributos, las capacidades o las características que tienen o deben tener los bienes y servicios que se producen (Consejo Nacional de Evaluación de la Política de Desarrollo Social, 2014, pp. 22-24)

Por último, enumera los pasos para construir un indicador:

1. Revisar la claridad del resumen narrativo.
2. Identificar los factores relevantes.
3. Establecer el objetivo de la medición.
4. Plantear el nombre y la fórmula de cálculo.
5. Determinar la frecuencia de medición.
6. Seleccionar los medios de verificación” (Consejo Nacional de Evaluación de la Política de Desarrollo Social, 2014, p. 30).

En el estudio se emplea el error de pronóstico como un indicador cuantitativo principal, pero además se incluyen otros indicadores cuantitativos que permiten conocer el desempeño de los modelos predictivos y aportan parámetros de referencia en el método de selección de estos. Al respecto, se explican los siguientes:

MAPE

“El error porcentual absoluto medio (MAPE) expresa la exactitud como un porcentaje del error. Debido a que el MAPE es un porcentaje, puede ser más fácil de entender que otros estadísticos de medición de exactitud. Por ejemplo, si el MAPE es 5, en promedio, el pronóstico está errado en un 5 %” (Minitab, 2025d).

RMSE

“La raíz del error cuadrático medio (RMSE, del inglés *root mean squared error*) asociada con dicha secuencia, es decir, la desviación típica muestral de los errores de previsión” (Mauricio, 2007, p. 132)

MSE

“El cuadrado medio del error (MSE) se obtiene dividiendo la suma de los cuadrados del error residual entre los grados de libertad. El MSE es la varianza (s^2) en torno a la línea de regresión ajustada” (Minitab, 2025a).

R^2

R2 es el porcentaje de variación en la respuesta que se explica por el modelo. Se calcula como 1 menos la relación de la suma de los cuadrados del error (que es la variación que no es explicada por el modelo) a la suma total de los cuadrados (que es la variación total en el modelo).

Utilice el R2 para determinar qué tan bien se ajusta el modelo a los datos. Mientras mayor sea el valor de R2, mejor se ajustará el modelo a los datos. R2 siempre está entre 0 % y 100 % (Minitab, 2025c).

Q de Ljung-Box (LBQ)

Utilice el estadístico q de Ljung-Box para comprobar si una serie de observaciones en un período de tiempo específico son aleatorias e independientes. Si las observaciones no son independientes, una observación puede estar correlacionada con otra observación k unidades de tiempo después, una relación que se denomina autocorrelación. La autocorrelación puede reducir la exactitud de un modelo predictivo basado en el tiempo, como la gráfica de series de tiempo, y conducir a una interpretación errónea de los datos (Minitab, 2025e).

MAD

“Valores más pequeños indican un mejor ajuste. La desviación absoluta media (MAD) expresa la exactitud en las mismas unidades que los datos, lo que ayuda a conceptualizar la cantidad de error” (Minitab, 2025b).

MASE

“Calcula el error de escala absoluta de media (MASE) entre el pronóstico y los eventuales resultados” (NUMXL, 2017).

SMAPE

Cuando se calcula el promedio MAPE para un número de series de tiempo, usted puede encontrar un problema: algunas de las series que tienen un alto MAPE pueden distorsionar una comparación entre el MAPE promedio de una serie de tiempo ajustada con un método en comparación con el MAPE promedio medio al usar otro método.

Para evitar este problema, otras medidas han sido definidas, por ejemplo, el SMAPE (MAPE simétrico), error porcentual absoluto ponderado (WAPE), error porcentual real agregado y medida relativa de la exactitud (ROMA). [...]

Es más fácil trabajar con SMAPE que con MAPE, ya que tiene un límite inferior de 0 % y un límite superior de 200 %.

El SMAPE no trata igualmente el sobre pronóstico y pronóstico insuficiente igualmente.

Para un cálculo de SMAPE, en el caso de la suma de la observación y la predicción de valores es igual a cero, la función MAPE salta ese punto de datos (NUMXL, 2016).

2.1.11 Gráfico de pastel y barras

Referente a la funcionalidad de los gráficos, el Instituto Uruguayo de Normas Técnicas (2009) señala:

La información puede ser presentada de diversas maneras para facilitar la comprensión y la posterior toma de decisiones. La misma puede ser presentada en forma de tablas de datos, gráficos, matrices, etc.

La mayoría de las organizaciones representan gráficamente la información referida a varias de las actividades que se realizan en ellas. La elección de una

representación gráfica se debe a que es una manera de exponer dicha información en forma fácilmente visualizable para la mayoría de las personas que integran la organización, independientemente de su grado de instrucción. Los gráficos son fácilmente comprendidos mientras las palabras pueden no serlo.

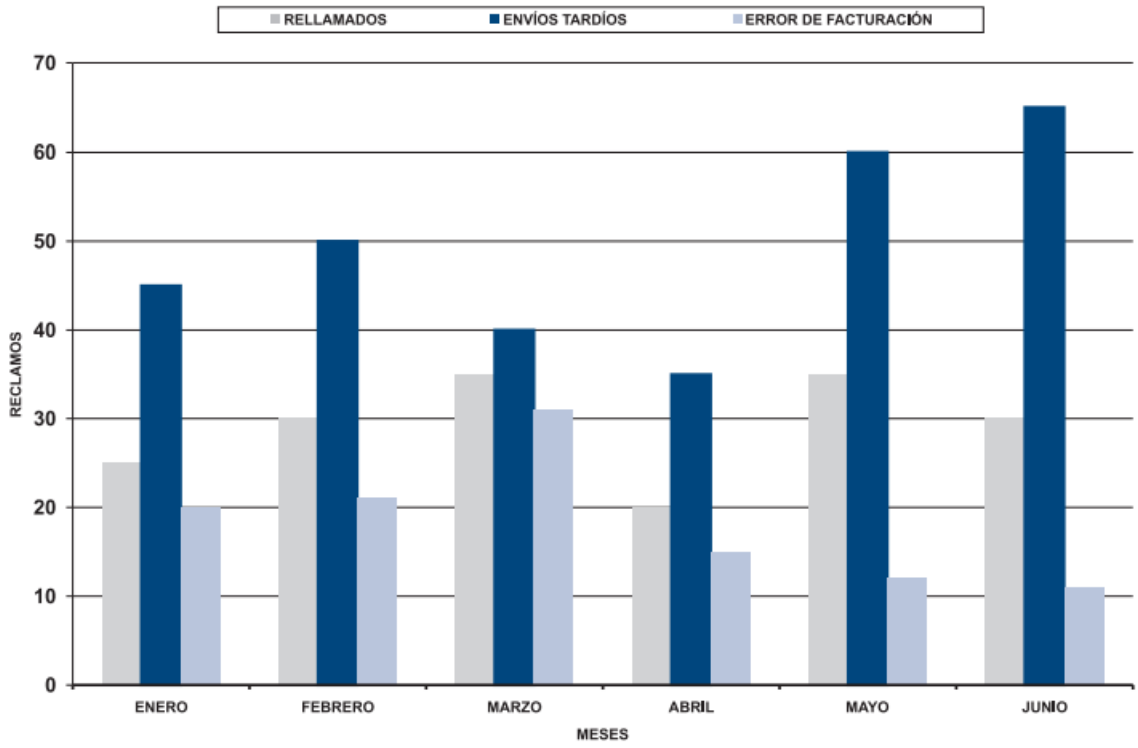
Cuando algo se va a representar en forma gráfica es necesario dar respuesta a las siguientes tres preguntas:

- ¿Cuál es el propósito del gráfico?
- ¿Cómo se usa estos gráficos?
- ¿Cómo pueden hacerse más útiles los gráficos empleados?

En caso de que se pueda dar respuesta fácilmente a estas preguntas, entonces los gráficos son una forma útil y sencilla de representar la información obtenida a través de una serie de etapas a partir de la observación de la realidad.

No puede argumentarse que los gráficos son complicados, difíciles de interpretar o que para comprenderlos es necesario tener conocimientos de estadística, puesto que los niños de primaria aplican los mismos sin grandes problemas (pp. 39-40).

Figura 2.9: Ejemplo de un gráfico de barras



Fuente: Instituto Uruguayo de Normas Técnicas, 2009, p. 42.

Esta herramienta permite mostrar gráficas comparativas de los resultados del proceso de pronóstico a lo largo del tiempo, comparar el desempeño de los diferentes modelos predictivos, y servir de información gráfica que facilite la compresión de distintas pruebas y resultados obtenidos en el desarrollo del estudio.

2.1.12 Lluvia de ideas

En cuanto a la lluvia de ideas, Secchi et al. (2024) detallan:

> Es una herramienta que busca en la etapa de ideación, potenciar la creatividad de los participantes. Se parte de un disparador que las personas deberán responder de manera espontánea. Se busca, no sólo que surjan nuevas preguntas y respuestas, sino también que los participantes contribuyan al ordenamiento de las ideas.

¿Para qué sirve?

Una sesión de tormenta de ideas pretende que los participantes, guiados por un facilitador, exploren su potencial en la generación de nuevas ideas sin interrupciones y sin juzgamiento. Busca que aquellas personas más tímidas se sientan estimuladas a participar.

¿Cuándo se utiliza?

La utilización de esta herramienta es apropiada cuando se busca romper estándares o para moverse de la zona de confort. Permite explotar el potencial creativo de los participantes. Se emplea principalmente para definir una idea, un enfoque o una estrategia (pp. 3-4).

Figura 2.10: Ejemplo de una lluvia de ideas



Fuente: Moreira, 2025.

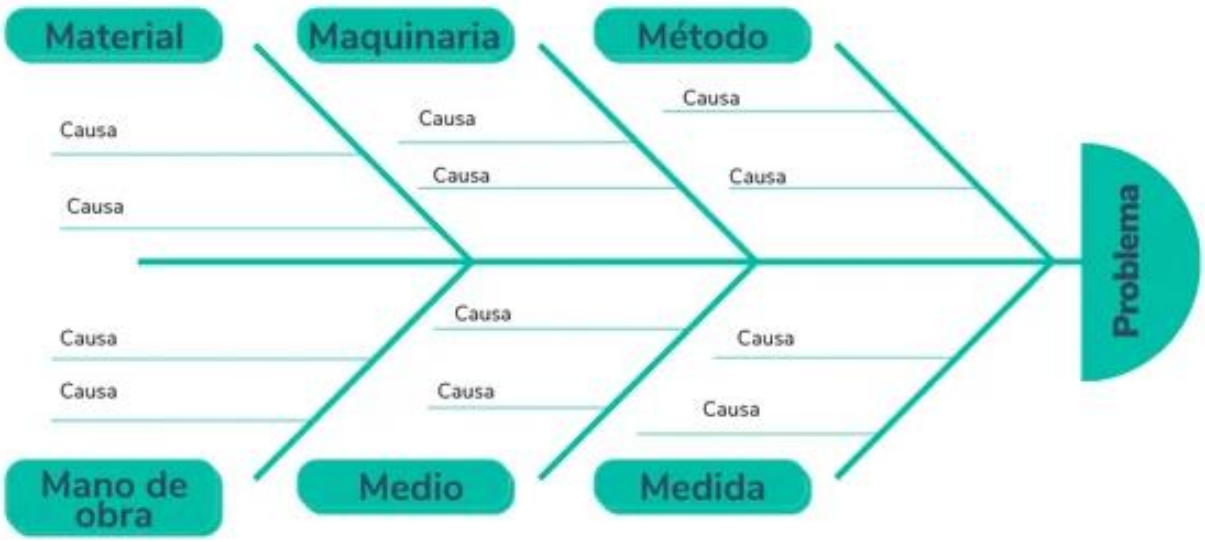
Mediante esta herramienta es posible identificar causas asociadas a los resultados actuales de precisión del pronóstico con la participación del personal del Departamento de WFM. Además de permitir, en un segundo uso, el reconocimiento de parámetros que puedan integrarse y complementar el método de selección de los diferentes modelos predictivos.

2.1.13 Diagrama de Ishikawa

Cuatrecasas (2010) expone lo siguiente acerca de lo conveniente que resulta este diagrama en la identificación de las causas de un problema:

> El diagrama causa-efecto, también conocido como diagrama de Ishikawa en honor a Kaoru Ishikawa que lo desarrolló. También se le denomina, por la similitud que existe, como diagrama de “espina de pez”.
>
> El diagrama analiza de una forma organizada y sistemática los problemas, sus causas, y las causas de estas causas, cuyo resultado en lo que afecta a la calidad se denominará efecto. Existen dos aspectos básicos que definen esta técnica: ordena y profundiza. Describir las causas evidentes de un problema puede ser más o menos sencillo, pero es necesario ordenar dichas causas, ver de dónde provienen y profundizar en el análisis de sus orígenes con el objetivo de solucionar el problema desde su raíz.
>
> El problema está identificado y queremos resolverlo. En este sentido este diagrama nos ayudará a determinar el porqué de ese problema o efecto. El número de factores que influyen en un determinado efecto son numerosos y representarlos todos sería complejo. Por tal motivo se debe seleccionar un grupo representativo de factores para cada problema. Es frecuente utilizar unas causas primarias de tipo genérico, denominadas como las 6M: mano de obra, materiales, métodos, medio ambiente, mantenimiento y maquinaria. Estos factores primarios, que dependiendo de la situación pueden variar, formarán las espinas principales del diagrama y posteriormente se irán añadiendo las causas secundarias, terciarias, etc., que representan las causas de las causas y que permiten profundizar en los orígenes jerarquizados del problema.

Figura 2.11: Diagrama de Ishikawa



Fuente: Universidad Americana de Europa [UNADE], 2025.

El diagrama de Ishikawa se realiza con la intención de clasificar las causas identificadas durante etapas anteriores que influyen en la precisión del pronóstico, agrupándolas con el método de las 6M en mano de obra, medición, materiales, máquinas, método y medio ambiente, para facilitar su compresión y determinar cómo estás pueden afectar el proceso actual.

2.1.14 Multivoto

Según Hermida et al. (2014), el multivoto cuenta con las siguientes características:

> En ocasiones se cuenta con una lista de ideas, o de datos verbales en general, bastante numerosa que es preciso reducir para centrar los esfuerzos en unos pocos, los que sean considerados por los miembros del equipo como los más importantes.
>
> Se establece un compromiso por parte del equipo en las elecciones que se han tomado por ellos mismos, así como una participación igualitaria en el proceso.

Permite a un grupo de trabajo llegar a un consenso en la importancia que tiene algún tema, problema o solución que se esté revisando de acuerdo a su nivel de importancia.

En estos casos puede ser de ayuda la votación múltiple, que podemos definir como un sistema estructurado de series de votación: la multivotación (o voto múltiple).

Es una técnica que permite libertad para priorizar temas, sin existir dominancia de miembros del grupo de trabajo que sean fuertes sobre los que lo son menos. Al llevar a cabo este proceso es posible evidenciar si existe consenso y si no es así hace posible el discutir abiertamente desacuerdos sobre un punto específico para llegar a soluciones.

Adicional, los autores enumeran algunas ventajas de esta herramienta:

- Permite a un equipo llegar rápidamente a un consenso con relación a la importancia relativa de los asuntos, problemas o soluciones completando clasificaciones de importancia individuales en las prioridades finales de un equipo o grupo de personas.
- Sirve de complemento a otras técnicas como la tormenta de ideas.
- Crea compromiso con la opción del equipo a través de la igual participación en el proceso.
- Pone a los integrantes callados del equipo en una posición igual con relación a los integrantes más dominantes o frente a miembros con jerarquías (Hermida et al., 2014).

Figura 2.12: Ejemplo de un multivoto

CLASIFICACION FINAL

Rk.	Equipo	1	2	3	4	5	6	7	8	9	10	Des 1	Des 2	Des 3
1	Agrupacion B	*	2	1½	3	3½	3	2	2½	2½	3	14	0	23
2	L'Aurora Estadilla A	2	*	4	2½	1½	3	2½	1	4	2½	13	2	23
3	Ejea A	2½	0	*	2½	2	1	2½	2½	4	3	13	0	20
4	St Casablanca D	1	1½	1½	*	2½	2½	3½	3	2½	4	12	0	22
5	**Marcos Frechin A**	½	2½	2	1½	*	1	3	3	3½	3	11	0	20
6	Las Fuentes A	1	1	3	1½	3	*	2	2	2½	2½	10	0	18,5
7	El Olivar C	2	1½	1½	½	1	2	*	2½	3½	3½	8	0	18
8	Tauste B	1½	3	1½	1	1	2	1½	*	3	2	6	0	16,5
9	Caissa-Hnos Cortes B	1½	0	0	1½	½	1½	½	1	*	2½	2	0	9
10	Santa Isabel A	1	1½	1	0	1	1½	½	2	1½	*	1	0	10

Fuente: Frechin, 2015.

En este proyecto, el multivoto agrega un valor a las causas identificadas en la lluvia de ideas y clasificadas en el diagrama de Ishikawa, con el propósito de obtener un peso que posibilite la discriminación de las más importantes y con mayor impacto mediante la ayuda de otras herramientas.

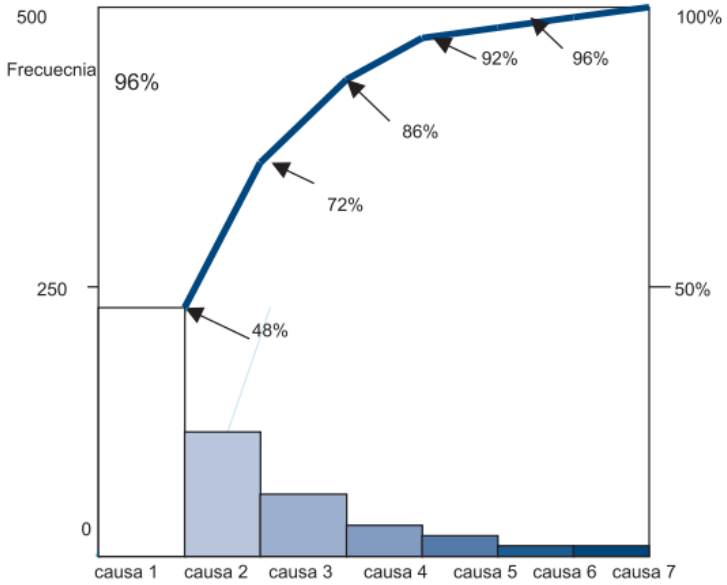
2.1.15 Diagrama de Pareto

El Instituto Uruguayo de Normas Técnicas (2009) explica cuándo utilizar este diagrama y el principio a partir del cual se rige:

> Un diagrama de Pareto es una técnica gráfica simple para ordenar elementos, desde el más frecuente hasta el menos frecuente, basándose en el principio de Pareto.
>
> Hay consenso en admitir que en numerosas situaciones que se plantean en las organizaciones, los problemas tienen una importancia desigual, fenómeno que no está limitado a cuestiones relativas a la calidad.
>
> En estos casos se da el principio de “los pocos vitales y los muchos triviales” que se conoce como principio de Pareto. Dicha proporción, en una gran mayoría

de los casos, ha resultado ser de aproximadamente un 20 % para los “pocos vitales” y de un 80 % para los “muchos triviales”. Este 20 % es el responsable de la mayor parte del efecto que se produce (p. 28).

Figura 2.13: Ejemplo de un diagrama de Pareto



Fuente: Instituto Uruguayo de Normas Técnicas, 2009, p. 30.

La aplicación de esta herramienta complementa el proceso de identificación, clasificación y valorización de las causas asociadas al error de pronóstico, determinando las de mayor relevancia dentro del proceso mediante el proceso del 80/20, con la finalidad de concentrar los esfuerzos en los aspectos que generan más impacto.

2.1.16 5 porqués

Araújo (2011) define esta herramienta a continuación:

> La práctica de los “5 porqués”, es una técnica sistemática de preguntas utilizada para el análisis de problemas y para buscar las posibles causas y soluciones (Ohno, 1997 en Santos, 2010: 56). Se pregunta “¿por qué?” cinco veces por cada problema encontrado con el objetivo de ir más allá de los síntomas evidentes, hasta que la verdadera causa del problema se torne clara y se encuentre la solución más efectiva. En realidad, no importa concretamente el número de

preguntas, lo que importa es que la causa real y final sea identificada y eliminada. (p. 143).

Figura 2.14: Ejemplo de un 5 porqués

Descripción del problema	1er ¿Por qué?	2do ¿Por qué?	3er ¿Por qué?	4to ¿Por qué?	5to ¿Por qué?
Vibración en máquina de línea de soldadura	¿Por qué hay vibración en la máquina de la línea de soldadura?	¿Por qué los baleros de rodamiento generan vibración de la máquina?	¿Por qué los baleros presentan desgaste prematuro?	¿Por qué presentan falta de lubricación?	¿Por qué no está considerada dentro de las tareas de mantenimiento preventivo de la máquina?
	Porque los baleros de rodamiento generan vibración de la máquina	Porque los baleros presentan desgaste	Porque presentan falta de lubricación	Porque no está considerada dentro de las tareas de mantenimiento preventivo de la máquina	Porque la lubricación de baleros no fue considerada como tarea crítica en el PM
	Cuando la causa raíz es una de las 5 razones, se debe dejar de preguntar **por qué**				

Fuente: Rodríguez, 2019.

Por medio de esta metodología, se pretende finalizar el ciclo RCA (análisis de causa raíz) posterior a la aplicación del Pareto, al establecer la causa raíz de los problemas encontrados en los análisis previos.

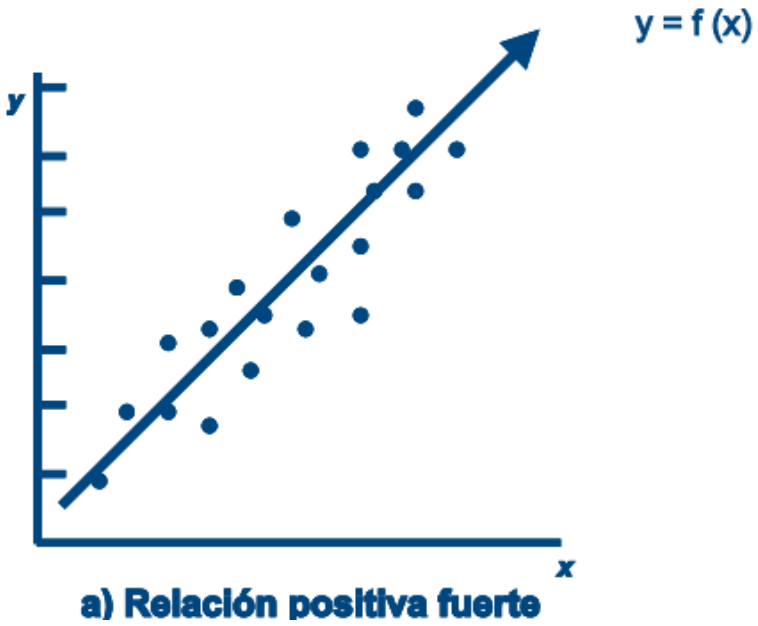
2.1.17 Diagrama de dispersión

El Instituto Uruguayo de Normas Técnicas (2009) señala respecto a este diagrama:

> El diagrama de dispersión representa gráficamente la relación entre dos conjuntos de resultados. Sin embargo, en muchas situaciones lo que se necesita es utilizar uno de los conjuntos de resultados para predecir o para verificar el otro conjunto. Para ello se emplea el análisis de regresión como una técnica de predicción y de medición del error en dichas predicciones.
>
> Para ello es necesario expresar la relación existente entre los dos conjuntos de resultados mediante una representación gráfica lineal o mediante una ecuación matemática.

La variable que se va a predecir se designa como y, variable dependiente, mientras que la otra variable, x, se denomina variable independiente o de predicción. La ecuación resultante queda expresada como y = f(x) (pp. 49-50).

Figura 2.15: Ejemplo de un gráfico de dispersión



Fuente: Instituto Uruguayo de Normas Técnicas, 2009, p. 50.

Este diagrama se pretende integrar como mejora al método de selección del modelo predictivo, pues facilita analizar las llamadas pronósticas y las llamadas reales con el objetivo de establecer el grado de correlación entre ambas variables y validar la consistencia de los resultados.

2.1.18 Matriz de decisión

De acuerdo con Alfaro (s.f.), “Una matriz de decisión es un gráfico que permite a un equipo o un individuo identificar y analizar la tasa de la fuerza de las relaciones entre conjuntos de información” (p. 1).

Referente a cuándo debe utilizarse, el autor agrega:

Una matriz de decisión se utiliza con frecuencia durante las actividades de planificación de la calidad para seleccionar producto/servicio, características y objetivos; desarrollar los procesos y sopesar las alternativas.

Para mejorar la calidad, una matriz de decisión puede ser útil en la selección de un proyecto, en la evaluación de soluciones alternativas a problemas y en el diseño de los recursos.

Por último, en cuanto a cómo usarse, Alfaro (s.f.) expone: “Dependiendo de las necesidades del equipo, estos pueden ser producto/prestaciones del servicio, etapas del proceso, los proyectos o las posibles soluciones” (p. 1).

Tabla 2.1: Ejemplo de una matriz de decisión

	Ponderación	Opción 1	Opción 2	Opción 3
Criterio 1				
Criterio 2				
Criterio 3				
	Total			

Fuente: Stepanets, 2024.

Con esta herramienta se identifican los parámetros e indicadores más relevantes para la medición del modelo. Su aplicación permite evaluar, asignar valor y ponderación, según los diferentes criterios y su importancia.

2.1.19 Repositorio web

En cuanto a su repositorio, Microsoft (2025) detalla:

> SharePoint Server 2019 te ofrece una plataforma moderna para el acceso compartido, la interacción y la colaboración. Ahora, el trabajo en equipo puede suceder en cualquier lugar, en cualquier momento y de forma rápida, confiable y segura. Crea, comparte ideas y toma decisiones con la administración de contenido y las herramientas de colaboración que se integran a la perfección con otras aplicaciones como OneDrive para la Empresa y Microsoft Graph.

Este repositorio web se implementa como herramienta de control en el uso continuo de un nuevo método de selección del modelo predictivo. Su uso posibilita trazabilidad y control de versiones, sirve de respaldo y aporta disponibilidad de acceso a la información.

2.1.20 Auditoría interna

Con relación a esta auditoría, Villardefrancos y Rivera (2006) describen:

> Por su parte, la auditoría interna constituye una excelente herramienta de apoyo a la dirección de las organizaciones, las que, generalmente, poseen un departamento especial dedicado a estos menesteres. Este tipo de auditoría, denominado también auditoría de gestión u operativa, pone el énfasis en la evaluación de políticas, procedimientos, métodos, así como en el análisis de tareas (p. 55).

Estas auditorías internas se aplican como método de control para garantizar la continuidad de un nuevo método de selección del modelo predictivo, la integridad de los archivos, el formato y el adecuado uso de este.

2.1.21 Reuniones

Ander-Egg (2002) brindan la siguiente definición de reunión y sus características:

> [...] una actividad que se genera en una situación de grupo, en un momento y espacio determinados y que tiene un objetivo específico.

> En este esbozo de definición, surgen claramente las tres notas que caracterizan a toda reunión. Decimos, en primer lugar, que es una **actividad** que se da en una situación de grupo. Es actividad, porque toda reunión supone que se está haciendo (interactuando, comunicando, participando), y aludimos a **situación de grupo**, porque una reunión puede realizarse sin que, necesariamente, quienes participan de la misma constituyan un grupo, pero tiene que realizarse al menos en una situación de grupo. Esta circunstancia interesa desde un punto de vista práctico en el momento de realizar las reuniones. En algunos casos, por la índole de la reunión, cuando se trata de personas que no se conocen, es necesario aplicar algunas técnicas de iniciación grupal, asegurando de esta forma un mejor clima para el comienzo de la reunión.
>
> Un grupo o una organización puede realizar reuniones más o menos frecuentes (periódicas, continuas), pero cada reunión, en sí, tiene un carácter puntual o efímero (en un tiempo y espacio determinados). Después de cumplir con los propósitos de la reunión, de estar juntos, reunidos durante un cierto tiempo, los participantes de la misma se separan.
>
> Una tercera característica de las reuniones es la de tener un **objetivo específico**. Como ya lo indicamos, las reuniones y los grupos deben tener objetivos bien claros y definidos. Cuando esto no se tiene en cuenta —y es bastante frecuente— quienes han participado en la reunión quedan con la sensación de no haber hecho nada útil, ni nada positivo, salvo el haber pasado un grato momento entre amigos. Pero, como es obvio, no tiene mucho sentido hacer una reunión de trabajo para encontrarse entre amigos (pp. 15-16).

Las reuniones se utilizan como medio para conocer aspectos cualitativos del proceso y realizar otras herramientas como la lluvia de ideas, matriz de decisión, entre otras. Además, se integran reuniones periódicas a la fase de control de la propuesta como un medio de comunicación y seguimiento que permita el análisis de los resultados obtenidos

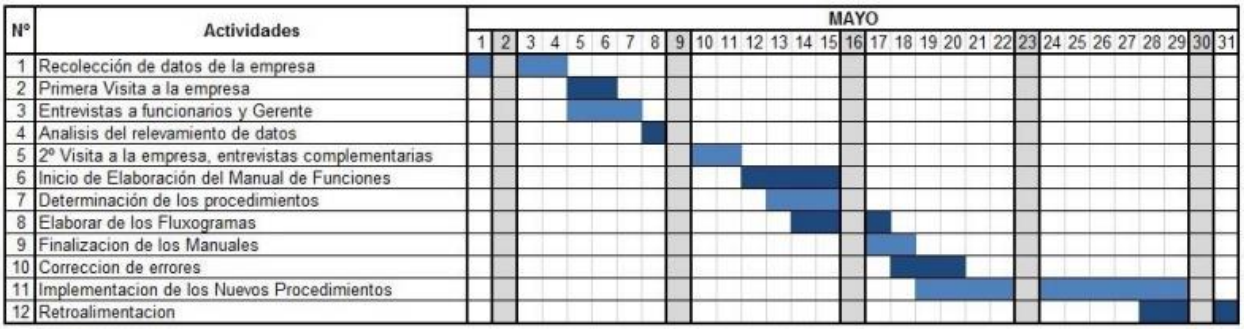
del nuevo método a lo largo del tiempo e identificar así posibles mejoras o cambios necesarios para el cumplimiento de los requerimientos.

2.1.22 Diagrama de Gantt

El Instituto Uruguayo de Normas Técnicas (2009) explica lo siguiente sobre este diagrama:

> El gráfico de Gantt fue desarrollado por Henry Gantt en 1918 durante la I Guerra Mundial para la programación del arsenal Frankford y continúa siendo una herramienta útil en la programación de proyectos y en el seguimiento de su ejecución. Su simplicidad y su claro desarrollo gráfico lo han establecido como de gran utilidad.
>
> El gráfico de Gantt es un gráfico de barras horizontales que consiste en hacer una lista de actividades, las cuales se indican verticalmente en un diagrama. En forma horizontal (con forma de barra), se indica el tiempo en las unidades más apropiadas según el tipo de proyecto de que se trata. Se representa tanto la duración prevista como la verdadera de cada actividad, mediante una barra de longitud adecuada.
>
> El gráfico indica, también, el inicio más temprano posible para cada actividad. Eso depende de si tiene que estar finalizada o no una actividad para ejecutar la siguiente.
>
> Cuando se completa cada actividad (o parte de ella), se sombrea la barra correspondiente. Por lo tanto, en un momento cualquiera se ve con claridad cuáles actividades están “en tiempo” y cuáles no.
>
> El gráfico de Gantt se usa, también, como un registro para llevar el seguimiento de la progresión en el tiempo de las actividades a ejecutar para cada proyecto (p. 83).

Figura 2.16: Ejemplo de un diagrama de Gantt



Fuente: Ingeniería de Software 3CV3, 2025.

Este diagrama representa de forma visual la planificación de las fases y actividades de la propuesta en este estudio, así como proyecta las fechas y la duración de estas implementaciones. De esta manera, aporta una estructura y control para estas.

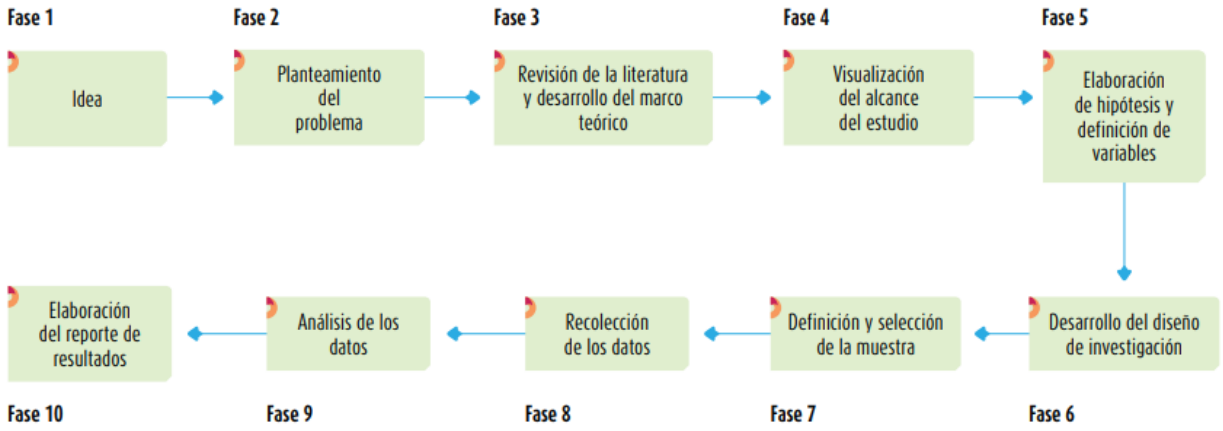
CAPÍTULO III. MARCO METODOLÓGICO

3.1 ENFOQUE DE LA INVESTIGACIÓN

El presente estudio se desarrolla con base en un enfoque mixto, ya que posee secciones cualitativas complementarias, pero en su gran mayoría se plantea bajo un enfoque cuantitativo, el cual parte de una idea inicial que gradualmente se va ejecutando sobre medidas cuantitativas. Este último enfoque permite analizar datos numéricos de manera estructurada, como lo explican Hernández et al. (2014):

> El enfoque cuantitativo (que representa, como dijimos, un conjunto de procesos) es secuencial y probatorio. Cada etapa precede a la siguiente y no podemos "brincar" o eludir pasos. El orden es riguroso, aunque desde luego, podemos redefinir alguna fase. Parte de una idea que va acotándose y, una vez delimitada, se derivan objetivos y preguntas de investigación, se revisa la literatura y se construye un marco o una perspectiva teórica. De las preguntas se establecen hipótesis y determinan variables; se traza un plan para probarlas (diseño); se miden las variables en un determinado contexto; se analizan las mediciones obtenidas utilizando métodos estadísticos, y se extrae una serie de conclusiones respecto de la o las hipótesis (p. 4).

Figura 3.1: Fases del proceso de la investigación cuantitativa



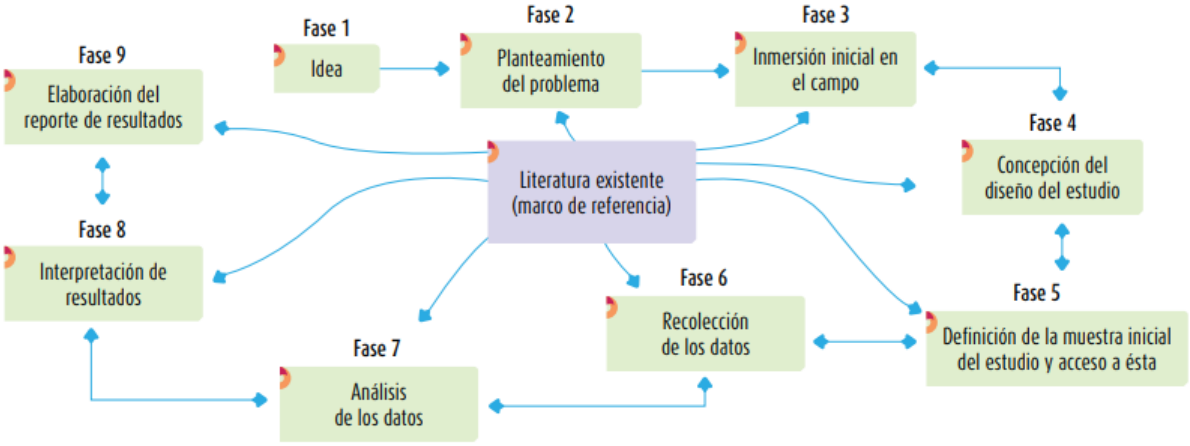
Fuente: Hernández et al., 2014, p. 5.

Al mismo tiempo, esta investigación propone el uso de herramientas cualitativas, como las reuniones con los analistas y jefaturas en busca de la experiencia para identificar

factores clave en los KPI por utilizar para efectuar las medidas cualitativas. Referente al enfoque, Hernández et al. (2014) expresan:

> El enfoque cualitativo también se guía por áreas o temas significativos de investigación. Sin embargo, en lugar de que la claridad sobre las preguntas de investigación e hipótesis preceda a la recolección y el análisis de los datos (como en la mayoría de los estudios cuantitativos), los estudios cualitativos pueden desarrollar preguntas e hipótesis antes, durante o después de la recolección y el análisis de los datos. Con frecuencia, estas actividades sirven, primero, para descubrir cuáles son las preguntas de investigación más importantes; y después, para perfeccionarlas y responderlas. La acción indagatoria se mueve de manera dinámica en ambos sentidos: entre los hechos y su interpretación, y resulta un proceso más bien "circular" en el que la secuencia no siempre es la misma, pues varía con cada estudio (p. 7).

Figura 3.2: Fases del proceso de la investigación cualitativa



Fuente: Hernández et al., 2014, p. 7.

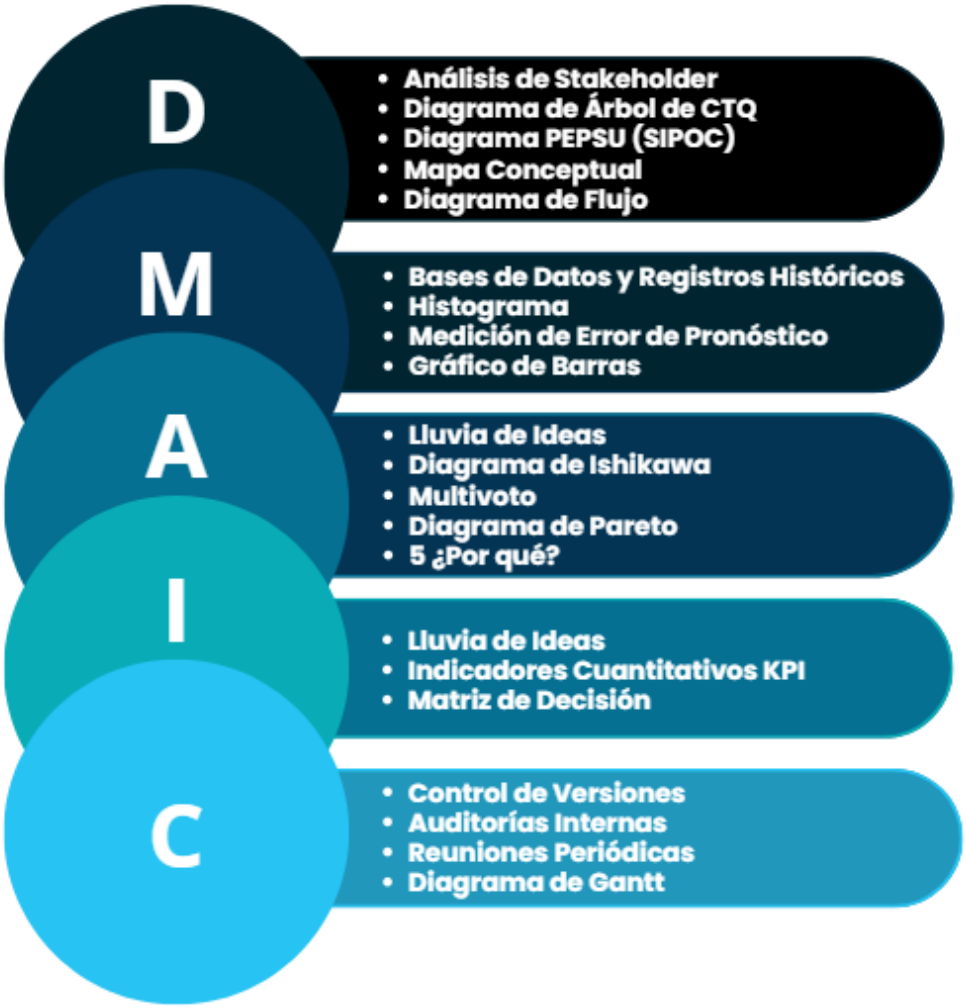
En la ejecución de este estudio, el enfoque se aplica mediante un proceso secuencial y estructurado, iniciando con la identificación del problema y la demarcación de la investigación. A partir de esto, se establecen los objetivos, las herramientas por utilizar y

se determinan las variables clave vinculadas al error de pronóstico de los modelos predictivos.

Se recolectan datos históricos y se emplean medidas cuantitativas de parámetros estadísticos, entre otros, para evaluar los distintos modelos de pronósticos utilizados en el proceso de dimensionamiento de la empresa. Con base en estas mediciones, se pretende seleccionar el modelo con el menor error de pronóstico, validando cuantitativamente su efectividad.

3.2 MÉTODO DE LA INVESTIGACIÓN

Figura 3.3: Método de la investigación



Fuente: Elaboración propia, 2025.

3.3 FUENTES DE INFORMACIÓN

Fuentes primarias

Hernández et al. (2014) señalan que estas fuentes “proporcionan datos de primera mano, pues se trata de documentos que incluyen los resultados de los estudios correspondientes” (p. 61). Tamayo (2003, como se citó en Gallardo, 2017) agrega que estas fuentes “constituyen elementos básicos de la investigación” (p. 45).

Asimismo, Hernández et al. (2014) brindan los siguientes ejemplos de fuentes primarias: “libros, antologías, artículos de publicaciones periódicas, monografías, tesis y disertaciones, documentos oficiales, reportes de asociaciones, trabajos presentados en conferencias o seminarios, artículos periodísticos, testimonios de expertos, documentales, videocintas en diferentes formatos, foros y páginas en internet, etc.” (p. 61).

Fuentes secundarias

De acuerdo con Beaudiquez (1983) y Villaseñor-Rodríguez (1998, como se citaron en Gallardo, 2017): “Son listas de fuentes primarias que remiten generalmente a documentos primarios. La fuente secundaria menciona y comenta brevemente el contenido de las publicaciones. Luego de leer el resumen (*abstract*), se evalúa si es o no útil” (p. 45).

Adicional, Monje-Álvarez (2011), Salkind (1999) y Tamayo (2003, como se citaron en Gallardo, 2017) proporcionan los siguientes ejemplos: “Enciclopedias, diarios, publicaciones periódicas, reseñas de investigaciones, boletines estadísticos o censales, bibliografías, resúmenes, catálogos de bibliotecas, bases de datos bibliográficas referenciales, etc.” (p. 45).

En cuanto al estudio, se utilizan como fuentes primarias los registros históricos del volumen de llamadas y los pronósticos históricos, además de las reuniones con los colaboradores del WFM, las cuales cuentan con el consentimiento informado de los

participantes y se hacen bajo un muestreo intencional, porque se selecciona a los colaboradores que tienen un conocimiento directo de los procesos de pronóstico y dimensionamiento de personal. Además, se incluyen fuentes secundarias como artículos académicos y técnicos para sustentar teóricamente los modelos de pronóstico, los errores de pronóstico y los métodos de análisis usados.

3.3.1 Project charter

A continuación, se detalla el *project charter* empleado para desarrollar la investigación:

Tabla 3.1: Project charter para la investigación

<table>
<tr><th colspan="3">ACTA DE CONSTITUCIÓN DEL PROYECTO</th></tr>
<tr><td>1. Fecha
8/6/2025.</td><td colspan="2">2. Nombre del proyecto
“EVALUACIÓN DEL MÉTODO ACTUAL DE SELECCIÓN DE MODELOS PREDICTIVOS INTEGRANDO CAMBIOS Y PARÁMETROS QUE OPTIMICEN LA PRECISIÓN DEL PRONÓSTICO EN EL PROYECTO BANCO”</td></tr>
<tr><td colspan="2">3. Miembros
3.1. Equipo de trabajo
Andrés Villalobos Esquivel.
3.2. Supervisor del proyecto
Ricardo Segura Barboza (coordinador de WFM).</td><td>4. Área de aplicación, interesados del proyecto:
Departamento de Workforce Management.</td></tr>
<tr><td colspan="2">5. Fecha de inicio del proyecto: 20/05/2025.</td><td>6. Fecha tentativa de finalización: 30/10/2025.</td></tr>
<tr><td colspan="3">7. Objetivos del proyecto
7.1. Objetivo general: Evaluar el actual método de selección del modelo predictivo de llamadas de la empresa NETCOM BUSINESS CONTACT CENTER, identificando oportunidades de mejora y parámetros que optimicen la selección del modelo predictivo.
7.2. Objetivos específicos
7.2.1 Analizar el actual método de selección del modelo predictivo de llamadas mediante la revisión detallada de los datos históricos de los últimos 12 meses, cuantificando el error del modelo generado y potenciando áreas de mejora.
7.2.2 Validar oportunidades de mejora, incluyendo cambios y parámetros al modelo actual, que optimicen la selección y el pronóstico del modelo predictivo.
7.2.3 Recomendar la implementación de un método de selección del modelo predictivo de llamadas que integre cambios y mejoras que optimicen el pronóstico de llamadas de la empresa NETCOM BUSINESS CONTACT CENTER.</td></tr>
<tr><td colspan="3">Descripción del producto: pronóstico de llamadas entrantes.</td></tr>
<tr><td colspan="3">Necesidad del proyecto: robustecer el método actual de selección del modelo de pronóstico para reducir el error de precisión.</td></tr>
</table>

Posibles restricciones: por temas de confidencialidad, no se utiliza el nombre del proyecto.	
Supuestos:	
Identificación de los grupos de interés (*stakeholders*): Andrés Villalobos Esquivel. **Cliente directo:** Banco. **Cliente indirecto:** Departamento de Operaciones.	
Aprobado por: Andrés Villalobos Esquivel.	**Firma:**
Presentado por: Andrés Villalobos Esquivel.	**Firma:**

Fuente: Elaboración propia, 2025.

3.4 VARIABLES DE ANÁLISIS

Seguidamente, se adjunta la tabla que contiene las variables de la investigación formuladas según los objetivos específicos, así como su definición conceptual, instrumental y operacional:

Tabla 3.2: Variables de la investigación por objetivo específico

Objetivo específico	Variable	Definición conceptual	Operacionalización	Instrumentalización
Analizar el actual método de selección del modelo predictivo de llamadas mediante la revisión detallada de los datos históricos de los últimos 12 meses, cuantificando el error del modelo generado y potenciando áreas de mejora.	Precisión del pronóstico actual	Diferencia entre los valores estimados por un modelo de pronóstico y los valores reales.	Cálculo de la precisión del pronóstico histórico del periodo comprendido desde junio 2024 hasta julio 2025.	Análisis de *stakeholders* Modelo Gardner Diagrama de árbol de CTQ Diagrama PEPSU Mapa conceptual Diagrama de flujo Bases de datos o registros históricos Histograma Gráfico de pastel y barras Medición del error de pronóstico
Validar oportunidades de mejora, incluyendo cambios y parámetros al modelo actual, que optimicen la selección y el pronóstico del modelo predictivo.	Parámetros estadísticos	Parámetros estadísticos que permiten evaluar modelos predictivos.	Validar cambios en el modelo actual, aportando la inclusión de parámetros y cambios.	Diagrama de flujo Lluvia de ideas Indicadores cuantitativos KPI Matriz de decisión
Recomendar la implementación de un método de selección del modelo predictivo de llamadas que integre cambios y mejoras que optimicen el pronóstico de llamadas de la empresa NETCOM BUSINESS CONTACT CENTER.	Creación del nuevo modelo	Creación de un nuevo método de selección del modelo predictivo.	Aplicación de las mejoras identificadas, desarrollando un nuevo método.	Gráfico de pastel y barras Indicadores cuantitativos KPI Diagrama de Gantt Repositorio web Auditorías internas Reuniones periódicas

Fuente: Elaboración propia, 2025.

3.5 INSTRUMENTOS

Con relación a esta investigación, se utilizan instrumentos de acuerdo con el enfoque cuantitativo y la naturaleza del problema. Estos permiten medir y analizar los resultados de los modelos de pronósticos.

Los registros históricos, correspondientes a las bases de datos de las llamadas entrantes y los modelos de pronóstico utilizados, son el principal instrumento empleado. Esta es una fuente primaria de información que ofrece datos cuantificables, los cuales son indispensables para la medición del error de pronóstico de los modelos predictivos.

También se llevan a cabo reuniones con los analistas de datos y la jefatura de WFM, con la intención de obtener información cualitativa de apoyo sobre la percepción del método actual, forma de selección y criterios utilizados, lo que posibilita identificar puntos clave no reflejados en los datos históricos.

Además, se hace uso de otras herramientas de análisis, como el diagrama de flujo y SIPOC, para identificar el proceso y herramientas como gráficos de barras, histogramas, KPI y la matriz de decisión, que permiten organizar, visualizar y comparar la información recolectada, facilitando la toma de decisiones de los modelos de pronósticos más precisos.

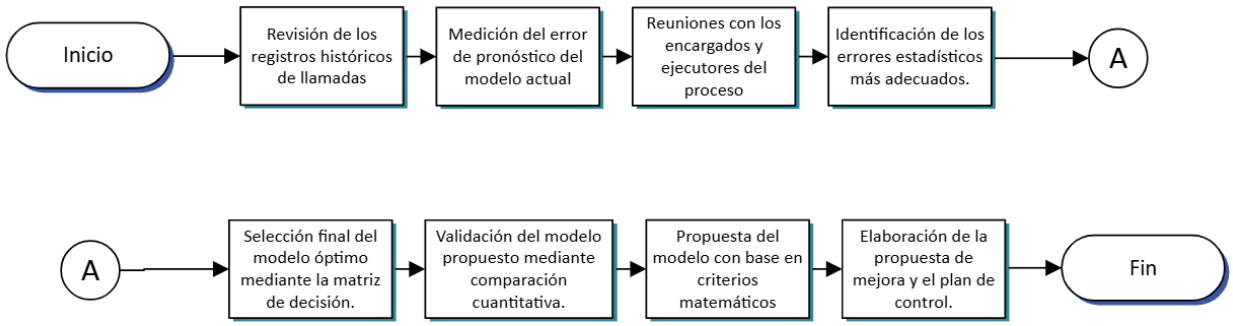
3.6 PROCESO PARA LA RECOLECCIÓN Y ANÁLISIS DE DATOS

El proceso de recolección de datos inicia con la recopilación de los datos históricos reales del modelo y los valores de los pronósticos utilizados, específicamente los datos de llamadas por día que sirven como el principal insumo para el cálculo de errores de pronóstico.

Luego, se hacen reuniones con los analistas de datos y la jefatura de WFM para contextualizar los resultados y obtener los criterios de primera mano de los ejecutores del proceso, así como los parámetros y cambios que se plantean emplear.

Una vez obtenida la información, se aplican los parámetros que posibilitan medir y comparar el margen de error entre el modelo actual y el propuesto. Este análisis se complementa con las herramientas gráficas como el histograma, los gráficos de dispersión y barras, además de la matriz de decisión, con el fin de facilitar la comparación objetiva de los resultados.

Figura 3.4: Diagrama de flujo del proceso de recolección de datos



Fuente: Elaboración Propia (2025)

A continuación, se enumera la secuencia de pasos ilustrados en el diagrama de flujo en la figura 3.4:

1. Revisión de los registros históricos de llamadas.
2. Medición del error de pronóstico del modelo actual.
3. Reuniones con los encargados y ejecutores del proceso.
4. Identificación de los errores estadísticos más adecuados.
5. Selección final del modelo óptimo mediante la matriz de decisión.
6. Propuesta del modelo con base en criterios matemáticos y estadísticos.
7. Validación del modelo propuesto mediante comparación cuantitativa.
8. Elaboración de la propuesta de mejora y el plan de control.

CAPÍTULO IV. ANÁLISIS DE RESULTADOS

4.1 DEFINIR

NETCOM BUSINESS CONTACT CENTER incluye dentro de su portafolio de proyectos al Proyecto Banco, el cual sobresale como uno de los principales por su magnitud. Al respecto, es el proyecto con la planilla más grande al representar aproximadamente un 25 % de la población de la empresa, según los datos del Departamento de RR. HH.; además, su aporte financiero es alrededor de un 20 % de la facturación mensual de la empresa.

Cabe mencionar que el pronóstico de llamadas se debe realizar 50 días hábiles antes debido al desfase operativo, correspondiente al tiempo en que RR. HH. debe reclutar al personal y el Departamento de Capacitación formarlo y entrenarlo adecuadamente. Adicional, el tipo de producto del cliente Banco es muy amplio, delicado y complicado; así, la capacitación de este proyecto es de las más extensas y, por el mismo motivo, el perfil de los agentes solicitado por el cliente es exigente.

Dentro de los acuerdos contractuales del proyecto, destacan los indicadores relacionados al desarrollo de este trabajo, detallados a continuación:

- **Nivel de servicio:** contestar el 80 % de las llamadas antes del umbral de 20 segundos.
- **Tasa de respuesta (TR):** contestar el 95 % de las llamadas entrantes.

Estos son los indicadores contractuales de referencia para el cálculo del personal necesario, siendo el pronóstico de llamadas (objeto de estudio) una de las principales variables. También, en caso de incumplimiento de los anteriores SLA (acuerdo de nivel de servicio), en el contrato se estipulan multas escalonadas según el incumplimiento, empezando en un 5 % hasta un 25 % de la facturación total.

Tabla 4.1: Multas por el incumplimiento de un SLA

Porcentaje de multa	Rango mínimo	Rango máximo
5,0 %	76,00 %	79,99 %
10,0 %	72,00 %	75,99 %
15,0 %	68,00 %	71,99 %
20,0 %	64,00 %	67,99 %
25,0 %	0,00 %	63,99 %

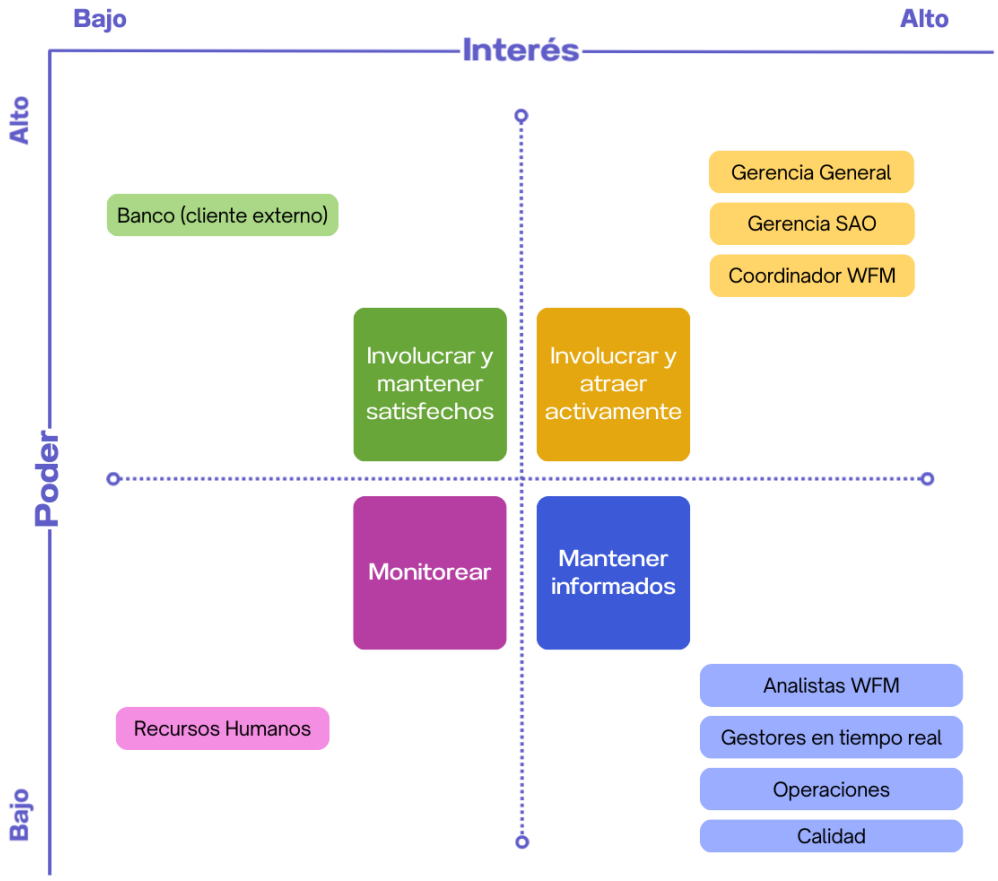
Fuente: Elaboración propia, 2025.

Por lo anterior, existe un proceso de validaciones que se realiza para no ser penalizado, situación que ocurre en la mayoría de los meses. Sin embargo, aunque el proceso permita no ser multado, hay pérdidas generadas por sobrepoblación o por ganancias no percibidas al disponer de más o menos personal del requerido. Es aquí donde el dimensionamiento de personal toma protagonismo, al ser el mecanismo mediante el cual se estima la capacidad necesaria para atender las llamadas y, en cuanto a la finalidad de este estudio, conocer el impacto financiero que la desviación en el pronóstico de llamadas provoca en el dimensionamiento al ser la variable principal.

El cálculo del dimensionamiento se lleva a cabo en el Departamento de WFM por el analista. El proceso contempla un ejercicio de proyección de la demanda basado en la teoría de colas de Erlang (Erlang C). Para esto, se requiere de los pronósticos de llamadas, AHT y los respectivos reductores, siendo en este caso tiempos auxiliares (café, baño, almuerzo, entre otros no predecibles), ausentismo y rotación. A efectos de esta investigación, se trabaja solamente en el pronóstico de llamadas, el mismo se efectúa en Forecast Pro, y para las demás variables se toman los valores preestablecidos con el fin de no alterar el cálculo.

4.1.1 Análisis de stakeholders

Figura 4.1: Análisis de stakeholders



Fuente: Elaboración propia, 2025.

Mediante el anterior análisis de *stakeholders* en el modelo Gardner, se identifican las siguientes relaciones de poder e interés:

Alto poder–alto interés

La Gerencia SAO (Servicios de áreas de Apoyo a la Operación), la Gerencia General y el coordinador de WFM son las partes con alto poder e interés, debido a su jerarquía en la toma de decisiones y por la supervisión directa del proceso de pronósticos. De esta manera, se llevan a cabo reuniones periódicas para la toma de decisiones sobre el proceso.

Alto poder–bajo interés

El cliente externo representa un alto poder, pero un bajo interés en los aspectos técnicos del proceso de pronósticos, por lo que se debe mantener satisfecho mediante informes ejecutivos vinculados a los resultados del servicio.

Bajo poder–alto interés

Los analistas de WFM, Calidad, gestores en tiempo real y Operaciones tienen un alto interés en el resultado y desarrollo del proceso de pronósticos, pues los resultados de este derivan en su gestión diaria; no obstante, poseen un menor poder de decisión en el proceso, por lo cual se deben mantener informados de cambios que se presenten.

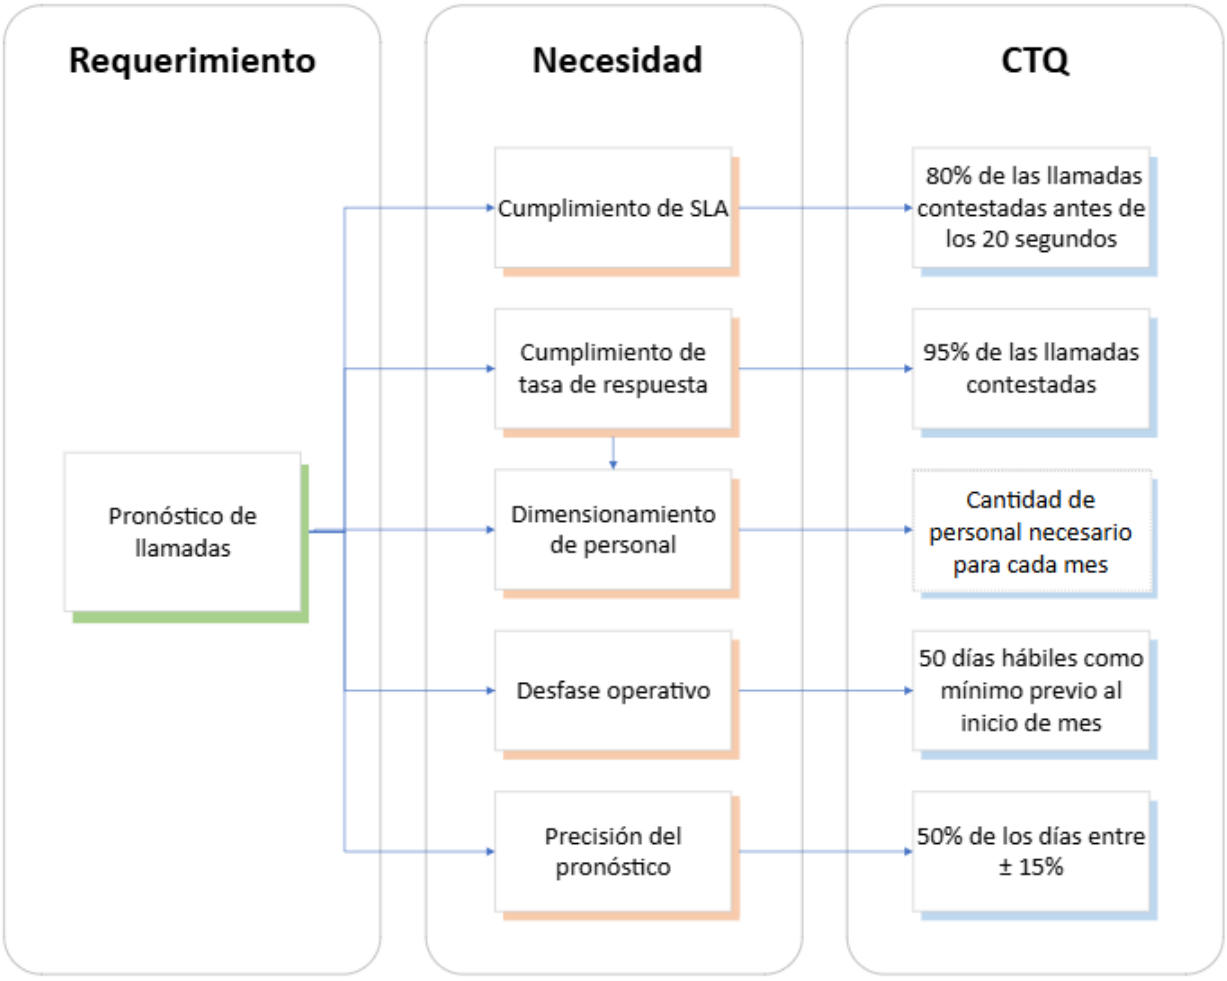
Bajo poder–bajo interés

El Departamento de Recursos Humanos tiene un bajo poder e interés en los aspectos técnicos; por esto, se debe monitorear para asegurar que el personal requerido derivado de los cálculos del pronóstico se cumpla de forma adecuada.

4.1.2 Diagrama de árbol de CTQ

Con la finalidad de representar las necesidades del cliente en parámetros cuantificables y alineados al proceso de pronóstico, se realiza el siguiente árbol de CTQ. Con este diagrama se identifican de manera estructurada la necesidad, los requisitos operativos para esta y, por consiguiente, los indicadores críticos de la calidad que sirven como referencia para evaluar el proceso.

Figura 4.2: Diagrama de árbol de CTQ



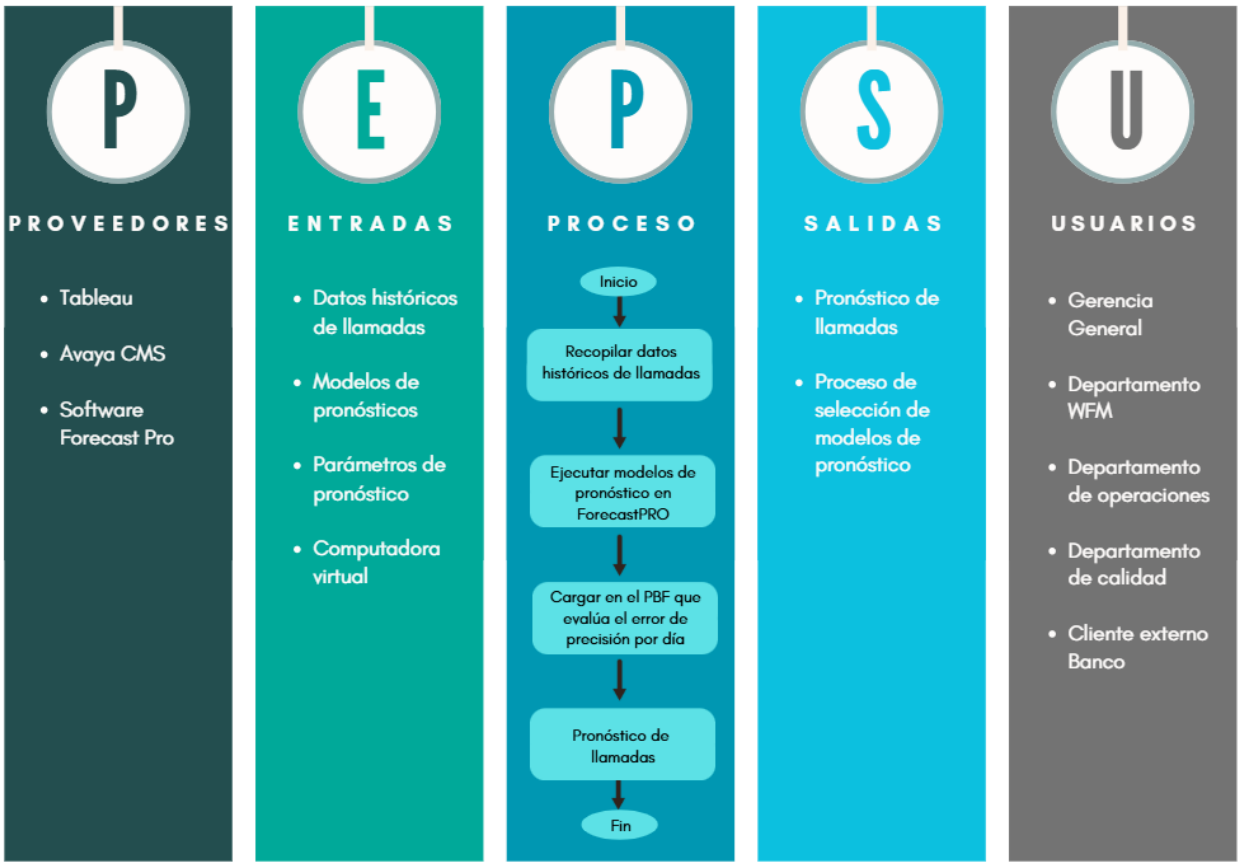
Fuente: Elaboración propia, 2025.

El árbol de CTQ permite determinar las necesidades operativas y del cliente derivadas en métricas que orientan la gestión del pronóstico de llamadas. Mediante los indicadores definidos, se establece una relación directa entre el cumplimiento del nivel de servicio, el adecuado dimensionamiento de personal y la precisión; estos parámetros sirven como referencia para la mejora del modelo de pronóstico.

4.1.3 Diagrama PEPSU (SIPOC) del pronóstico de llamadas

El siguiente diagrama PEPSU ayuda a visualizar de una forma conjunta las fases del proceso:

Figura 4.3: Diagrama PEPSU (SIPOC) del pronóstico de llamadas



Fuente: Elaboración propia, 2025.

Por medio de la figura 4.3, se puede entender de una mejor manera el contexto del proceso de pronóstico desde los proveedores, las herramientas internas de modelado y almacenamiento de datos, los parámetros y ajustes en las entradas, el proceso de pronóstico, las salidas de este hasta los usuarios interesados en estas salidas.

Dimensionamiento de personal

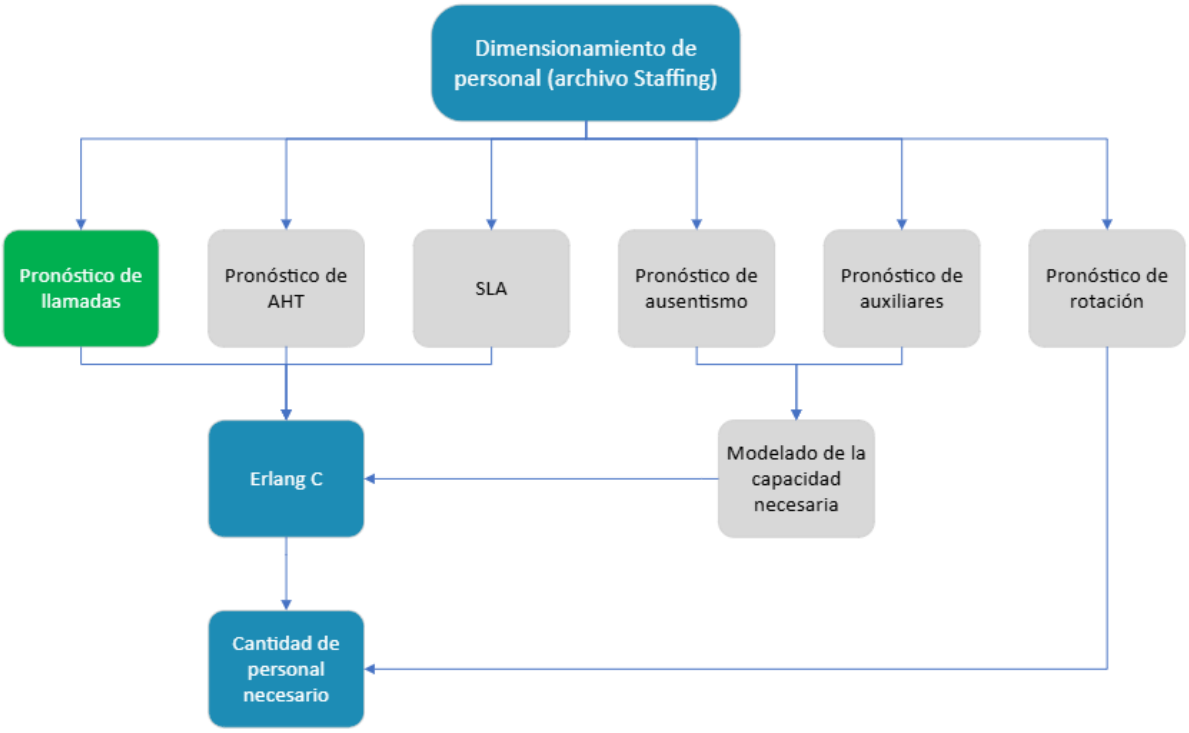
Como se menciona al inicio de este capítulo, el dimensionamiento de personal es el producto derivado del pronóstico de llamadas. A efectos del presente estudio, se toma este cálculo para poder conocer el impacto y las pérdidas asociadas al error de pronóstico y lo que este provoca en el cálculo del dimensionamiento de personal.

El Proyecto Banco opera con un rango de entre 150 y 200 colaboradores, según la época del año, y requiere del proceso de dimensionar el personal necesario de forma mensual para garantizar el cumplimiento de sus objetivos operativos.

4.1.4 Mapa conceptual del dimensionamiento de personal

Con el propósito de tener un mejor contexto del proceso y saber por qué se incluye el dimensionamiento de personal en este estudio, el cual se centra en el pronóstico de llamadas, se realiza el siguiente mapa conceptual:

Figura 4.4: Mapa conceptual del dimensionamiento de personal

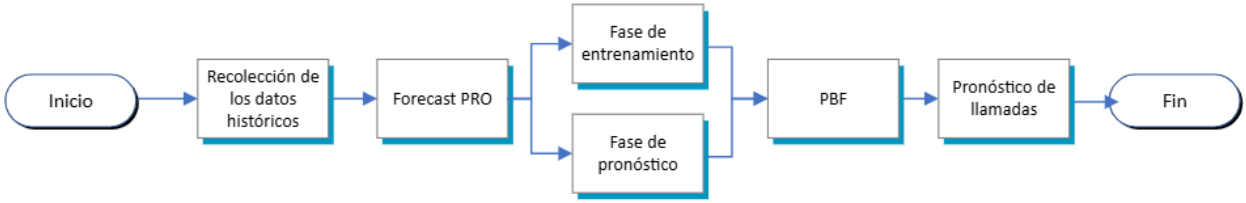


Fuente: Elaboración propia, 2025.

En el anterior mapa conceptual, se aprecian los componentes del cálculo del dimensionamiento de personal. Al respecto, en color verde se indica el pronóstico de llamadas, en color azul los procesos derivados de este y en gris los elementos necesarios para el cálculo que están fuera del alcance del proyecto. Al ser la cantidad de personal necesario el cálculo final y la razón por la que se hace este dimensionamiento, se toman como base para el cálculo asociado a las pérdidas por la desviación de pronóstico.

4.1.5 Diagrama de flujo del proceso de pronóstico de llamadas

Figura 4.5: Diagrama de flujo del proceso de pronóstico de llamadas



Fuente: Elaboración propia, 2025.

Recolección de los datos históricos

Actualmente el proceso para pronosticar la cantidad de llamadas durante el mes inicia en la recolección de datos históricos que se lleva a cabo en la plataforma de Tableau, donde se almacenan todos los reportes con un periodo de actualización diario.

Forecast PRO

Posterior a la recolección de datos, se efectúa el ejercicio de pronóstico en la herramienta Forecast PRO, donde se modelan los datos en los siguientes modelos predictivos:

- **Selección experta:** algoritmo de Forecast Pro que escoge dentro de su gama de modelos el que más se ajusta según parámetros estadísticos predefinidos.
- ***Machine learning* (ML):** modelo de aprendizaje automático basado en árboles de decisión.
- **Suavización exponencial:** con sus modelos derivados, automático, simple, Holt, Winters, NA-CL.
- **Box Jenkings:** metodología para seleccionar y autoajustar modelos ARIMA.

En este punto se realizan dos modelados de datos divididos en dos fases que transcurren de manera paralela, es decir, no se puede avanzar hasta terminar ambas.

Fase de entrenamiento

Consiste en hacer los pronósticos en cada uno de los modelos predictivos descritos anteriormente con un desfase de mínimo 6 semanas hacia el pasado. Este desfase

permite comparar los resultados con los datos reales, calculando los días dentro del umbral definido por la Gerencia de ± 15% y, así, definir qué modelo predice de una mejor forma los datos de llamadas para cada día.

Fase de pronóstico

En esta fase se efectúa de nuevo el pronóstico en cada uno de los modelos predictivos, pero en esta ocasión con todos los datos históricos disponibles para obtener los datos futuros que se van a asignar al pronóstico final, luego de evaluar cuál de los modelos es mejor para cada día.

PBF (plannig budget forecasting)

Todo esto se incluye en el archivo de Excel llamado PBF, el cual se encuentra formulado para identificar el mejor modelo por día y, de esta manera, seleccionar cada modelo para cada día del mes por dimensionar. A modo de ejemplo, se aprecia el siguiente extracto:

Tabla 4.2: Ejemplo de la combinación de modelos

Fecha	Modelo
Día 1	Suavización exponencial Winters
Día 2	*Machine learning* (ML)
Día 3	Box Jenkings
Día 4	Suavización exponencial Holt
Día 5	Box Jenkings
Día 6	Suavización exponencial Winters
Día 7	Selección experta
Día 8	Suavización exponencial automática

Fuente: Elaboración propia, 2025.

Pronóstico de llamadas

Una vez concluido este proceso, el pronóstico de llamadas seleccionado se coloca en el archivo de Excel llamado Staffing, junto a las demás variables necesarias como lo son los reductores y la proyección de la capacidad instalada con todas sus restricciones. Esto posibilita, mediante la teoría de colas de Erlang, el cálculo de la cantidad de personal necesario para atender la demanda del mes en cuestión.

4.2 MEDIR

4.2.1 Bases de datos y registros históricos

En cuanto a esta etapa, se inicia con el establecimiento de una base de datos con todos los registros históricos de llamadas y los pronósticos utilizados en los dimensionamientos correspondientes al periodo comprendido desde julio del 2024 hasta junio 2025.

Las bases de datos se adjuntan en los anexos 1 al 12, los cuales contienen la información agrupada por cada uno de los meses del periodo de estudio. Ahora bien, con el fin de representar estas bases de datos, se crea un consolidado mensual en la siguiente tabla:

Tabla 4.3: Registro histórico mensual, julio 2024–junio 2025

Mes	Real	Combinado	Selección experta	*Machine learning* (ML)	Suavización exponencial automática	Suavización exponencial Winters	Suavización NA-CL	Box Jenkings
Julio 2024	Información Confidencial		168 639	184 796	191 407	191 302	207 401	168 639
Agosto 2024			170 396	178 239	185 854	186 557	203 648	170 396
Septiembre 2024			162 354	158 214	177 760	178 466	194 782	162 354
Octubre 2024			167 801	230 553	204 963	217 829	177 989	167 801
Noviembre 2024			157 419	219 344	192 598	206 854	167 095	157 419
Diciembre 2024			147 553	152 340	182 150	156 977	148 163	147 553
Enero 2025			172 235	173 506	161 682	173 920	201 401	172 235
Febrero 2025			146 449	143 978	161 920	164 816	150 460	146 449
Marzo 2025			159 264	153 620	184 879	184 384	172 866	159 264
Abril 2025			140 306	164 880	140 306	132 668	167 652	164 065
Mayo 2025			142 665	130 552	139 906	116 503	142 665	157 450
Junio 2025			136 943	136 914	129 312	130 191	136 943	143 028

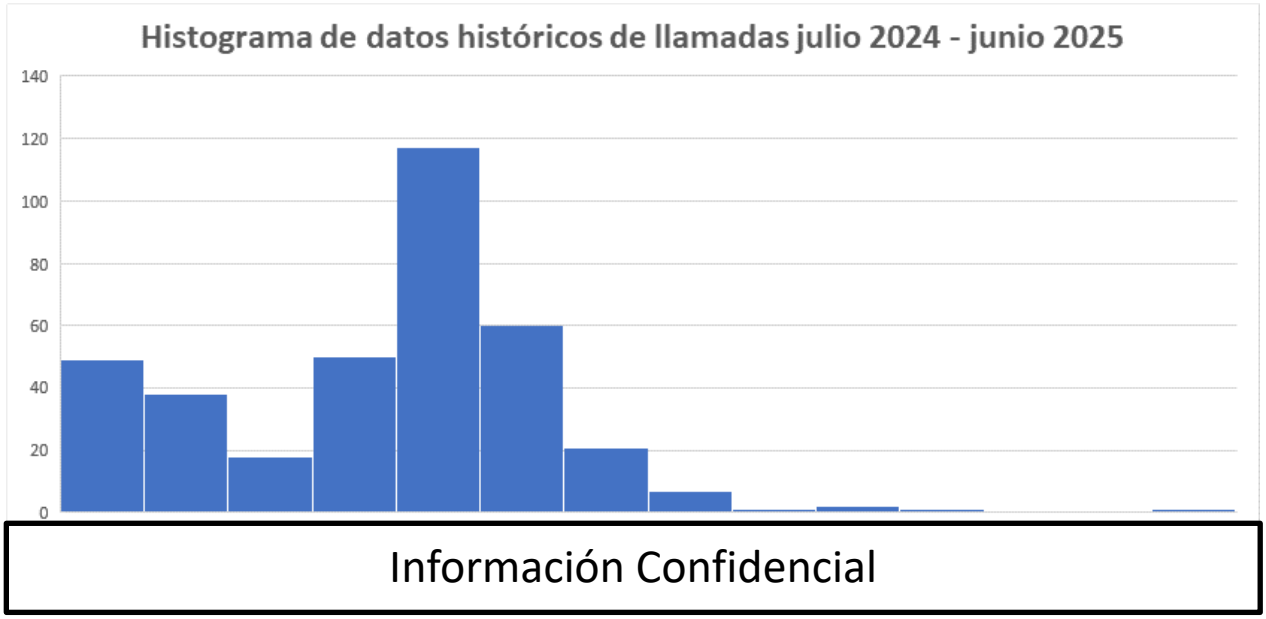
Fuente: Elaboración propia, 2025.

Este registro histórico funciona como la base principal para la aplicación de los modelos predictivos, el cálculo de las precisiones de pronóstico, los cálculos necesarios en las herramientas utilizadas en el desarrollo de este proyecto y cualquier otro parámetro estadístico o matemático que se requiera. Además, esta información sirve como referencia para calcular el impacto del sobre- o subdimensionamiento de personal.

4.2.2 Histograma

Con el objetivo de analizar la distribución de la demanda, se lleva a cabo un histograma a partir de los volúmenes diarios de las llamadas reales correspondientes al periodo comprendido en el estudio. Esto posibilita visualizar de manera gráfica la frecuencia con la que se presentan los distintos rangos de volúmenes de llamadas e identificar los valores comunes.

Figura 4.6: Histograma de los datos históricos de llamadas, julio 2024–junio 2025



Fuente: Elaboración propia, 2025.

El histograma es fundamental para apreciar la variabilidad natural de la demanda de llamadas y como parámetro de referencia para conocer la frecuencia de los rangos del volumen de llamadas, además permite reconocer patrones, picos de llamadas y periodos con menor actividad. Esta información sirve como contexto para los posteriores análisis y la evaluación de los modelos predictivos.

4.2.3 Error de pronóstico

Posteriormente, se cuantifica el resultado del error de pronóstico por mes, el cual es el resultado de medir la precisión de cada uno de los días en un rango de ± 15 %, es decir,

los días que el EPP (error precisión del pronóstico) no exceda el 115 % y no sea menor a 85 %, por ejemplo:

$$EPP = \frac{\text{Pronóstico}}{Real}$$

Tabla 4.4: Ejemplo de un error de precisión del pronóstico

Fecha	Pronóstico	Realidad	EPP
1/6/2025	1652	Información Confidencial	**93,0 %**
2/6/2025	6615		**90,4 %**
3/6/2025	5875		**91,9 %**
4/6/2025	5330		**93,2 %**
5/6/2025	5673		**105,8 %**
6/6/2025	5673		**107,6 %**
7/6/2025	3254		**124,7 %**
8/6/2025	1604		**130,7 %**
9/6/2025	6525		**108,2 %**
10/6/2025	5875		**83,2 %**
11/6/2025	5144		**68,1 %**
12/6/2025	5673		**82,6 %**
13/6/2025	5673		**74,5 %**
14/6/2025	2764		**63,6 %**
15/6/2025	1674		**70,8 %**
16/6/2025	6563		**83,8 %**
17/6/2025	5875		**89,2 %**
18/6/2025	5330		**98,0 %**
19/6/2025	5326		**102,4 %**
20/6/2025	5673		**107,0 %**
21/6/2025	2732		**101,7 %**
22/6/2025	1624		**130,7 %**
23/6/2025	6594		**117,4 %**
24/6/2025	5642		**106,9 %**
25/6/2025	5330		**108,6 %**
26/6/2025	5673		**120,3 %**
27/6/2025	5673		**106,6 %**
28/6/2025	2813		**84,6 %**
29/6/2025	1651		**113,1 %**
30/6/2025	6937		**88,3 %**

Fuente: Elaboración propia, 2025.

Tabla 4.5: Consolidado de resultados del EPP

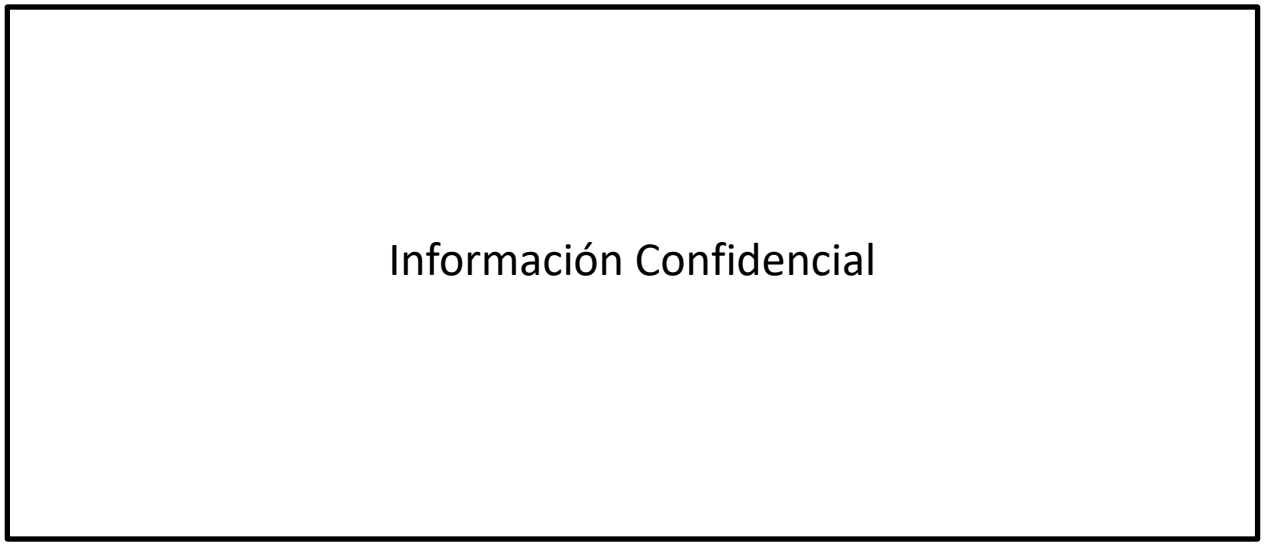
Rango	Días
Días sub	8
Días en rango	17
Días sobre	5

Fuente: Elaboración propia, 2025.

La anterior tabla de ejemplo muestra un mes cuando el 56,7 % (EPP) de los días está en rango; al respecto, 8 días está por debajo y 5 días sobre los rangos de ± 15 %.

En el siguiente gráfico de barras se observa el resultado de error de pronóstico por cada uno de los meses del periodo comprendido desde julio 2024 hasta junio 2025:

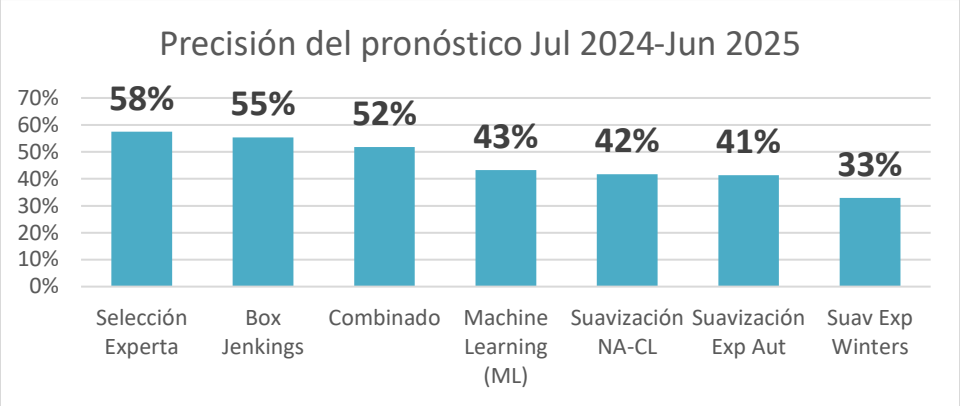
Figura 4.7: Gráfico de barras de la precisión del pronóstico diaria por mes del método actual



Fuente: Elaboración propia, 2025.

Complementando la información para la siguiente etapa, se cuantifica la precisión del pronóstico histórica de cada modelo predictivo en el periodo de estudio (julio 2024–junio 2025), los mismos son la base para la combinación de modelos en el método actual.

Figura 4.8: Gráfico de barras de la precisión del pronóstico diaria por mes del método actual



Fuente: Elaboración propia, 2025.

Tabla 4.6: Precisión del pronóstico por modelo predictivo

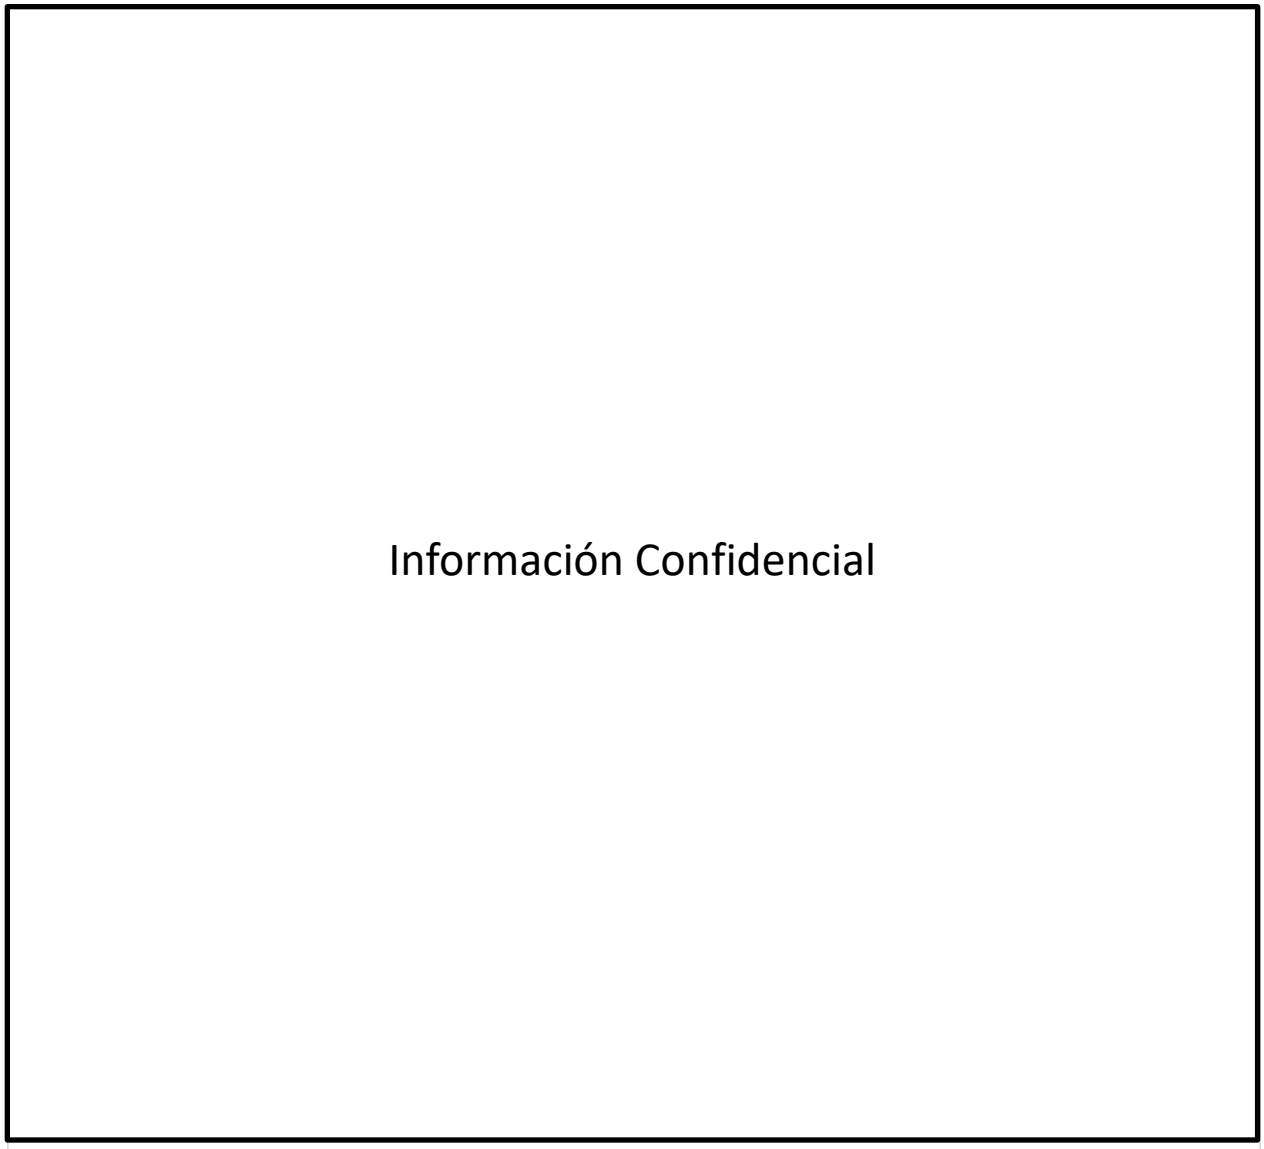
Mes	Combinado	Selección experta	*Machine learning* (ML)	Suavización exponencial auto	Suavización exponencial Winters	Suavización exponencial NA-CL	Box Jenkings
Información Confidencial							

Fuente: Elaboración propia, 2025.

Los resultados representados en verde en la figura 4.18 corresponden a los más altos en cada mes, lo que permite identificar el modelo de **selección experta** como el de mejor desempeño para el periodo evaluado, siendo el de mayor precisión en el 67 % de los meses, es decir, 8 de 12.

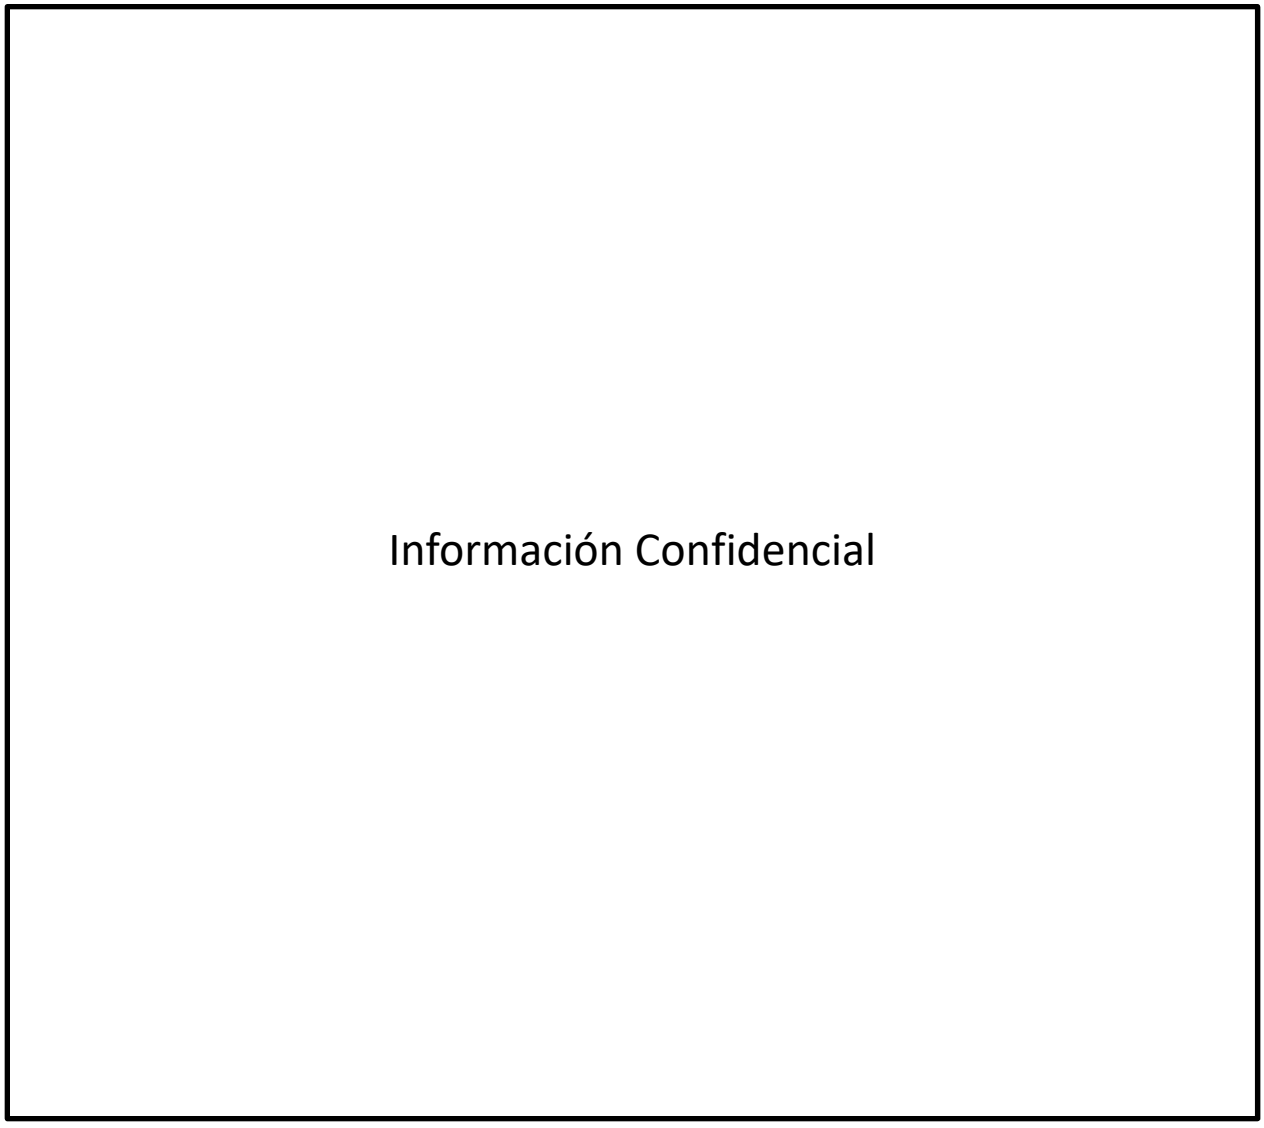
En el siguiente gráfico se muestran los resultados y se evidencia que estos modelos sin combinar obtienen un mejor resultado de precisión:

Figura 4.9: Gráfico de la precisión de los modelos predictivos del año 2024



Fuente: Elaboración propia, 2025.

Figura 4.10: Gráfico de la precisión de los modelos predictivos del año 2025



Fuente: Elaboración propia, 2025.

4.2.4 Impacto económico

Posteriormente, se mide el impacto generado por las desviaciones en el pronóstico de llamadas dentro del proceso de dimensionamiento, mediante la comparación del personal requerido calculado por el método actual y el personal real en cada uno de los meses del periodo de estudio.

El cálculo se realiza por medio del archivo de Staffing. Este consta de un archivo de Excel formulado que calcula, mediante la fórmula de la teoría de colas de Erlang C, la cantidad de agentes necesarios en intervalos, días y meses:

$$SLA = 1 - \left[P_w \cdot e^{-\left[(N-A)\cdot \frac{Umbral\ Servicio}{AHT}\right]} \right]$$

Donde

- Umbral de servicio = umbral máximo de espera para atender las llamadas (20 segundos para el Proyecto Banco).

$$P_w = \frac{\frac{A^n}{N!}\ \frac{N}{N-A}}{\left(\sum_{i=0}^{N-1} \frac{A^i}{i!}\right) + \frac{A^n}{N!}\ \frac{N}{N-A}}$$

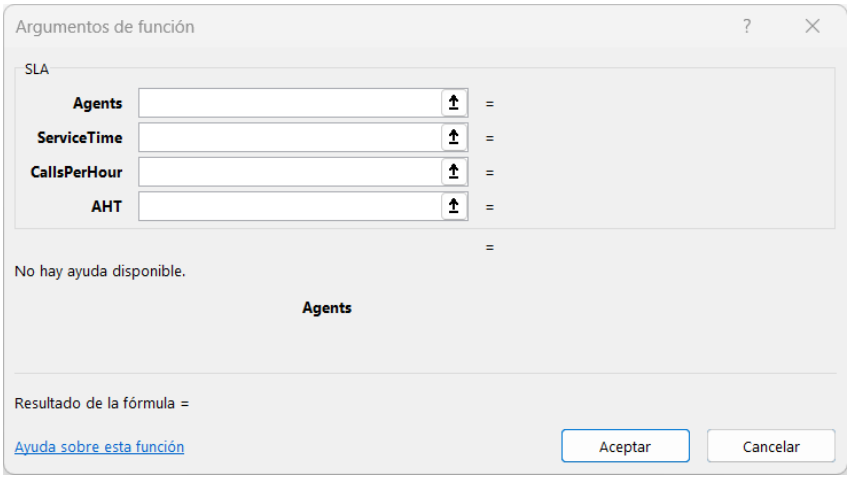
Donde:

$$A = \frac{Llamadas\ por\ Hora \cdot Min\ Promedio\ por\ llamada}{60\ Min}$$

$$N = A + 1$$

Lo anterior se representa en Excel mediante la siguiente función del complemento Erlang X97:

Figura 4.11: Función SLA en Excel



Fuente: Excel, 2025.

Para el cálculo, se coloca una cantidad de agentes iniciales con todos sus reductores (ausentismo, auxiliar y restricciones de programación), el umbral de servicio (20 segundos), las llamadas por hora y el tiempo promedio de manejo operativo (AHT); así, con estas variables, se obtiene el nivel de servicio.

El archivo de Staffing se formula de tal manera que cada uno de los intervalos del mes se calcula mediante este ejercicio y se pondera hasta un resultado mensual; en este sentido, se aumenta la cantidad de agentes hasta obtener el objetivo de un 80 % de nivel de servicio mensual.

Con la finalidad de realizar la comparación de forma estructurada y poder comprenderla mejor, se desarrolla en 2 escenarios en los que se comparan 3 resultados; estos se describen a continuación:

A. **Dimensionamiento del método actual:** este corresponde a los dimensionamientos históricos hechos con el pronóstico seleccionado por el método actual.

B. **Dimensionamiento necesario real:** este es el cálculo en el que se toman los dimensionamientos históricos y se sustituye únicamente el pronóstico de llamadas seleccionado en el método actual por las llamadas reales.

C. **Personal real:** es el personal real, en otras palabras, la lista de personal en cada uno de los meses.

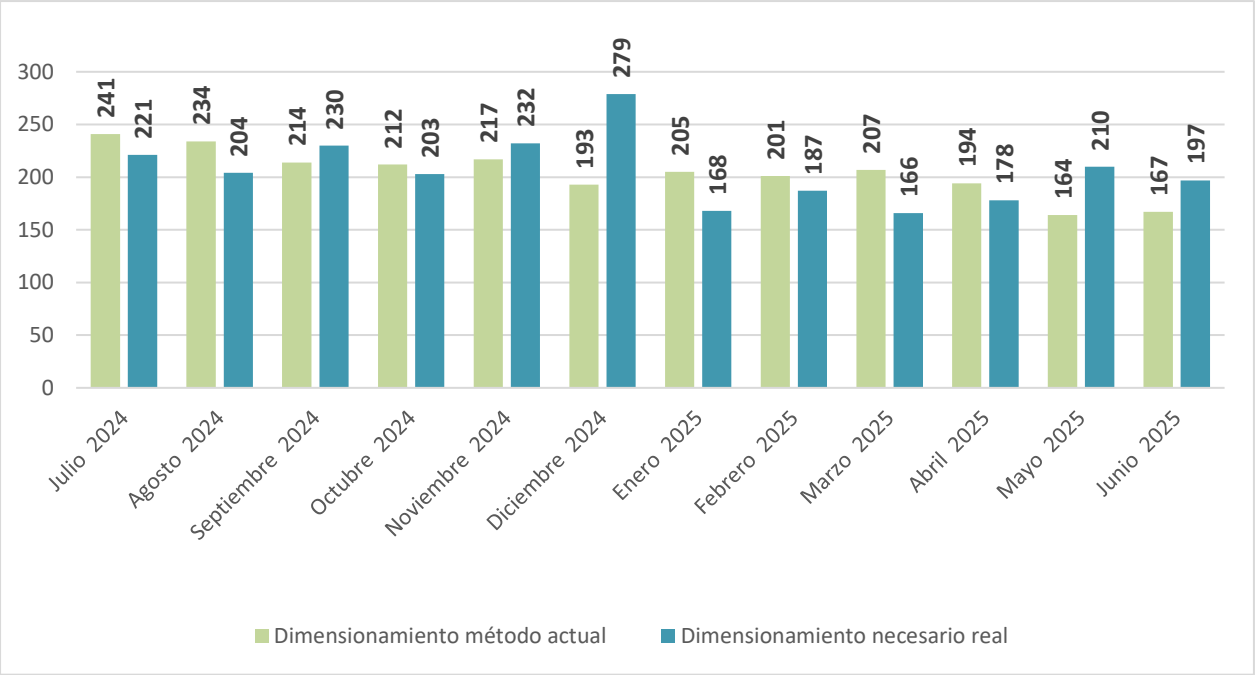
Escenario 1 (método actual): cálculo comparativo del dimensionamiento con el método actual (A) vs. el dimensionamiento necesario real (B)

En este escenario se compara la cantidad de agentes necesarios, derivada del cálculo de dimensionamiento de personal en el que la principal variable es el pronóstico de llamadas.

Para esto, se cuenta con los datos históricos calculados con el pronóstico de llamadas seleccionado en el método actual (A) y se toman los mismos datos históricos sustituyendo solo las llamadas pronosticadas por las reales (B), para mantener las otras variables que son necesarias, pero no se incluyen dentro del estudio.

Este ejercicio pretende evidenciar la diferencia entre el personal calculado con el método actual y el personal que realmente se necesita. Los resultados obtenidos se muestran en el siguiente gráfico de barras:

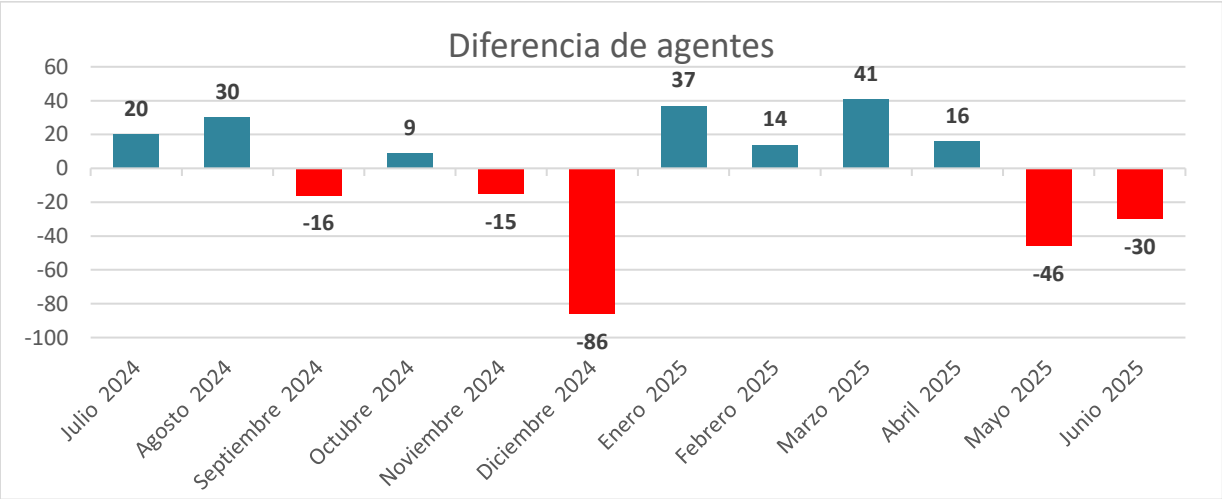
Figura 4.12: Gráfico de barras del dimensionamiento del método actual (A) vs. el dimensionamiento necesario real (B)



Fuente: Elaboración propia, 2025.

Después se discrimina la diferencia de agentes necesarios representándola en el siguiente gráfico de barras:

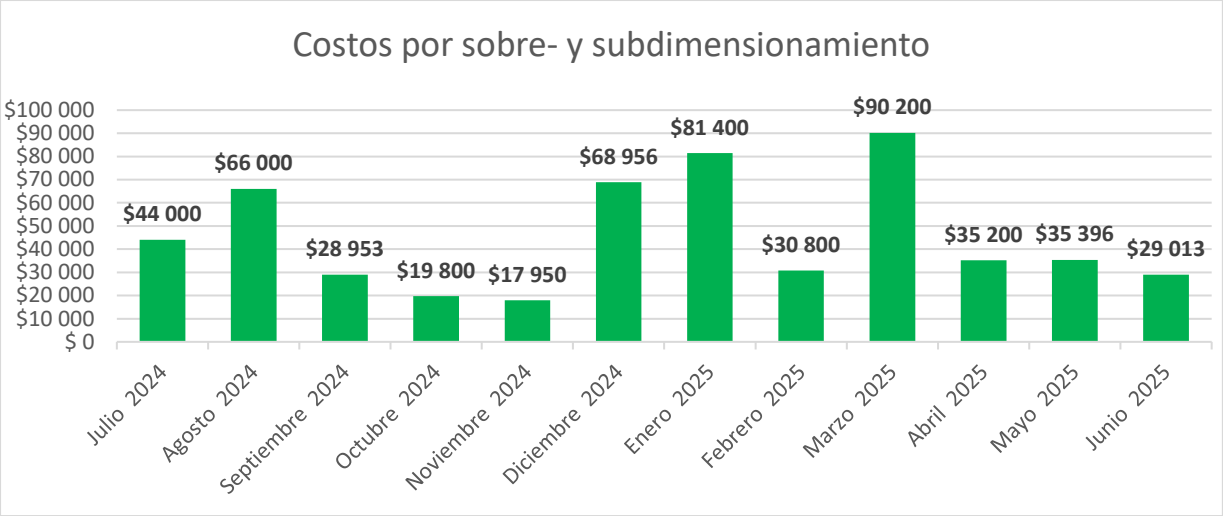
Figura 4.13: Gráfico de barras de la diferencia de agentes en el dimensionamiento del método actual (A) vs. el dimensionamiento necesario real (B)



Fuente: Elaboración propia, 2025.

Esta diferencia representa un sobrecosto para los meses de julio 2024, agosto 2024, octubre 2024, enero 2025, febrero 2025, marzo 2025, abril 2025 y una ganancia no percibida en los meses de septiembre 2024, noviembre 2024, diciembre 2024, mayo 2025 y junio 2025. Los montos por estas pérdidas se exponen en el siguiente gráfico:

Figura 4.14: Costos por sobre- y subdimensionamiento del método actual (A) vs. el dimensionamiento necesario real (B)



Fuente: Elaboración propia, 2025.

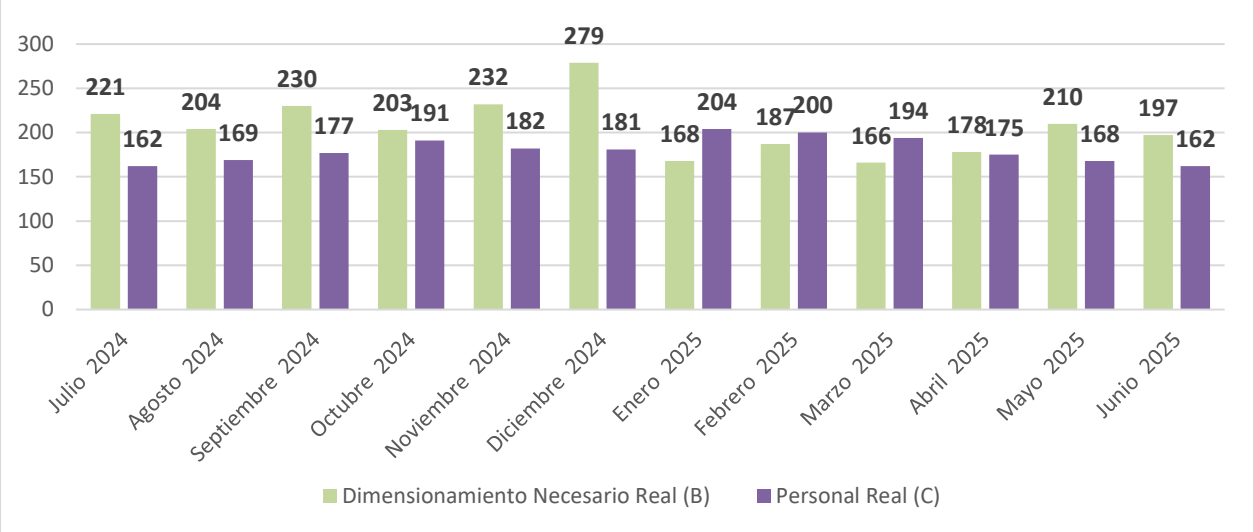
Estas pérdidas suman en total **$ 547 669** en el período que comprende desde julio 2024 hasta junio 2025, en el supuesto de que la capacidad necesaria se hubiera cumplido en su totalidad cada uno de los meses. Sin embargo, algunas variables no permiten que esto se cumpla, como los aumentos en la rotación de la capacitación o un incumplimiento en el reclutamiento del personal a cargo de Recursos Humanos.

Actualmente existe una alta presión por parte de la Gerencia General y la Gerencia de Operaciones hacia el Departamento de Recursos Humanos para que se cumpla al 100 % el requerimiento de personal calculado por el Departamento de WFM. Por este motivo, en el escenario 2 se realiza el mismo ejercicio, pero esta vez comparando el dimensionamiento necesario real (B) vs. el personal real (B) que hay por mes (lista de personal).

Escenario 2 (referencia): cálculo comparativo de la capacidad necesaria real (B) vs. el personal real por mes (C)

En el caso de este ejercicio de comparación, se toma el cálculo de la capacidad necesaria real (B) y se cruza contra el personal real (C), con la finalidad de cuantificar las pérdidas por no tener el personal necesario para atender la demanda de llamadas de una manera adecuada.

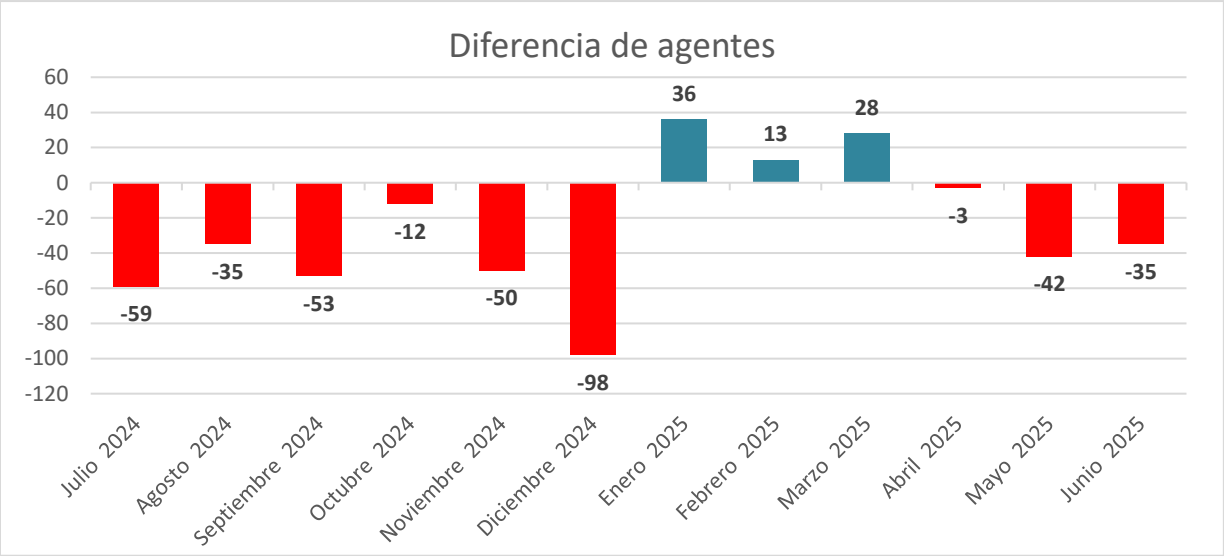
Figura 4.15: Gráfico de barras del dimensionamiento necesario real (B) vs. el personal real (C)



Fuente: Elaboración propia, 2025.

Luego se discrimina la diferencia de agentes necesarios representándola en el siguiente gráfico de barras:

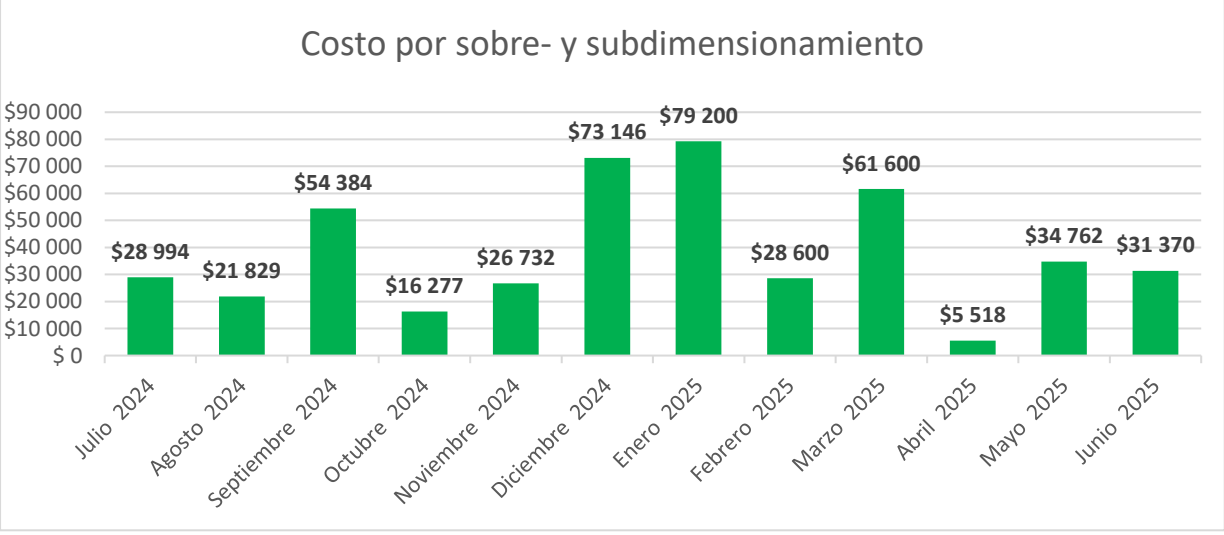
Figura 4.16: Gráfico de barras del dimensionamiento necesario real (B) vs. el personal real (C)



Fuente: Elaboración propia, 2025.

El gráfico representa una mayor pérdida por ganancia no percibida en 9 de los 12 meses y un sobrecosto para los primeros 3 meses del 2025. Los montos asociados a estas diferencias se grafican en la siguiente figura:

Figura 4.17: Gráfico de los costos por sobre- y subdimensionamiento necesario real (B) vs. personal real (C)



Fuente: Elaboración propia, 2025.

Continuando con la cuantificación de las pérdidas monetarias vinculadas al cálculo de la figura 4.17, se concluye que el costo de la sobrepoblación de agentes y la ganancia no percibida en el periodo evaluado suma **$ 462 411** en pérdidas, es decir, **$ 85 258** menos que el modelo actual en el escenario de un cumplimiento al 100 % del personal calculado bajo ese modelo. Para una mejor compresión, se consolida en la siguiente tabla:

Tabla 4.7: Comparativo de pérdidas, escenarios 1 y 2

Pérdidas por sobre- y subdimensionamiento	
Escenario 1 (método actual A)	$ 547 669
Escenario 2 (referencia B)	$ 462 411
Diferencia	**-$ 85 258**

Fuente: Elaboración propia, 2025.

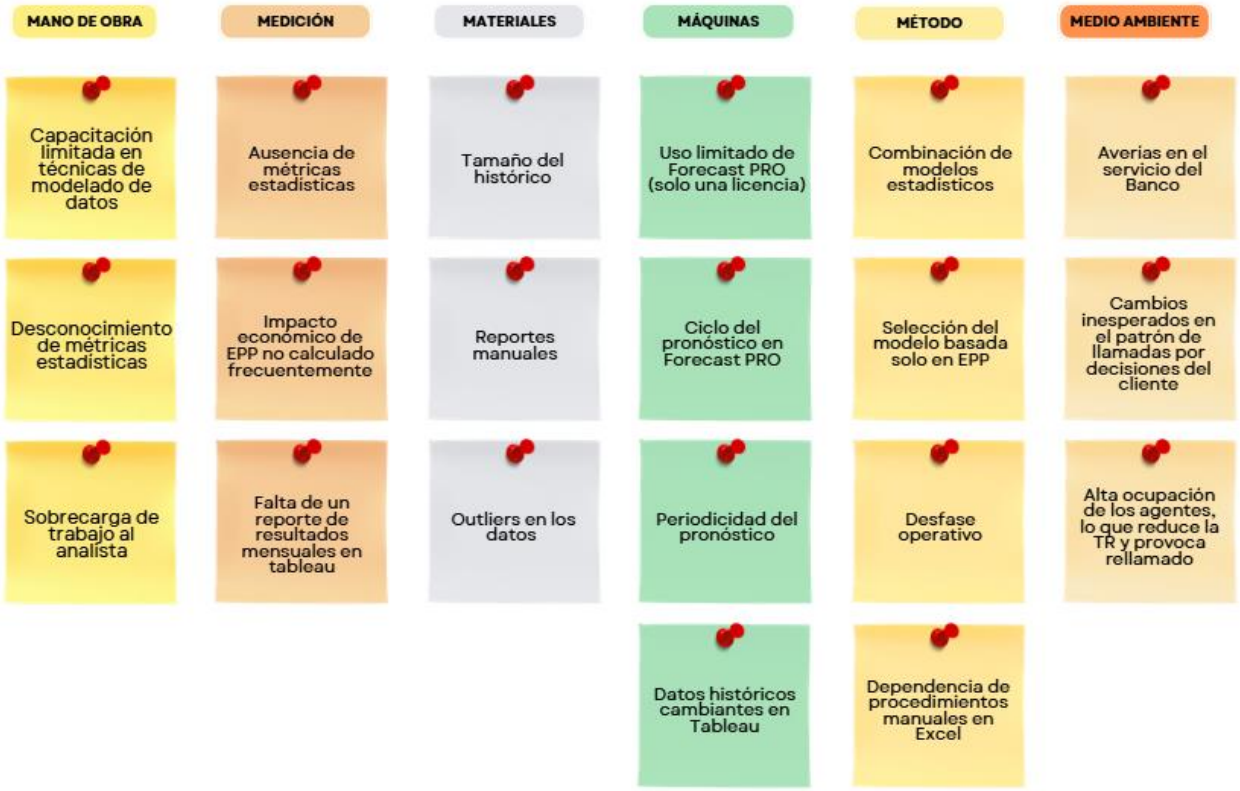
4.3 ANALIZAR

En esta etapa se realiza el análisis de las posibles causas que provocan las desviaciones en el pronóstico de llamadas y, en consecuencia, el sobre- o subdimensionamiento. Por lo tanto, se utilizan las siguientes herramientas ingenieriles que permiten recopilar, organizar, priorizar y cuantificar las más críticas.

4.3.1 Lluvia de ideas

En primer lugar, se efectúa una lluvia de ideas junto con el jefe de WFM, el supervisor, un analista y el autor de este estudio en la búsqueda de las posibles causas que desde su experiencia expliquen la afectación en la precisión del pronóstico del volumen de llamadas y el impacto que esto genera. Para la construcción de esta lluvia de ideas, se aceptan todas las opiniones y no se aplican filtros ni restricciones que pudieran sesgar las respuestas.

Figura 4.18: Lluvia de ideas



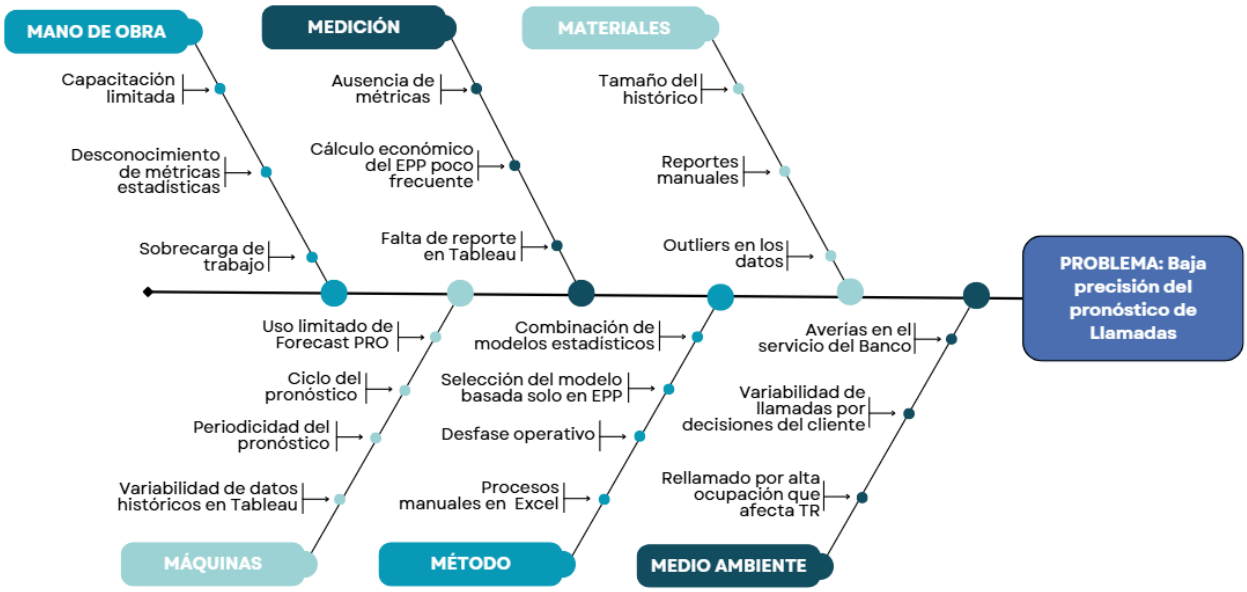
Fuente: Elaboración propia, 2025.

Posteriormente estas causas se consolidan y categorizan mediante el diagrama de Ishikawa, con la intención de visualizar de manera estructurada la relación con el problema central.

4.3.2 Diagrama de Ishikawa

El diagrama de Ishikawa se lleva a cabo utilizando el método de las 6M (mano de obra, medición, materiales, máquinas, método, medio ambiente). Al respecto, en cada una de las categorías, se agrupan las causas identificadas en la lluvia de ideas, esto permite observar los diferentes factores que contribuyen en el problema principal.

Figura 4.19: Diagrama de Ishikawa



Fuente: Elaboración propia, 2025.

Mano de obra

- **Capacitación limitada** en modelado de datos y parámetros estadísticos que posibiliten una mejor selección de modelos predictivos.
- **Desconocimiento de métricas estadísticas** que permitan evaluar los modelos predictivos de una manera objetiva.
- **Sobrecarga de trabajo** a los analistas, debido a los múltiples proyectos que manejan algunos.

Medición

- **Ausencia de métricas** estadísticas en el PBF que posibiliten evaluar cada modelo y funcionen como referencia para la selección del modelo predictivo.
- **Cálculo económico del EPP poco frecuente**; en cuanto a esto, la estimación del impacto se realiza de manera casual y no es una práctica frecuente, lo que dificulta dimensionar la magnitud de la afectación por EPP.
- **Falta de reporte en Tableau**, con datos mensuales consolidados que faciliten analizar y conocer el impacto en la operación por el EPP.

Materiales

- **Tamaño del histórico** utilizado en Forecast PRO; al respecto, no hay parámetros que lo definan, solo el mínimo de 6 meses estipulado por la norma GMD que audita COPC.
- **Reportes manuales** que aumentan la probabilidad de error humano, como la construcción del histórico y el proceso en el PBF actual.
- ***Outliers* en los datos** históricos que pueden aumentar el EPP.

Máquinas

- **Uso limitado de Forecast PRO** porque solo se dispone de una licencia en una máquina virtual, la cual la comparten los analistas, incluso en un mismo día de trabajo por los requerimientos de los proyectos.
- **Ciclo del pronóstico** en Forecast PRO que actualmente es de 7; es decir, la referencia para los modelos predictivos es por día de la semana.
- **Periodicidad del pronóstico** actualmente establecida en rangos mensuales de corto y largo plazo, esto imposibilita reaccionar a eventuales cambios en el comportamiento de las llamadas.
- **Variabilidad de datos históricos en Tableau**; en relación con esto, los datos históricos en Tableau en ocasiones cambian por reprocesamientos a cargo del Departamento de BI (Business Intelligence).

Método

- **Combinación de modelos estadísticos**, lo que provoca ausencia de tendencia y estacionalidad en los modelos predictivos, además de no conocer cuál modelo se adapta mejor a los datos.
- **Selección del modelo basada solo en EPP**, pues no se consideran otras métricas como estacionalidad, tendencia, promedio de errores, entre otros.
- **Desfase operativo** muy extenso, situación que no permite identificar tendencias o cambios significativos para el mes por pronosticar.
- **Procesos manuales en Excel**, lo cual aumenta la probabilidad de errores y dificulta la trazabilidad.

Medio ambiente

- **Averías en el servicio de Banco**, como fallas de la aplicación, página web, servicios esenciales como transferencias o caídas de sistemas internos.
- **Variabilidad de llamadas por decisiones del cliente**, como cambios en el token autenticador o en la aplicación que no se pueden medir por ser eventos únicos o no disponer del histórico.
- **Rellamado por alta ocupación que afecta la TR**, al provocar una pérdida de productividad y, en consecuencia, una nueva llamada por parte de un cliente que abandona la cola de espera al superar su umbral de paciencia.

Mediante el análisis anterior se obtiene un mapa completo de las causas; sin embargo, debido la cantidad de estas, se emplea el siguiente multivoto para determinar cuál tiene un mayor impacto en el problema.

4.3.3 Multivoto

Dada la cantidad de causas encontradas y consolidadas en las fases anteriores, se omiten de esta herramienta aquellas que no se pueden cambiar y las que la jefatura de WFM considera no viables por temas de costos agregados, licencias, permisos, presupuesto, entre otros.

Ahora bien, para el ejercicio del multivoto, primero se otorga a cada uno de los 4 participantes (el jefe de WFM, el supervisor, un analista y el autor) 100 puntos por distribuir entre las 10 causas restantes. Posteriormente, se contabilizan para obtener el puntaje total de cada una, con la finalidad de cuantificar su impacto en el proceso.

Tabla 4.8: Multivoto de las causas derivadas del diagrama de Ishikawa

Subcausas	P1	P2	P3	P4	Total
Total de puntos	**100**	**100**	**100**	**100**	**400**
Capacitación limitada	5	1	5	5	**16**
Desconocimiento de métricas estadísticas	5	1	5	2	**13**
Ausencia de métricas	30	1	15	50	**96**
Cálculo económico del EPP poco frecuente	1	1	5	4	**11**
Falta de reporte en Tableau	1	1	1	4	**7**
Ciclo del pronóstico	1	1	1	5	**8**
Periodicidad del pronóstico	1	1	3	5	**10**
Combinación de modelos estadísticos	30	70	20	10	**130**
Selección del modelo basada en EPP	25	20	40	10	**95**
Procesos manuales en Excel	1	3	5	5	**14**

Fuente: Elaboración propia, 2025.

Tabla 4.9: Multivoto ordenado

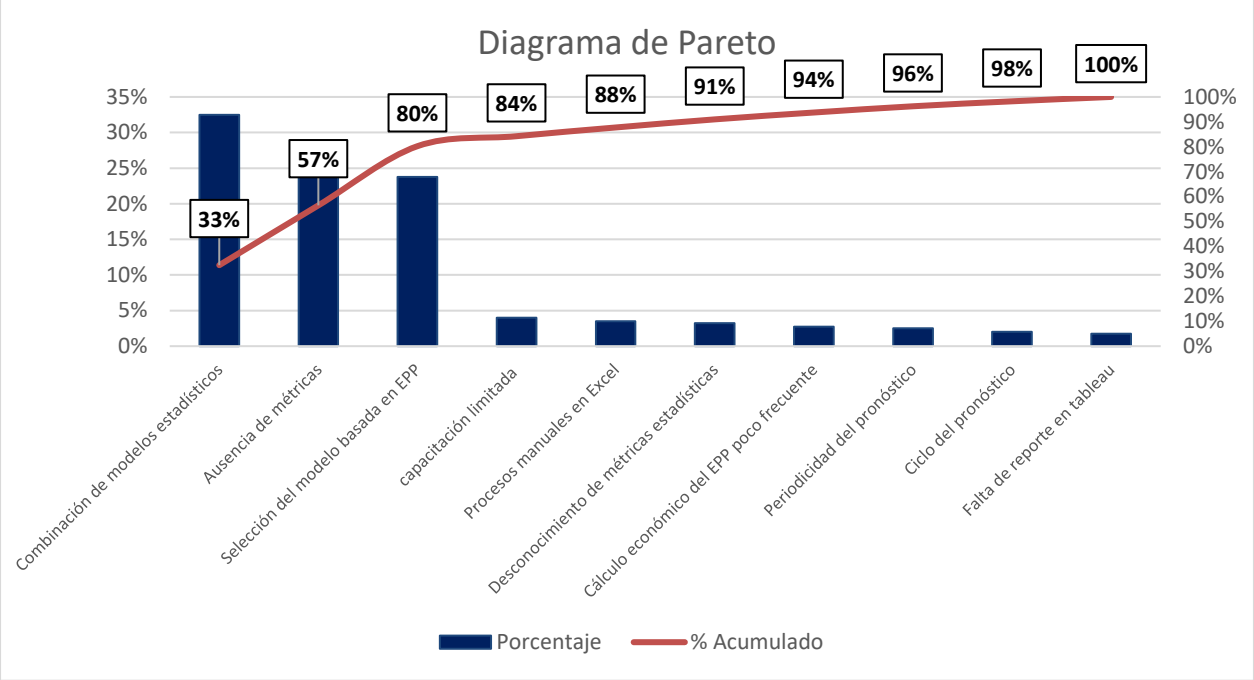
Subcausas	P1	P2	P3	P4	Total	Porcentaje	Porcentaje acumulado
Combinación de modelos estadísticos	**30**	**70**	**20**	**10**	**130**	**33 %**	**33 %**
Ausencia de métricas	**30**	**1**	**15**	**50**	**96**	**24 %**	**57 %**
Selección del modelo basada en EPP	**25**	**20**	**40**	**10**	**95**	**24 %**	**80 %**
Capacitación limitada	5	1	5	5	16	4 %	84 %
Procesos manuales en Excel	1	3	5	5	14	4 %	88 %
Desconocimiento de métricas estadísticas	5	1	5	2	13	3 %	91 %
Cálculo económico del EPP poco frecuente	1	1	5	4	11	3 %	94 %
Periodicidad del pronóstico	1	1	3	5	10	3 %	96 %
Ciclo del pronóstico	1	1	1	5	8	2 %	98 %
Falta de reporte en Tableau	1	1	1	4	7	2 %	100 %

Fuente: Elaboración propia, 2025.

Los resultados del multivoto se analizan y ordenan en el siguiente diagrama de Pareto, con el objetivo de identificar el 20 % de las causas que generan el 80 % de los problemas.

4.3.4 Diagrama de Pareto

Figura 4.20: Diagrama de Pareto



Fuente: Elaboración propia, 2025.

En cuanto a los resultados de la aplicación del Pareto, estos indican que las causas “combinación de modelos estadísticos”, “ausencia de métricas estadísticas” y “selección del modelo basada solo en EPP” son atribuibles a la mayoría de los problemas generados.

4.3.5 5 porqués

Por último, se efectúa un análisis de las causas encontradas anteriormente con la aplicación de la herramienta de los 5 porqués, la cual permite profundizar en cada una de estas de una manera estructurada en busca de la causa raíz de cada problema. Este análisis se realiza a partir de las causas derivadas del diagrama Ishikawa y priorizadas mediante la regla de Pareto.

Causas del Pareto	1° porqué	2° porqué	3° porqué	4° porqué	5° porqué	Causa raíz
Combinación de modelos estadísticos	**¿Por qué se combinan los modelos estadísticos?** Porque la jefatura anterior así lo definió para el proceso de selección de modelos de pronóstico.	**¿Por qué la jefatura lo definió así?** Porque buscaba cambiar el proceso actual.	**¿Por qué buscaba cambiar el proceso actual?** Porque quería mejorar la precisión del pronóstico.	**¿Por qué quería mejorar la precisión del pronóstico?** Porque la precisión del pronóstico está directamente ligada al sobre- y sub dimensionamiento.	**¿Por qué la precisión del pronóstico es responsable del sobre- y sub dimensionamiento?** Porque es una de las principales métricas dentro del cálculo del dimensionamiento.	Combinaciones de modelos por selección arbitraria de la jefatura sin justificación técnica, lo que afecta el error de precisión del pronóstico.
Ausencia de métricas	**¿Por qué hay ausencia de métricas?** Porque actualmente el PBF carece de un conjunto de indicadores, solo evalúa el EPP.	**¿Por qué el PBF carece de métricas?** Porque el PBF no se realizó con un proceso metodológico.	**¿Por qué no se realizó con un proceso metodológico?** Porque el PBF actual se hizo de manera empírica y operativa, sin un análisis estadístico previo que orientara su diseño.	**¿Por qué se desarrolló de forma empírica?** Porque no existía documentación técnica ni de referencia para la selección de modelos.	**¿Por qué no existía documentación técnica?** Porque el proceso se enfocó en cumplir la necesidad operativa inmediata, sin pensar en la estandarización o definición de parámetros estadísticos para evaluar los modelos.	Ausencia de un modelo documentado y probado que establezca métricas estadísticas para evaluar el desempeño de los modelos predictivos.
Selección basada en EPP	**¿Por qué la selección se basa únicamente en EPP?** Porque el EPP es el único parámetro utilizado actualmente para medir el desempeño de los modelos de pronóstico.	**¿Por qué solo se utiliza el EPP?** Porque no se tienen definidos otros parámetros que complementen la evaluación del desempeño de los modelos de pronóstico.	**¿Por qué no se definieron parámetros adicionales?** Porque el proceso no tiene un respaldo técnico que guíe la selección de parámetros adicionales.	**¿Por qué no existe esa guía técnica?** Porque el método se realizó bajo criterios operativos.	**¿Por qué el método se basó en criterios operativos?** Porque no se contaba con herramientas, capacitación o referencias de parámetros que ayudaran a medir el desempeño de los modelos predictivos.	Falta de criterios técnicos para establecer parámetros complementarios para la selección del modelo.

A partir del análisis previamente desarrollado, se establecen las causas que tienen mayor impacto en el problema del error de precisión del pronóstico. Esto mediante la generación de las opiniones en la lluvia de ideas, la consolidación y estructuración en el diagrama de Ishikawa, la priorización por medio de la multivotación en conjunto con el Pareto y, por último, el análisis de los 5 porqués.

En conclusión, a lo largo de este capítulo se evidencia que la empresa cuenta con el histórico en las bases de datos de Tableau para poder efectuar ejercicios retroactivos de medición de resultados.

Adicional, se determina el peso del pronóstico de llamadas en el proceso de dimensionamiento de personal y lo que su desviación provoca en el ámbito financiero, siendo así para el periodo de estudio una pérdida de $ 462 411.

También se evidencia que la combinación de modelos predictivos por día y la selección del modelo basado solo en la precisión del pronóstico constituyen las causas más críticas que provocan la mayor parte del efecto.

Además, se establece que un modelo completo tiene un mejor desempeño que la combinación de estos, por ejemplo, para el periodo de estudio, se emplea el modelo de selección experta, este mejora la precisión en 8 de los 12 meses analizados.

Estos resultados proporcionan una base para la siguiente fase de mejora, en la cual se proponen las alternativas de solución al modelo actual de selección, enfocadas en corregir estas causas y, con esto, mejorar la precisión del pronóstico.

CAPÍTULO V. PROPUESTA

5.1 MEJORAR

En respuesta al resultado del capítulo anterior, en el que por medio del diagrama de Pareto se identifican las causas de mayor impacto, se crea un método de selección con el que se atiende cada una de ellas de la siguiente manera:

Respecto a la causa “combinación de modelos estadísticos”, en este nuevo método se implementa un proceso de entrenamiento que mide el desempeño de cada modelo predictivo por separado y permite la selección de solo un modelo predictivo completo, como se muestra en la figura 5.12.

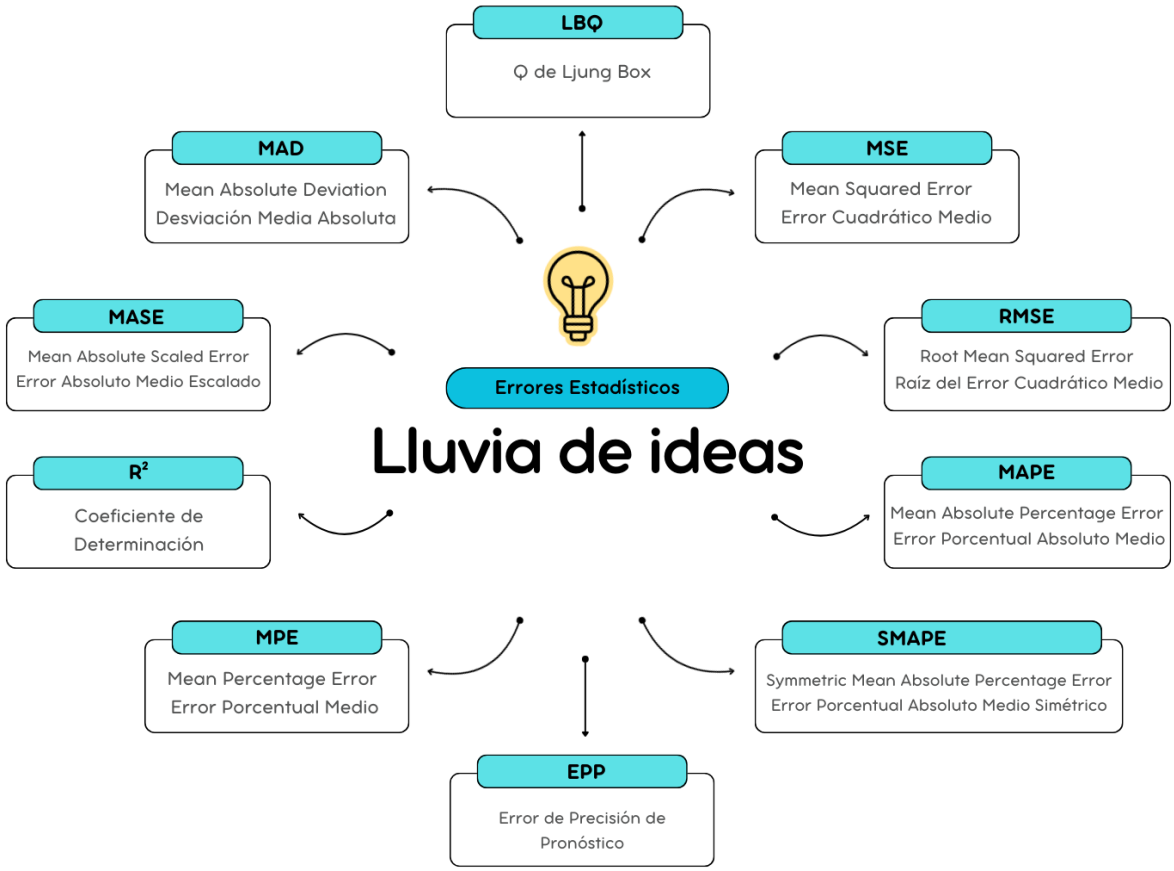
En cuanto a la causa “ausencia de métricas”, se incluyen parámetros estadísticos que establecen el desempeño de cada uno de los modelos y posibilitan la comparación de resultados, como se aprecia en la figura 5.8.

Referente a la causa “selección del modelo basada en EPP”, mediante el cálculo del tercer escenario incluido en este capítulo, se evidencia que el modelo de selección experta es el que mejor se adhiere a los datos y predice la demanda. Adicional, en el nuevo modelo se integra una ponderación de los resultados de los parámetros estadísticos para reconocer a los mejores en el periodo de entrenamiento, como se observa en la tabla 5.9.

Finalmente, el nuevo modelo incluye el histórico con los datos reales de los meses pasados (figura 5.11), la opción de ajuste del pronóstico por día y los parámetros de referencia como los límites del rango de la precisión (figura 5.12); además, muestra las predicciones de los demás modelos (figura 5.10), con el propósito de ofrecer la mayor cantidad de información para el analista en el proceso de selección.

5.1.1 Lluvia de ideas

Figura 5.1: Lluvia de ideas



Fuente: Elaboración propia, 2025.

Con el fin de identificar los parámetros estadísticos que se pueden agregar al método de selección de modelos de pronóstico, se realiza una lluvia de ideas en la cual participan el coordinador de WFM, el supervisor de WFM y un analista y, a partir de esta, se recopilan las métricas más apropiadas para evaluar los modelos de pronóstico. Esto posibilita generar la tabla 5.1 con los parámetros estadísticos que luego se evalúan para seleccionar los que más se adaptan a las necesidades del proceso. Las métricas propuestas en esta lluvia son:

- LBQ: Q de Ljung Box.

- MSE: error cuadrático medio (*mean square error*).
- RMSE: raíz del error cuadrático medio (*root mean square error*).
- MAPE: error porcentual absoluto medio (*mean absolute percentage error*).
- SMAPE: error porcentual absoluto medio simétrico (*symmetric mean absolute percentage error*).
- EPP: error de precisión del pronóstico.
- MPE: error porcentual medio (*mean percentage error*).
- R^2, coeficiente de determinación.
- MASE: error absoluto medio escalado (*mean absolute scaled error*).
- MAD: desviación media absoluta (*mean absolute deviation*).

5.1.2 Tabla descriptiva de errores estadísticos

Posterior a la lluvia de ideas, se elabora la siguiente tabla comparativa que resume cada error estadístico, como referencia que facilita la compresión de cada indicador y su relevancia dentro del proceso.

Tabla 5.1: Descripción de los parámetros estadísticos

Métrica	Fórmula	Cálculo	Qué mide	Métrica objetivo
LBQ	$Q = T(T+2) \cdot \sum_{i=1}^{L} \frac{{r_i}^2}{T-i}$	Prueba estadística	Si hay patrones en los errores que el modelo no capturó	P – valor alto > 0.05
MSE	$MSE = \frac{1}{n}\sum \left(Y_t - \hat{Y}_t\right)^2$	Promedio de los errores elevados al cuadrado	La magnitud del error al elevarlos al cuadrado	Lo más cercano a 0
RMSE	$RMSE = \sqrt{\frac{1}{n}\sum \left(Y_t - \hat{Y}_t\right)^2}$	Raíz cuadrada del promedio de los errores elevados al cuadrado	La magnitud del error en las mismas unidades del pronóstico	Lo más cercano a 0
MAPE	$MAPE = \frac{1}{n}\sum \left\lvert \frac{Y_t - \hat{Y}_t}{Y_t} \right\rvert$	Promedio de los errores absolutos	El error absoluto en porcentaje	Lo más cercano a 0 %

		representados en porcentaje		
SMAPE	$SMAPE = \frac{1}{n}\sum \left\| \frac{\lvert Y_t - \hat{Y}_t \rvert}{\frac{(Y_t + \hat{Y}_t)}{2}} \right\|$	División del promedio de los valores reales entre los pronosticados	El error absoluto en porcentaje, reduciendo el sesgo en los valores cercanos a 0	Lo más cercano a 0 %
EPP	$EPP = \frac{\hat{Y}}{Y}\, x\, 100\%$	División de los valores pronosticados entre los datos reales	La diferencia entre el pronóstico y el valor real	Lo más cercano a 100 %
MPE	$MPE = \frac{1}{n}\sum \left(\frac{Y - \hat{Y}}{Y}\right) 100\%$	Promedio de los errores porcentuales	Si el modelo tiende a sobre- o subestimar	Lo más cercano a 0 %
R2	$R^2 = 1 - \frac{\sum (Y_t - \hat{Y}_t)^2}{\sum (Y_t - \bar{Y})^2}$	División de la variación no explicada entre la variación total de los datos	Que tan predecible es la variable que se está pronosticando	Lo más cercano a 1
MASE	$MASE = \left(\frac{\frac{1}{n}\sum_{t=1}^{n} \lvert Y_t - \hat{Y}_{t-1} \rvert}{\frac{1}{n-1}\sum_{t=2}^{n} \lvert Y_t - \hat{Y}_{t-1} \rvert} \right)$	División del MAD del pronóstico entre el MAD del último valor	Compara el modelo utilizado contra el último valor	Menor que 1
MAD	$MAD = \frac{1}{n}\sum \lvert Y_t - \bar{Y}_t \rvert$	Promedio de los errores absolutos entre el pronóstico y los valores reales	El promedio de los errores	Lo más cercano a 0

Fuente: Elaboración Propia (2025)

5.1.3 Matriz de decisión

Con base en la información obtenida, se realiza la matriz de decisión, en esta se definen los criterios como: la posibilidad de efectuar el cálculo en las herramientas disponibles, la facilidad de interpretación por parte de los involucrados, la sensibilidad de las métricas a errores grandes, la métrica objetivo, la facilidad de interpretarla y la funcionalidad para el proceso.

Tabla 5.2: Criterios y peso para la matriz de decisión

Peso	Criterios
5	Disponibilidad
4	Funcionabilidad
3	Facilidad de interpretación
2	Sensibilidad a errores grandes
1	Métrica objetivo

Fuente: Elaboración propia, 2025.

Luego de establecer los criterios y su peso dentro de la decisión, se crea la matriz colocando en el eje Y las métricas y en el eje X los criterios. Se puntúan del 1 al 5, siendo este último el peso mayor.

Tabla 5.3: Puntaje de la matriz de decisión

Métricas	Disponibilidad	Funcionabilidad	Facilidad de interpretación	Sensibilidad a errores grandes	Métrica objetivo
Peso	**5**	**4**	**3**	**2**	**1**
LBQ	2	1	2	4	1
MSE	5	1	3	5	5
RMSE	5	5	4	5	5
MAPE	5	5	5	4	5
SMAPE	4	3	3	3	5
EPP	5	5	5	3	5
MPE	5	4	4	2	5
R^2	5	5	5	2	5
MASE	5	2	4	2	5
MAD	5	5	5	2	5

Fuente: Elaboración propia, 2025.

Por último, se ponderan los pesos, multiplicando el peso de cada criterio por la puntación obtenida en la votación.

Tabla 5.4: Puntaje ponderado de la matriz de decisión

Métricas	Disponibilidad	Funcionabilidad	Facilidad de interpretación	Sensibilidad a errores grandes	Métrica objetivo	Total
Peso	**5**	**4**	**3**	**2**	**1**	**--**
MAPE	25	20	15	8	5	**73**
RMSE	25	20	12	10	5	**72**
EPP	25	20	15	6	5	**71**
R2	25	20	15	4	5	**69**
MAD	25	20	15	4	5	**69**
MPE	25	16	12	4	5	**62**
MASE	25	8	12	4	5	**54**
MSE	25	4	9	10	5	**53**
SMAPE	20	12	9	6	5	**52**
LBQ	10	4	6	8	1	**29**

Fuente: Elaboración propia, 2025.

Después de realizar la matriz y analizar los resultados, se decide utilizar las 5 métricas con el mayor puntaje obtenido para integrarlas en el nuevo método de selección del modelo predictivo de llamadas, a saber, MAPE, RMSE, EPP, R^2 y MAD.

5.1.4 Nuevo método de selección (PBF 2.0)

En cuanto al nuevo método de selección de modelos predictivos, se crea un nuevo archivo de Excel (PBF 2.0) basado en las causas identificadas en el capítulo 4 y los parámetros estadísticos de este capítulo. Este archivo debe ser operado por el analista encargado del proyecto y consta de 5 hojas de cálculo, las mismas son:

- Entrenamiento.
- Selección del modelo.
- Histórico.
- BD Forecast PRO.
- Vínculos.

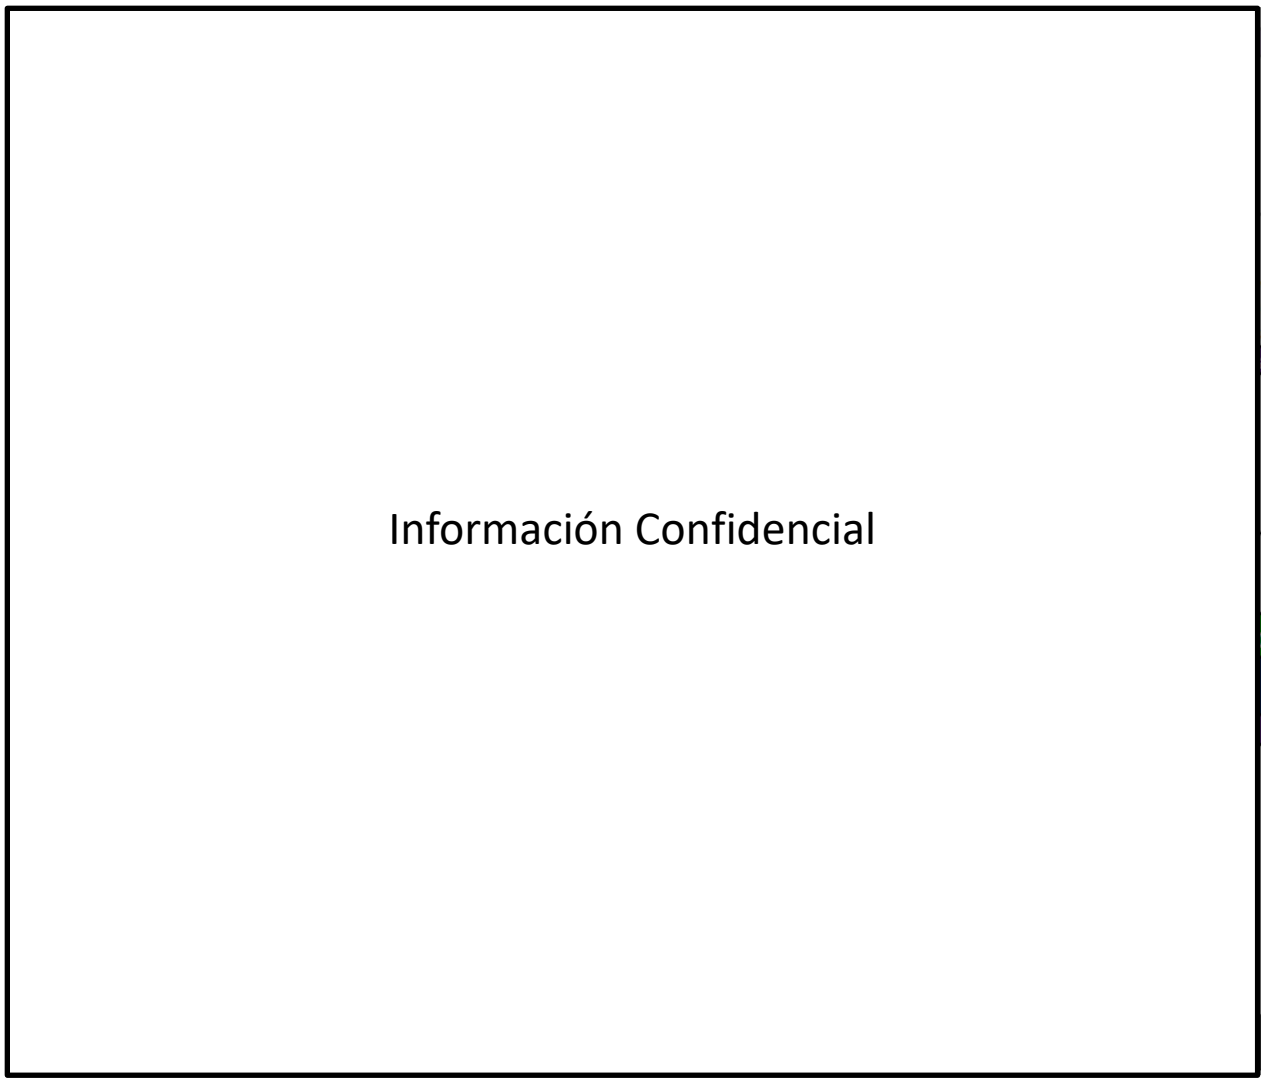
Cada una de estas hojas cumple un papel esencial para el funcionamiento de todo el modelo. Dentro de estas, se encuentran las bases de datos y cálculos base para el

funcionamiento de las hojas primarias. En las siguientes secciones, se detallan estas hojas.

Entrenamiento

Esta hoja es una de las principales, en la cual se efectúan los cálculos de los parámetros estadísticos y, mediante estos, la evaluación de la fase de entrenamiento. Primero, se define el mes por pronosticar (las celdas por considerar se encuentran en amarillo):

Figura 5.2: Ejemplo de selección de la fecha en la Hoja de Entrenamiento en el PBF 2.0

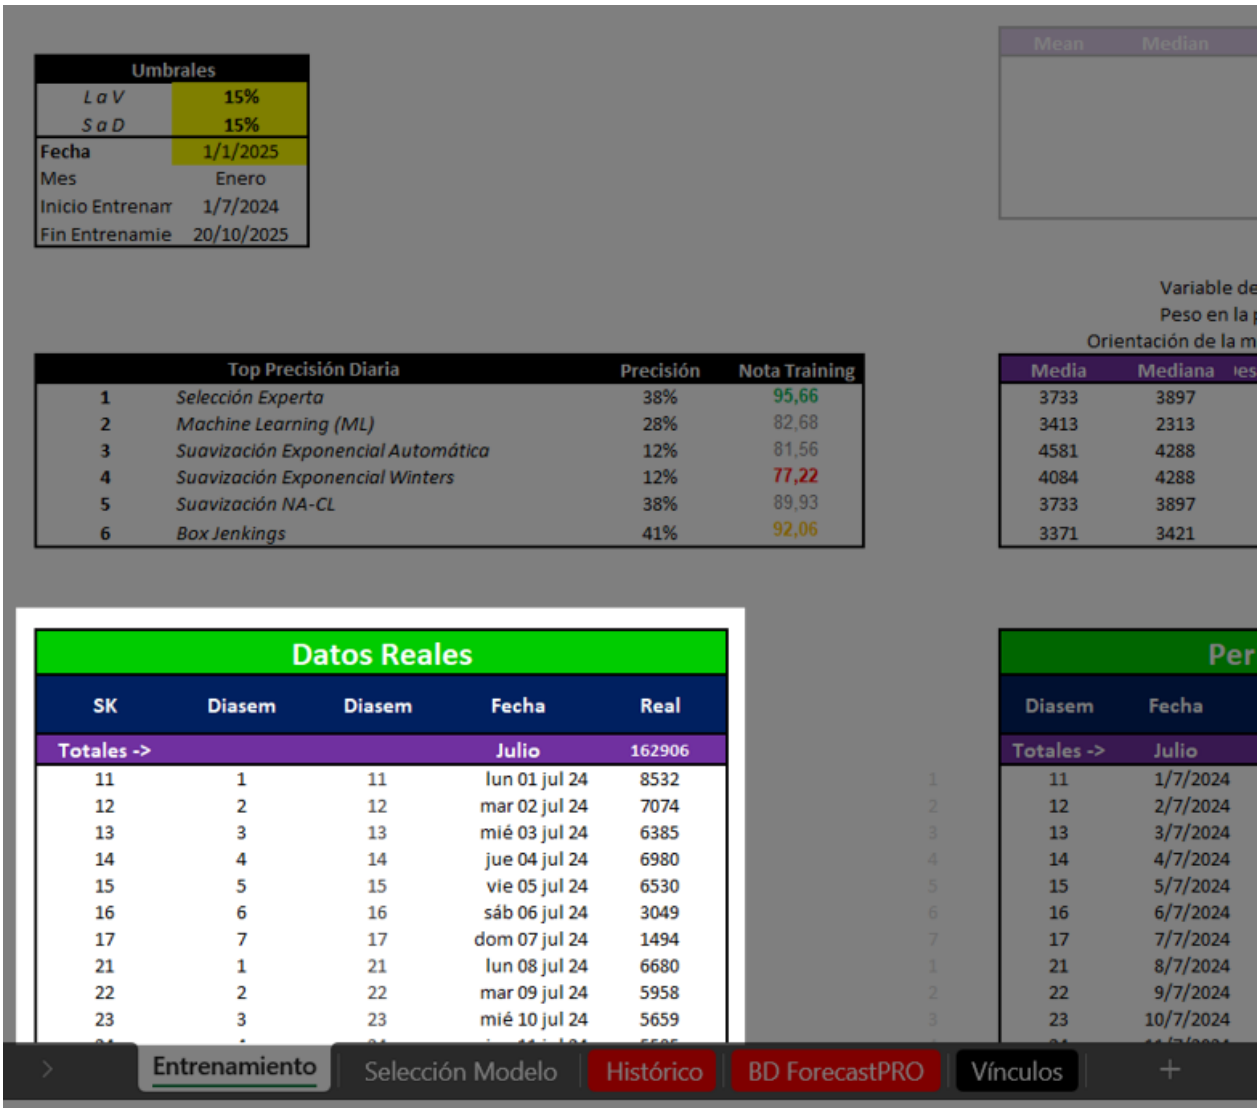


Fuente: Elaboración propia, 2025.

Una vez colocada la fecha del mes por pronosticar, toda la hoja se formula para calcular los parámetros estadísticos en las siguientes tablas que se muestran a continuación:

Datos reales: histórico de datos reales del volumen de llamadas entrantes.

Figura 5.3: Ejemplo de una tabla de datos reales en la Hoja de Entrenamiento en el PBF 2.0



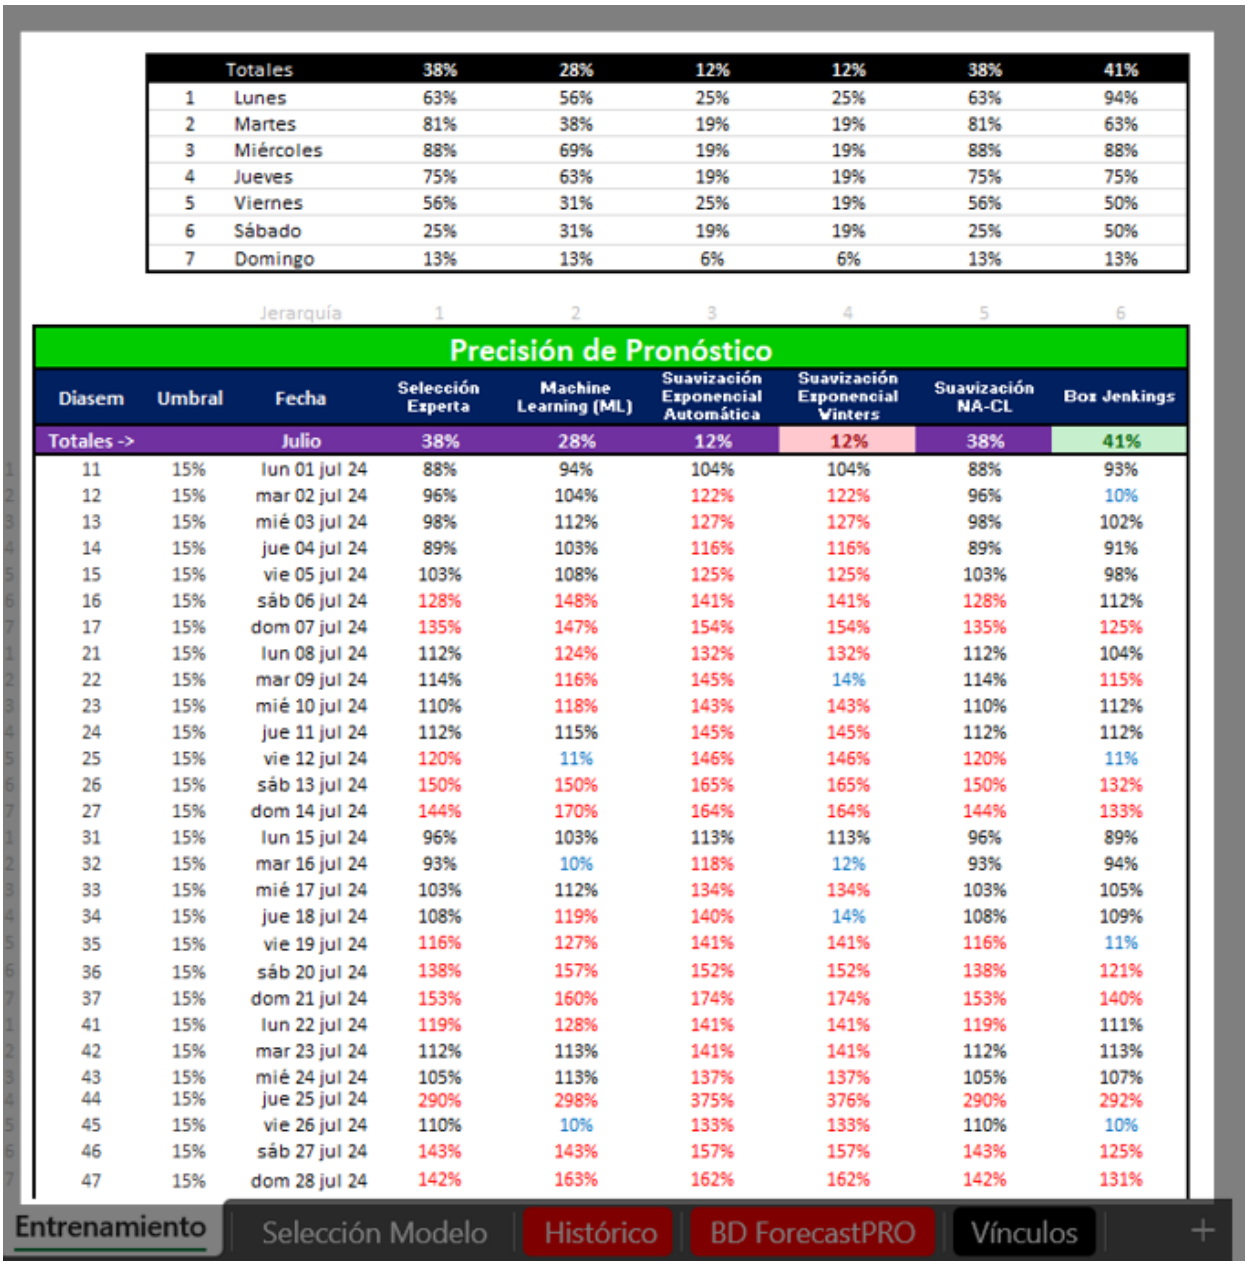
Fuente: Elaboración propia, 2025.

Precisión del pronóstico: cálculo de la precisión del pronóstico por cada uno de los modelos predictivos, de acuerdo con la siguiente fórmula descrita en la tabla 5.1:

$$EPP = \frac{\hat{Y}}{Y} x\ 100\%$$

Donde: Y = datos reales, Ŷ = pronóstico.

Figura 5.4: Ejemplo de la tabla de precisión del pronóstico en la Hoja de Entrenamiento en el PBF 2.0



	Totales	38%	28%	12%	12%	38%	41%
1	Lunes	63%	56%	25%	25%	63%	94%
2	Martes	81%	38%	19%	19%	81%	63%
3	Miércoles	88%	69%	19%	19%	88%	88%
4	Jueves	75%	63%	19%	19%	75%	75%
5	Viernes	56%	31%	25%	19%	56%	50%
6	Sábado	25%	31%	19%	19%	25%	50%
7	Domingo	13%	13%	6%	6%	13%	13%

Jerarquía 1 2 3 4 5 6

Precisión de Pronóstico

	Diasem	Umbral	Fecha	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
	Totales ->		Julio	38%	28%	12%	12%	38%	41%
1	11	15%	lun 01 jul 24	88%	94%	104%	104%	88%	93%
2	12	15%	mar 02 jul 24	96%	104%	122%	122%	96%	10%
3	13	15%	mié 03 jul 24	98%	112%	127%	127%	98%	102%
4	14	15%	jue 04 jul 24	89%	103%	116%	116%	89%	91%
5	15	15%	vie 05 jul 24	103%	108%	125%	125%	103%	98%
6	16	15%	sáb 06 jul 24	128%	148%	141%	141%	128%	112%
7	17	15%	dom 07 jul 24	135%	147%	154%	154%	135%	125%
1	21	15%	lun 08 jul 24	112%	124%	132%	132%	112%	104%
2	22	15%	mar 09 jul 24	114%	116%	145%	14%	114%	115%
3	23	15%	mié 10 jul 24	110%	118%	143%	143%	110%	112%
4	24	15%	jue 11 jul 24	112%	115%	145%	145%	112%	112%
5	25	15%	vie 12 jul 24	120%	11%	146%	146%	120%	11%
6	26	15%	sáb 13 jul 24	150%	150%	165%	165%	150%	132%
7	27	15%	dom 14 jul 24	144%	170%	164%	164%	144%	133%
1	31	15%	lun 15 jul 24	96%	103%	113%	113%	96%	89%
2	32	15%	mar 16 jul 24	93%	10%	118%	12%	93%	94%
3	33	15%	mié 17 jul 24	103%	112%	134%	134%	103%	105%
4	34	15%	jue 18 jul 24	108%	119%	140%	14%	108%	109%
5	35	15%	vie 19 jul 24	116%	127%	141%	141%	116%	11%
6	36	15%	sáb 20 jul 24	138%	157%	152%	152%	138%	121%
7	37	15%	dom 21 jul 24	153%	160%	174%	174%	153%	140%
1	41	15%	lun 22 jul 24	119%	128%	141%	141%	119%	111%
2	42	15%	mar 23 jul 24	112%	113%	141%	141%	112%	113%
3	43	15%	mié 24 jul 24	105%	113%	137%	137%	105%	107%
4	44	15%	jue 25 jul 24	290%	298%	375%	376%	290%	292%
5	45	15%	vie 26 jul 24	110%	10%	133%	133%	110%	10%
6	46	15%	sáb 27 jul 24	143%	143%	157%	157%	143%	125%
7	47	15%	dom 28 jul 24	142%	163%	162%	162%	142%	131%

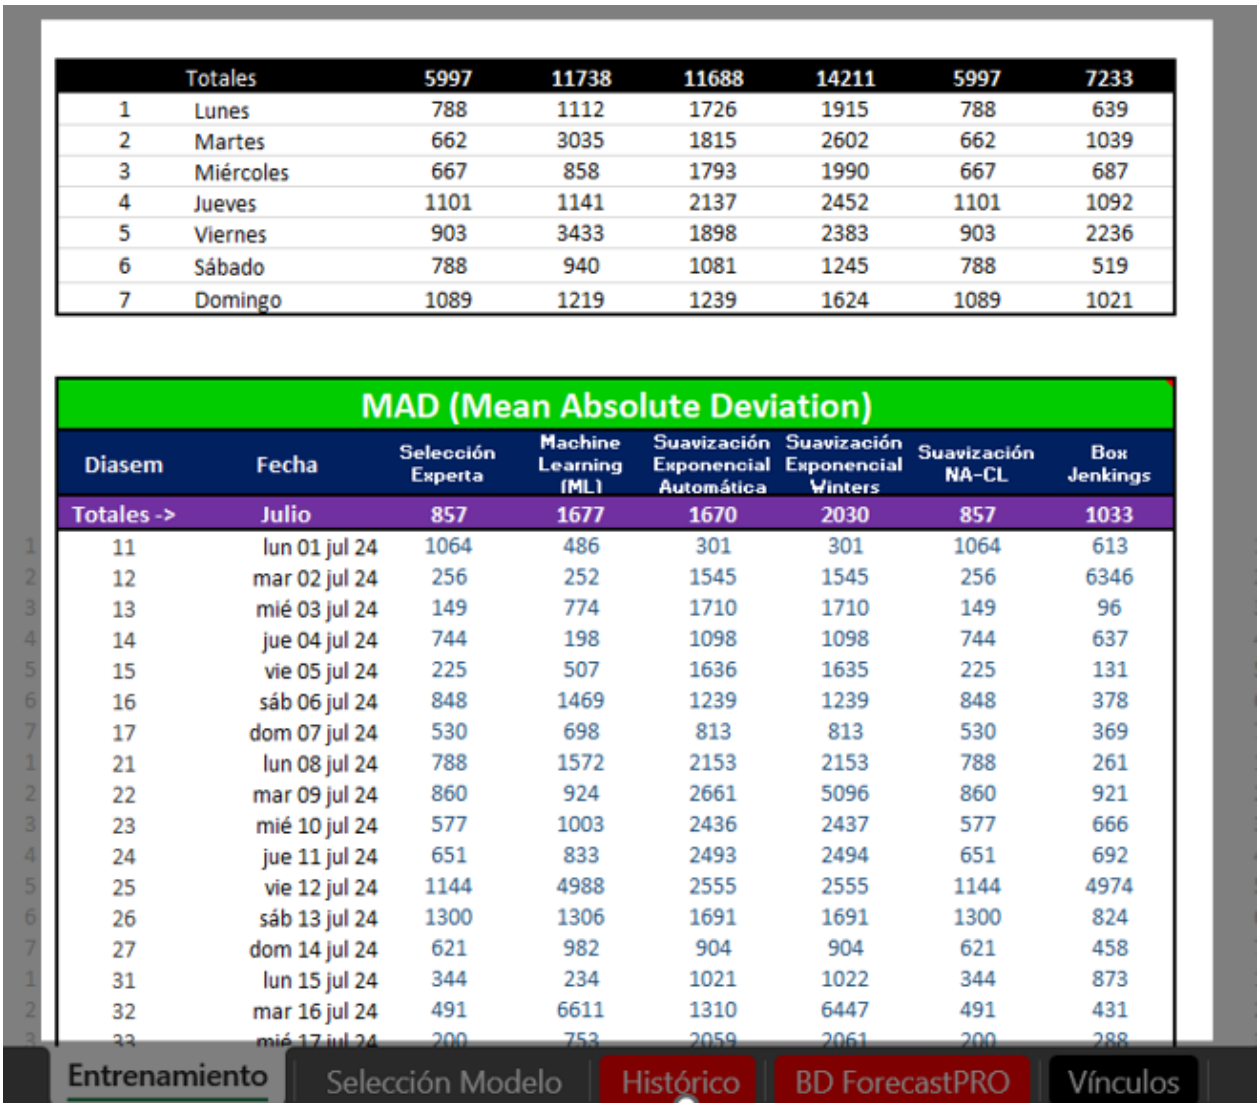
Fuente: Elaboración propia, 2025.

MAD: cálculo del MAD para cada uno de los modelos predictivos, según la siguiente fórmula descrita en la tabla 5.1:

$$MAD = \frac{1}{n} \sum |Y_t - \bar{Y}_t|$$

Donde: Y = datos reales, Ŷ = pronóstico.

Figura 5.5: Ejemplo de la tabla MAD en la Hoja de Entrenamiento en el PBF 2.0



	Totales	5997	11738	11688	14211	5997	7233
1	Lunes	788	1112	1726	1915	788	639
2	Martes	662	3035	1815	2602	662	1039
3	Miércoles	667	858	1793	1990	667	687
4	Jueves	1101	1141	2137	2452	1101	1092
5	Viernes	903	3433	1898	2383	903	2236
6	Sábado	788	940	1081	1245	788	519
7	Domingo	1089	1219	1239	1624	1089	1021

MAD (Mean Absolute Deviation)

Diasem	Fecha	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
Totales ->	Julio	857	1677	1670	2030	857	1033
11	lun 01 jul 24	1064	486	301	301	1064	613
12	mar 02 jul 24	256	252	1545	1545	256	6346
13	mié 03 jul 24	149	774	1710	1710	149	96
14	jue 04 jul 24	744	198	1098	1098	744	637
15	vie 05 jul 24	225	507	1636	1635	225	131
16	sáb 06 jul 24	848	1469	1239	1239	848	378
17	dom 07 jul 24	530	698	813	813	530	369
21	lun 08 jul 24	788	1572	2153	2153	788	261
22	mar 09 jul 24	860	924	2661	5096	860	921
23	mié 10 jul 24	577	1003	2436	2437	577	666
24	jue 11 jul 24	651	833	2493	2494	651	692
25	vie 12 jul 24	1144	4988	2555	2555	1144	4974
26	sáb 13 jul 24	1300	1306	1691	1691	1300	824
27	dom 14 jul 24	621	982	904	904	621	458
31	lun 15 jul 24	344	234	1021	1022	344	873
32	mar 16 jul 24	491	6611	1310	6447	491	431
33	mié 17 jul 24	200	753	2059	2061	200	288

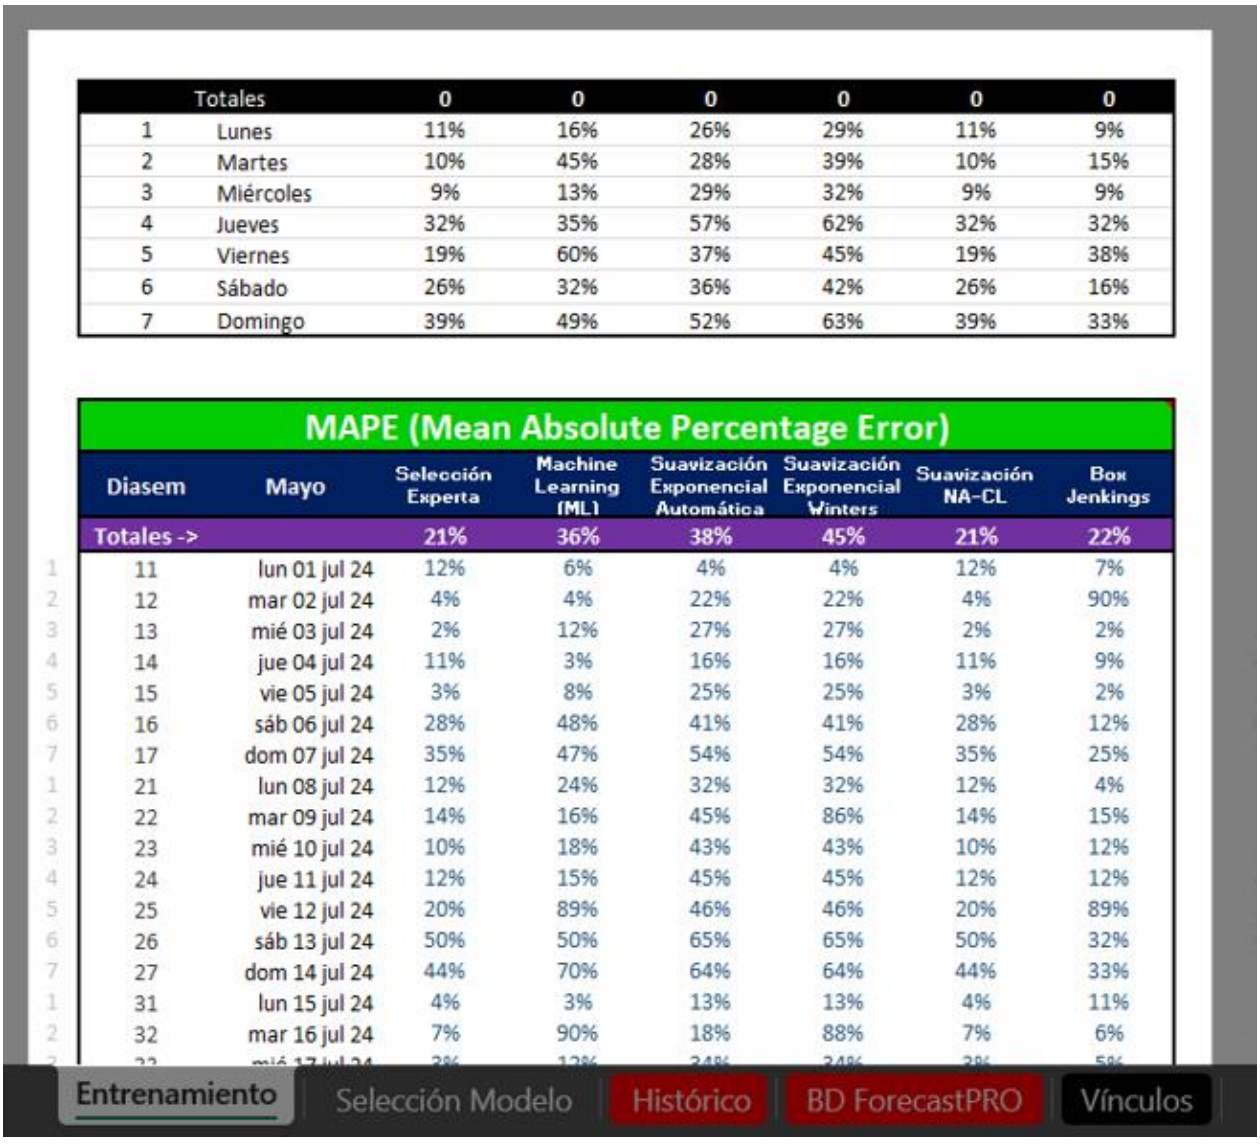
Fuente: Elaboración propia, 2025.

MAPE: cálculo del MAPE para cada uno de los modelos predictivos, de acuerdo con la siguiente fórmula descrita en la tabla 5.1:

$$MAPE = \frac{1}{n}\sum \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|$$

Donde: Y = datos reales, Ŷ = pronóstico.

Figura 5.6: Ejemplo de la tabla MAPE en la Hoja de Entrenamiento en el PBF 2.0



	Totales	0	0	0	0	0	0
1	Lunes	11%	16%	26%	29%	11%	9%
2	Martes	10%	45%	28%	39%	10%	15%
3	Miércoles	9%	13%	29%	32%	9%	9%
4	Jueves	32%	35%	57%	62%	32%	32%
5	Viernes	19%	60%	37%	45%	19%	38%
6	Sábado	26%	32%	36%	42%	26%	16%
7	Domingo	39%	49%	52%	63%	39%	33%

MAPE (Mean Absolute Percentage Error)

	Diasem	Mayo	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
	Totales ->		21%	36%	38%	45%	21%	22%
1	11	lun 01 jul 24	12%	6%	4%	4%	12%	7%
2	12	mar 02 jul 24	4%	4%	22%	22%	4%	90%
3	13	mié 03 jul 24	2%	12%	27%	27%	2%	2%
4	14	jue 04 jul 24	11%	3%	16%	16%	11%	9%
5	15	vie 05 jul 24	3%	8%	25%	25%	3%	2%
6	16	sáb 06 jul 24	28%	48%	41%	41%	28%	12%
7	17	dom 07 jul 24	35%	47%	54%	54%	35%	25%
1	21	lun 08 jul 24	12%	24%	32%	32%	12%	4%
2	22	mar 09 jul 24	14%	16%	45%	86%	14%	15%
3	23	mié 10 jul 24	10%	18%	43%	43%	10%	12%
4	24	jue 11 jul 24	12%	15%	45%	45%	12%	12%
5	25	vie 12 jul 24	20%	89%	46%	46%	20%	89%
6	26	sáb 13 jul 24	50%	50%	65%	65%	50%	32%
7	27	dom 14 jul 24	44%	70%	64%	64%	44%	33%
1	31	lun 15 jul 24	4%	3%	13%	13%	4%	11%
2	32	mar 16 jul 24	7%	90%	18%	88%	7%	6%

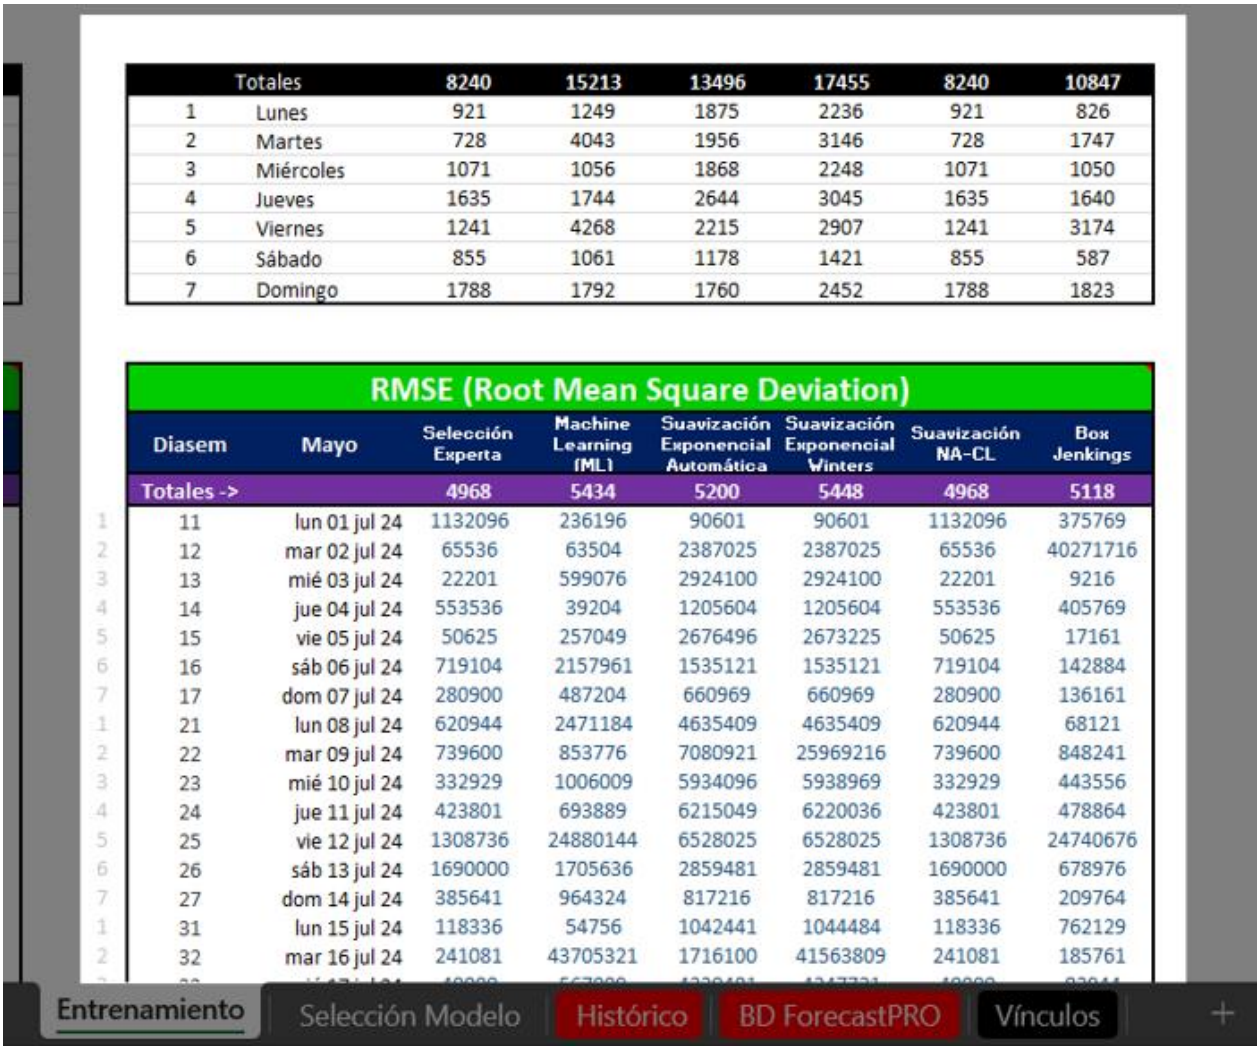
Fuente: Elaboración propia, 2025.

RMSE: cálculo del RMSE para cada uno de los modelos predictivos, según la siguiente fórmula descrita en la tabla 5.1:

$$RMSE = \sqrt{\frac{1}{n}\sum\left(Y_t - \hat{Y}_t\right)^2}$$

Donde: Y = datos reales, Ŷ = pronóstico.

Figura 5.7: Ejemplo de la tabla RMSE en la Hoja de Entrenamiento en el PBF 2.0



	Totales		8240	15213	13496	17455	8240	10847
1	Lunes		921	1249	1875	2236	921	826
2	Martes		728	4043	1956	3146	728	1747
3	Miércoles		1071	1056	1868	2248	1071	1050
4	Jueves		1635	1744	2644	3045	1635	1640
5	Viernes		1241	4268	2215	2907	1241	3174
6	Sábado		855	1061	1178	1421	855	587
7	Domingo		1788	1792	1760	2452	1788	1823

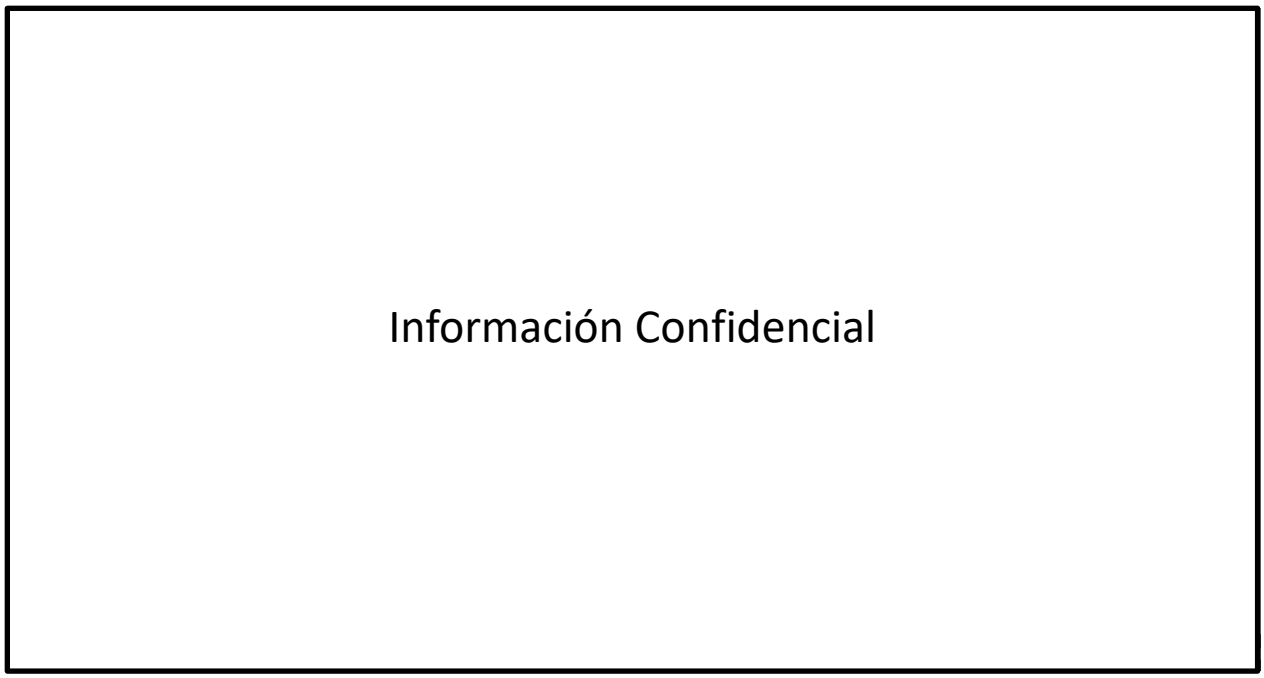
RMSE (Root Mean Square Deviation)

	Diasem	Mayo	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
	Totales ->		4968	5434	5200	5448	4968	5118
1	11	lun 01 jul 24	1132096	236196	90601	90601	1132096	375769
2	12	mar 02 jul 24	65536	63504	2387025	2387025	65536	40271716
3	13	mié 03 jul 24	22201	599076	2924100	2924100	22201	9216
4	14	jue 04 jul 24	553536	39204	1205604	1205604	553536	405769
5	15	vie 05 jul 24	50625	257049	2676496	2673225	50625	17161
6	16	sáb 06 jul 24	719104	2157961	1535121	1535121	719104	142884
7	17	dom 07 jul 24	280900	487204	660969	660969	280900	136161
1	21	lun 08 jul 24	620944	2471184	4635409	4635409	620944	68121
2	22	mar 09 jul 24	739600	853776	7080921	25969216	739600	848241
3	23	mié 10 jul 24	332929	1006009	5934096	5938969	332929	443556
4	24	jue 11 jul 24	423801	693889	6215049	6220036	423801	478864
5	25	vie 12 jul 24	1308736	24880144	6528025	6528025	1308736	24740676
6	26	sáb 13 jul 24	1690000	1705636	2859481	2859481	1690000	678976
7	27	dom 14 jul 24	385641	964324	817216	817216	385641	209764
1	31	lun 15 jul 24	118336	54756	1042441	1044484	118336	762129
2	32	mar 16 jul 24	241081	43705321	1716100	41563809	241081	185761

Fuente: Elaboración propia, 2025.

En el caso del coeficiente de determinación de Pearson **R^2**, se calcula directamente con la función de Excel: “Coeficiente.R2”. Asimismo, se agregan parámetros de media, mediana, desviación estándar y estacionalidad en la tabla consolidada de resultados, indicada a continuación:

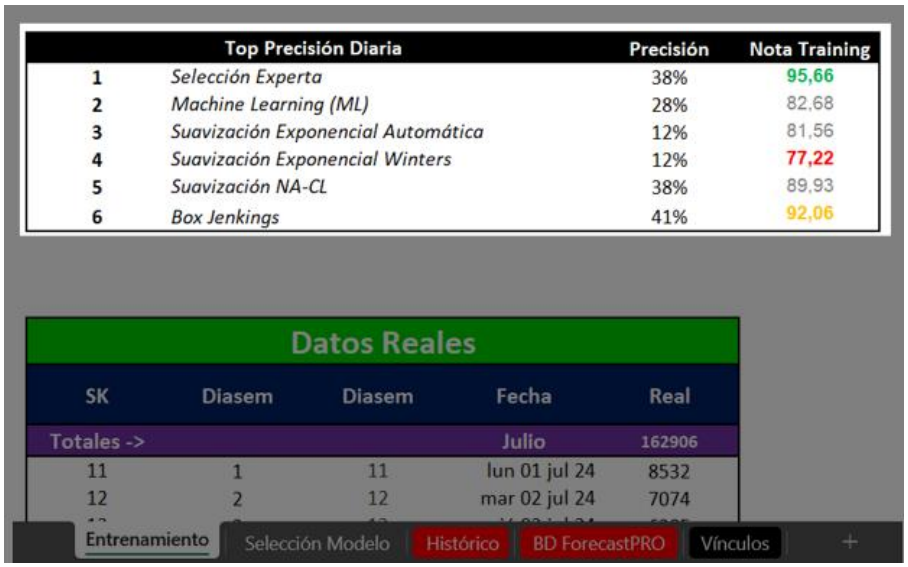
Figura 5.8: Ejemplo de la tabla de resultados de los parámetros estadísticos en la Hoja de Entrenamiento en el PBF 2.0



Fuente: Elaboración propia, 2025.

Además de consolidar los resultados, en esta tabla se agregan **variables de referencia** y **peso en la ponderación**, con la intención de poder calcular una nota de 0 a 100 para calificar el desempeño de cada modelo predictivo en la siguiente tabla:

Figura 5.9: Ejemplo de la tabla de resultados de los parámetros estadísticos en la Hoja de Entrenamiento en el PBF 2.0



Fuente: Elaboración propia, 2025.

Con esta tabla se finaliza la Hoja de Entrenamiento. Al respecto, en este ejemplo de pronóstico correspondiente al mes de enero de 2025, según la nota construida a partir del cálculo de los parámetros, el mejor modelo predictivo es selección experta con un resultado de 95,97 % en la fase de entrenamiento.

Selección del modelo

En esta hoja se selecciona el modelo con base en los resultados de la fase de entrenamiento. Sin embargo, no necesariamente es el modelo con la nota más alta, pues esta nota es una referencia del proceso de entrenamiento, sino que por la experiencia del analista se pueden determinar otros factores externos e internos, según la información del archivo, para decidir el modelo, o bien, en cuanto a este proyecto, elegir la selección experta, que como se evidencia en el estudio es el de mejor resultado en el periodo evaluado. Por consiguiente, la primera tabla en esta hoja es el consolidado de los modelos predictivos:

Figura 5.10: Ejemplo de la tabla de consolidado de los resultados de los modelos predictivos en la Hoja de Selección del Modelo en el PBF 2.0

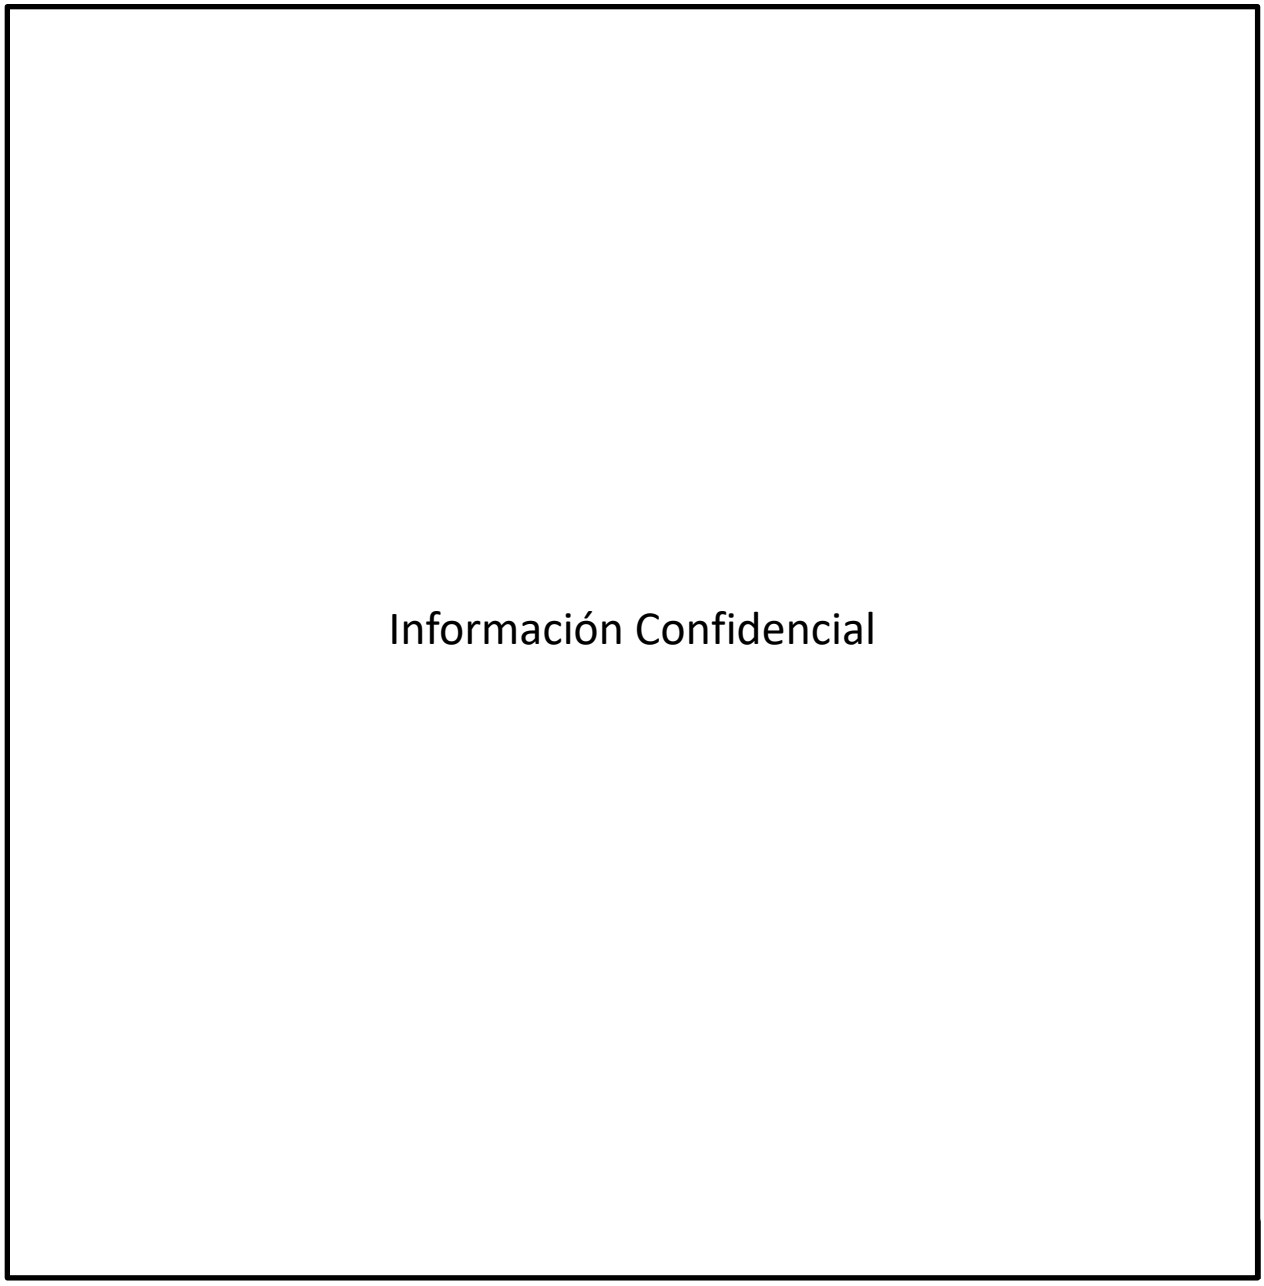


Diasem	Enero	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings
Totales ->		172 235	173 506	161 682	173 920	201 401	172 235
13	miércoles 01	6 520	6 660	5 922	6 412	7 243	6 520
14	jueves 02	6 084	6 336	5 708	5 945	6 653	6 084
15	viernes 03	6 159	6 148	5 808	6 047	6 481	6 159
16	sábado 04	3 274	3 099	2 814	3 216	3 431	3 274
17	domingo 05	1 942	1 891	1 959	2 381	3 610	1 942
11	lunes 06	7 325	7 327	7 341	7 807	9 513	7 325
12	martes 07	7 068	7 116	6 509	7 070	8 325	7 068
23	miércoles 08	6 519	6 660	5 922	6 412	7 243	6 519
24	jueves 09	6 084	6 363	5 708	5 945	6 653	6 084
25	viernes 10	6 159	6 148	5 808	6 047	6 481	6 159
26	sábado 11	3 274	3 099	2 814	3 216	3 431	3 274
27	domingo 12	1 942	1 891	1 959	2 381	3 610	1 942
21	lunes 13	7 325	7 327	7 341	7 807	9 513	7 325
22	martes 14	7 067	7 116	6 509	7 070	8 325	7 067
33	miércoles 15	6 519	6 660	5 922	6 412	7 243	6 519
34	jueves 16	6 083	6 336	5 708	5 945	6 653	6 083
35	viernes 17	6 158	6 148	5 808	6 047	6 481	6 158
36	sábado 18	3 274	3 099	2 814	3 216	3 431	3 274
37	domingo 19	1 942	1 891	1 959	2 381	3 610	1 942
31	lunes 20	7 324	7 327	7 341	7 808	9 513	7 324
32	martes 21	7 067	7 116	6 509	7 070	8 325	7 067
43	miércoles 22	6 519	6 660	5 922	6 413	7 243	6 519
44	jueves 23	6 083	6 363	5 708	5 945	6 653	6 083
45	viernes 24	6 158	6 148	5 808	6 047	6 481	6 158
46	sábado 25	3 275	3 099	2 814	3 216	3 431	3 275
47	domingo 26	1 942	1 891	1 959	2 381	3 610	1 942
41	lunes 27	7 324	7 327	7 341	7 808	9 513	7 324
42	martes 28	7 066	7 116	6 509	7 070	8 325	7 066
53	miércoles 29	6 518	6 660	5 922	6 413	7 243	6 518
54	jueves 30	6 083	6 336	5 708	5 945	6 653	6 083
55	viernes 31	6 158	6 148	5 808	6 047	6 481	6 158

Fuente: Elaboración propia, 2025.

Además del consolidado, se muestra el histórico por mes como referencia y para realizar cálculos de ajuste al modelo actual:

Figura 5.11: Ejemplo de las tablas del histórico por mes en la Hoja de Selección del Modelo en el PBF 2.0

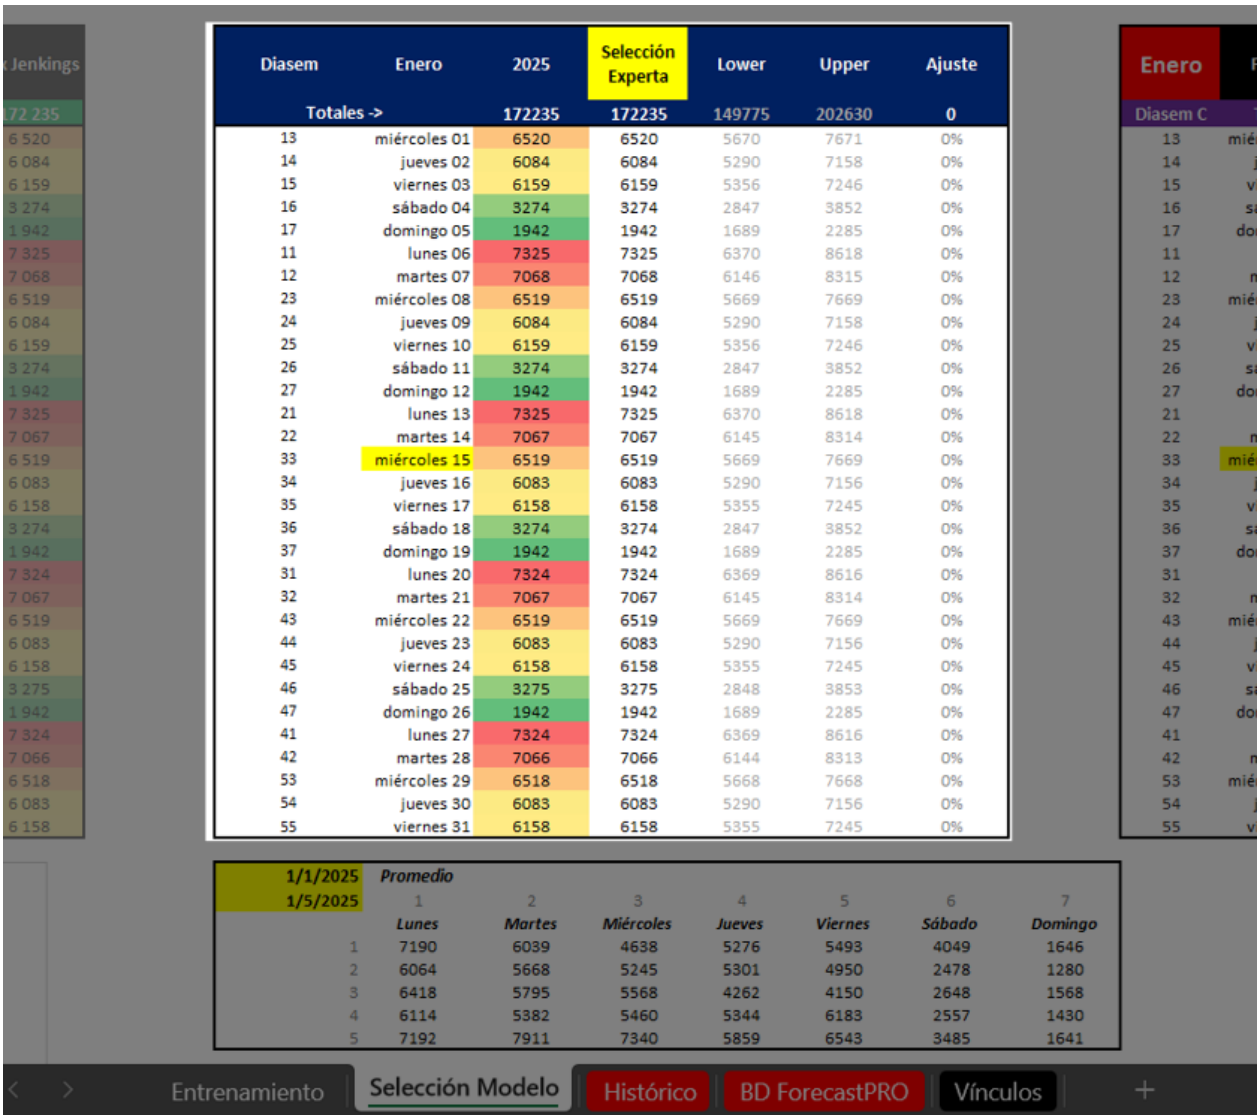


Fuente: Elaboración propia, 2025.

Por último, en la tabla de selección del modelo, la cual es el aspecto esencial de esta hoja, se elige el modelo en la celda en amarillo y se agrega una columna de *lower* y *upper* con relación al umbral de pronóstico (± 15 %) en conjunto con la columna de ajuste en la que se puede agregar un ajuste porcentual de crecimiento o decrecimiento individualmente para cada uno de los días del mes. Esto le proporciona al analista todos

los parámetros para, una vez elegido el modelo, efectuar los ajustes con base en estadística e históricos.

Figura 5.12: Ejemplo de la tabla de selección y ajuste del modelo predictivo en la Hoja de Selección del Modelo en el PBF 2.0



Diasem	Enero	2025	Selección Experta	Lower	Upper	Ajuste
	Totales ->	172235	172235	149775	202630	0
13	miércoles 01	6520	6520	5670	7671	0%
14	jueves 02	6084	6084	5290	7158	0%
15	viernes 03	6159	6159	5356	7246	0%
16	sábado 04	3274	3274	2847	3852	0%
17	domingo 05	1942	1942	1689	2285	0%
11	lunes 06	7325	7325	6370	8618	0%
12	martes 07	7068	7068	6146	8315	0%
23	miércoles 08	6519	6519	5669	7669	0%
24	jueves 09	6084	6084	5290	7158	0%
25	viernes 10	6159	6159	5356	7246	0%
26	sábado 11	3274	3274	2847	3852	0%
27	domingo 12	1942	1942	1689	2285	0%
21	lunes 13	7325	7325	6370	8618	0%
22	martes 14	7067	7067	6145	8314	0%
33	miércoles 15	6519	6519	5669	7669	0%
34	jueves 16	6083	6083	5290	7156	0%
35	viernes 17	6158	6158	5355	7245	0%
36	sábado 18	3274	3274	2847	3852	0%
37	domingo 19	1942	1942	1689	2285	0%
31	lunes 20	7324	7324	6369	8616	0%
32	martes 21	7067	7067	6145	8314	0%
43	miércoles 22	6519	6519	5669	7669	0%
44	jueves 23	6083	6083	5290	7156	0%
45	viernes 24	6158	6158	5355	7245	0%
46	sábado 25	3275	3275	2848	3853	0%
47	domingo 26	1942	1942	1689	2285	0%
41	lunes 27	7324	7324	6369	8616	0%
42	martes 28	7066	7066	6144	8313	0%
53	miércoles 29	6518	6518	5668	7668	0%
54	jueves 30	6083	6083	5290	7156	0%
55	viernes 31	6158	6158	5355	7245	0%

1/1/2025	Promedio						
1/5/2025	1	2	3	4	5	6	7
	Lunes	Martes	Miércoles	Jueves	Viernes	Sábado	Domingo
1	7190	6039	4638	5276	5493	4049	1646
2	6064	5668	5245	5301	4950	2478	1280
3	6418	5795	5568	4262	4150	2648	1568
4	6114	5382	5460	5344	6183	2557	1430
5	7192	7911	7340	5859	6543	3485	1641

Fuente: Elaboración propia, 2025.

Histórico

Esta hoja funciona como base de datos, ya que en esta se agregan los datos históricos de llamadas para hacer los cálculos en la Hoja de Entrenamiento; adicional, funciona como referencia en la Hoja de Selección del Modelo.

Figura 5.13: Ejemplo de la Hoja de Histórico en el PBF 2.0

Año	Mes	Diasem C	Diasem	Fecha	Ofrecidas	Mes
2022	Enero	16	6	1/1/2022	1108	154099
2022	Enero	17	7	2/1/2022	1488	154099
2022	Enero	11	1	3/1/2022	8389	154099
2022	Enero	12	2	4/1/2022	7839	154099
2022	Enero	13	3	5/1/2022	7927	154099
2022	Enero	14	4	6/1/2022	5824	154099
2022	Enero	15	5	7/1/2022	5717	154099
2022	Enero	26	6	8/1/2022	2558	154099
2022	Enero	27	7	9/1/2022	1282	154099
2022	Enero	21	1	10/1/2022	6090	154099
2022	Enero	22	2	11/1/2022	5438	154099
2022	Enero	23	3	12/1/2022	5963	154099
2022	Enero	24	4	13/1/2022	5293	154099
2022	Enero	25	5	14/1/2022	6021	154099
2022	Enero	36	6	15/1/2022	3014	154099
2022	Enero	37	7	16/1/2022	1475	154099
2022	Enero	31	1	17/1/2022	6990	154099
2022	Enero	32	2	18/1/2022	5998	154099
2022	Enero	33	3	19/1/2022	5712	154099
2022	Enero	34	4	20/1/2022	5245	154099
2022	Enero	35	5	21/1/2022	5619	154099
2022	Enero	46	6	22/1/2022	2901	154099
2022	Enero	47	7	23/1/2022	1287	154099
2022	Enero	41	1	24/1/2022	6041	154099
2022	Enero	42	2	25/1/2022	5672	154099
2022	Enero	43	3	26/1/2022	5904	154099
2022	Enero	44	4	27/1/2022	6142	154099
2022	Enero	45	5	28/1/2022	7691	154099
2022	Enero	56	6	29/1/2022	3591	154099
2022	Enero	57	7	30/1/2022	1692	154099
2022	Enero	51	1	31/1/2022	8188	154099
2022	Febrero	12	2	1/2/2022	8733	146535
2022	Febrero	13	3	2/2/2022	7575	146535
2022	Febrero	14	4	3/2/2022	6624	146535
2022	Febrero	15	5	4/2/2022	6286	146535
2022	Febrero	16	6	5/2/2022	3123	146535
2022	Febrero	17	7	6/2/2022	1161	146535
2022	Febrero	11	1	7/2/2022	6352	146535



Fuente: Elaboración propia, 2025.

BD Forecast PRO

En esta hoja se crean 2 tablas, la primera es **entrenamiento**, en la que se colocan los resultados de los modelos predictivos en esta fase para evaluarlos posteriormente en la Hoja de Entrenamiento y la otra tabla es **pronósticos**, la cual consolida los resultados de los pronósticos para la predicción del mes por pronosticar.

A modo de ejemplo, se toma de base enero de 2025 como el mes por pronosticar. Así, es necesario situarse en la fecha 21/10/2024 al ser el día en el que se lleva a cabo el pronóstico para este mes.

El proceso inicia cuando se toman los datos históricos disponibles hasta el 30/6/2024 y se pronóstica el periodo de entrenamiento en la herramienta de Forecast PRO, que para este caso es del 1/7/2024 al 20/10/2024. Estos resultados se colocan en la tabla de entrenamiento y luego se vuelve a realizar el ejercicio de pronóstico en la herramienta, esta vez con todo el histórico disponible hasta el 20/10/2024 para el dato del mes de enero de 2025 por pronosticar.

Figura 5.14: Ejemplo de la tabla de entrenamiento en la Hoja de BD Forecast PRO en PBF 2.0



Entrenamiento						
Fecha	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings
1/7/2024	7468	8046	8833	8833	7468	7919
2/7/2024	6818	7326	8619	8619	6818	728
3/7/2024	6236	7159	8095	8095	6236	6481
4/7/2024	6236	7178	8078	8078	6236	6343
5/7/2024	6755	7037	8166	8165	6755	6399
6/7/2024	3897	4518	4288	4288	3897	3427
30/7/2024	6818	698	8619	8622	6818	6877
31/7/2024	6236	6789	8095	8099	6236	6324
1/8/2024	6236	6874	8078	8081	6236	6276
2/8/2024	6755	7385	8166	8169	6755	637
3/8/2024	3897	4423	4288	429	3897	3421
4/8/2024	2024	2129	2307	2308	2024	1862
5/8/2024	7468	8046	8833	8837	7468	6938
6/8/2024	6818	6863	8619	8623	6818	6877
7/8/2024	6236	6662	8095	81	6236	6324
8/8/2024	6236	6418	8078	8082	6236	6276

Fuente: Elaboración propia, 2025.

Figura 5.15: Ejemplo de la tabla de pronóstico de la Hoja de BD Forecast PRO en PBF 2.0



Pronóstico						
Fecha	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CI	Box Jenkings
21/10/2024	7468	8046	8833	8848	7468	6936
22/10/2024	6818	698	8619	8634	6818	6875
23/10/2024	6236	6789	8095	8109	6236	6323
24/10/2024	6236	6874	8078	8092	6236	6275
25/10/2024	6755	7385	8166	8179	6755	6368
26/10/2024	3897	4423	4288	4295	3897	3422
21/11/2024	6086	6336	5708	5944	6653	6086
22/11/2024	6161	6148	5808	6046	6481	6161
23/11/2024	3273	3099	2814	3215	3431	3273
24/11/2024	1940	1891	1959	2381	3610	1940
25/11/2024	7329	7327	7341	7806	9513	7329
26/11/2024	7071	7116	6509	7069	8325	7071
27/11/2024	6521	6660	5922	6412	7243	6521
28/11/2024	6085	6363	5708	5944	6653	6085

Fuente: Elaboración propia, 2025.

Vínculos

Esta hoja almacena el cálculo de fechas, años, meses y días de la semana, que son indispensables para el funcionamiento del archivo.

Figura 5.16: Ejemplo de la Hoja de Vínculos en el PBF 2.0



Fecha	Año	Mes	Diasem	Diasem C
1/1/2022	2022	1	6	16
2/1/2022	2022	1	7	17
3/1/2022	2022	1	1	11
4/1/2022	2022	1	2	12
5/1/2022	2022	1	3	13
6/1/2022	2022	1	4	14
7/1/2022	2022	1	5	15
8/1/2022	2022	1	6	26
9/1/2022	2022	1	7	27
10/1/2022	2022	1	1	21
11/1/2022	2022	1	2	22
12/1/2022	2022	1	3	23
13/1/2022	2022	1	4	24
14/1/2022	2022	1	5	25
15/1/2022	2022	1	6	36
16/1/2022	2022	1	7	37
17/1/2022	2022	1	1	31

Fuente: Elaboración propia, 2025.

Terminado el nuevo método, se efectúa una comprobación basada en los resultados obtenidos en el capítulo 4, figura 4.17, donde se evidencia que el modelo de **selección experta** tiene un mejor desempeño en el periodo de estudio.

Después, se lleva a cabo un nuevo cálculo fundamentado en la metodología aplicada en el cálculo (B), en la sección 4.2.3, en el que solo se sustituye el pronóstico de llamadas del método actual por el pronóstico de llamadas del modelo de selección experta. Posterior a esto, se vuelve a realizar el ejercicio comparativo en un tercer escenario.

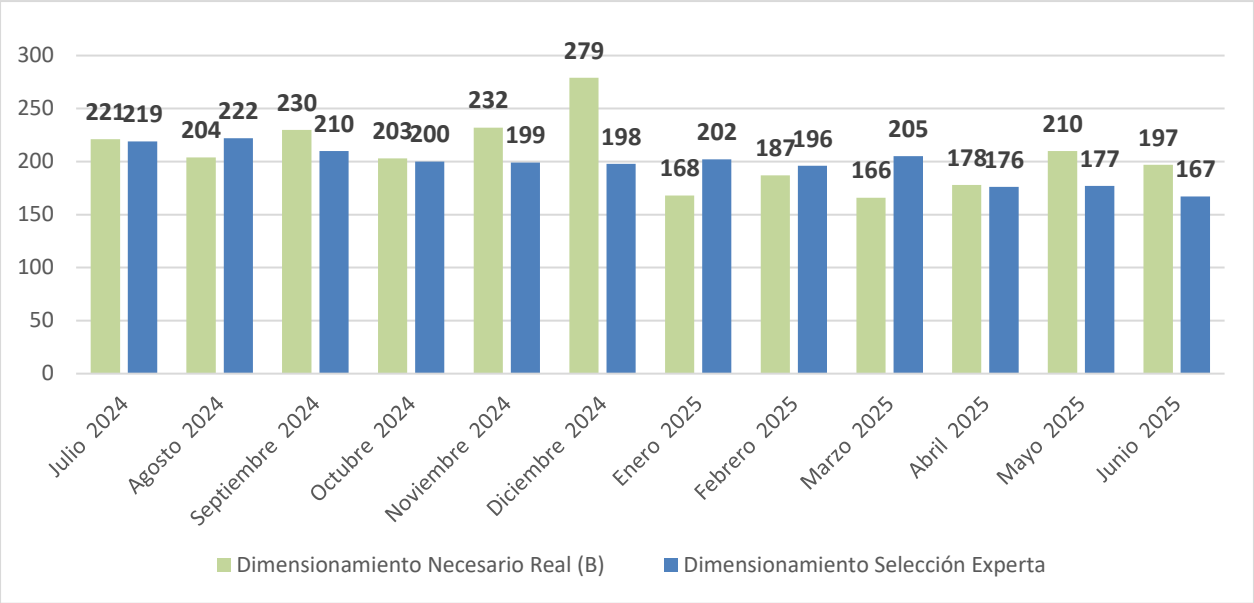
Escenario 3 (nuevo método): cálculo comparativo del dimensionamiento necesario real (B) vs. el dimensionamiento con selección experta

Mediante los cálculos hechos en este escenario, se pone a prueba el nuevo método. En un principio, se pretendía que en este nuevo método los parámetros estadísticos fueran los decisivos para la selección; no obstante, estos pasan a ser una referencia del desempeño de los modelos en la fase de entrenamiento, debido a que en el capítulo 4 se identifica el modelo de **selección experta** como el que mejor predice las llamadas del proyecto consistentemente. Por lo tanto, este escenario se basa en este modelo.

Lo anterior no significa que los parámetros estadísticos no son parte del modelo o se les reste importancia, sino que para este escenario no son los protagonistas por los hallazgos antes mencionados. Sin embargo, estos parámetros son vitales en la selección del modelo cuando los factores son una tendencia histórica, como lo puede ser un cambio de proceso del cliente, un cambio en la cartera de clientes o un cambio mayor, lo cual puede afectar el comportamiento de la demanda. Además, su uso adquiere mayor relevancia cuando un análisis histórico de desempeño por modelo no sea posible como proyecto nuevo.

Ahora bien, como en los anteriores escenarios, primero se compara el dimensionamiento necesario real (B) vs. el nuevo cálculo del dimensionamiento con la selección del modelo de **selección experta** mediante el nuevo método, como lo indica el siguiente gráfico:

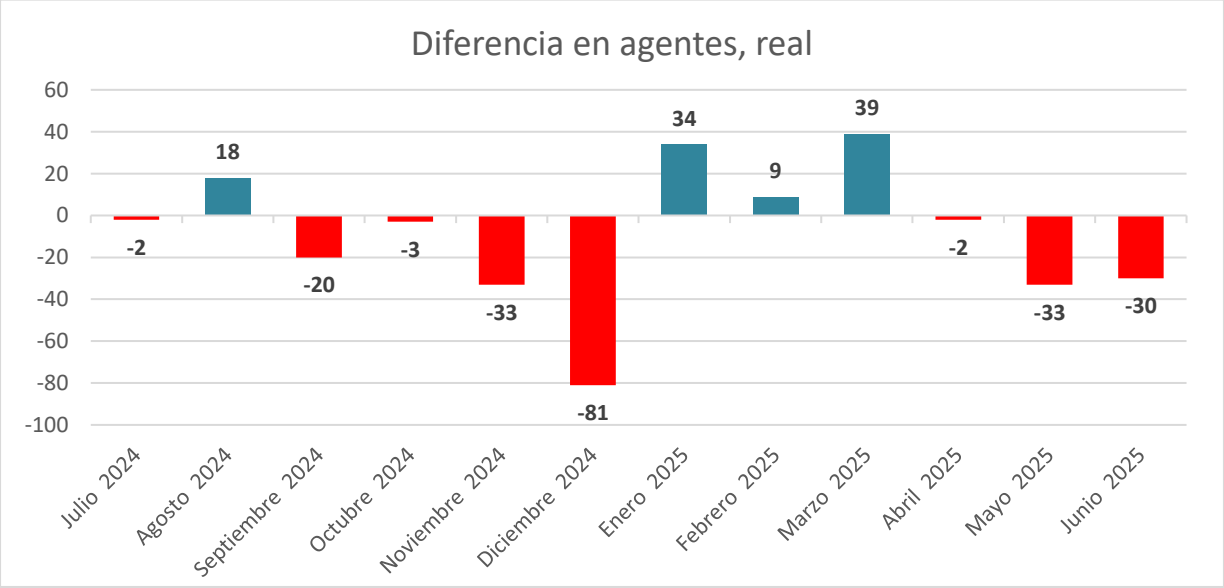
Figura 5.17: Gráfico de barras del dimensionamiento necesario real (B) vs. el dimensionamiento con el modelo de selección experta



Fuente: Elaboración propia, 2025.

Luego, se discrimina la diferencia de agentes necesarios representándola en el siguiente gráfico de barras:

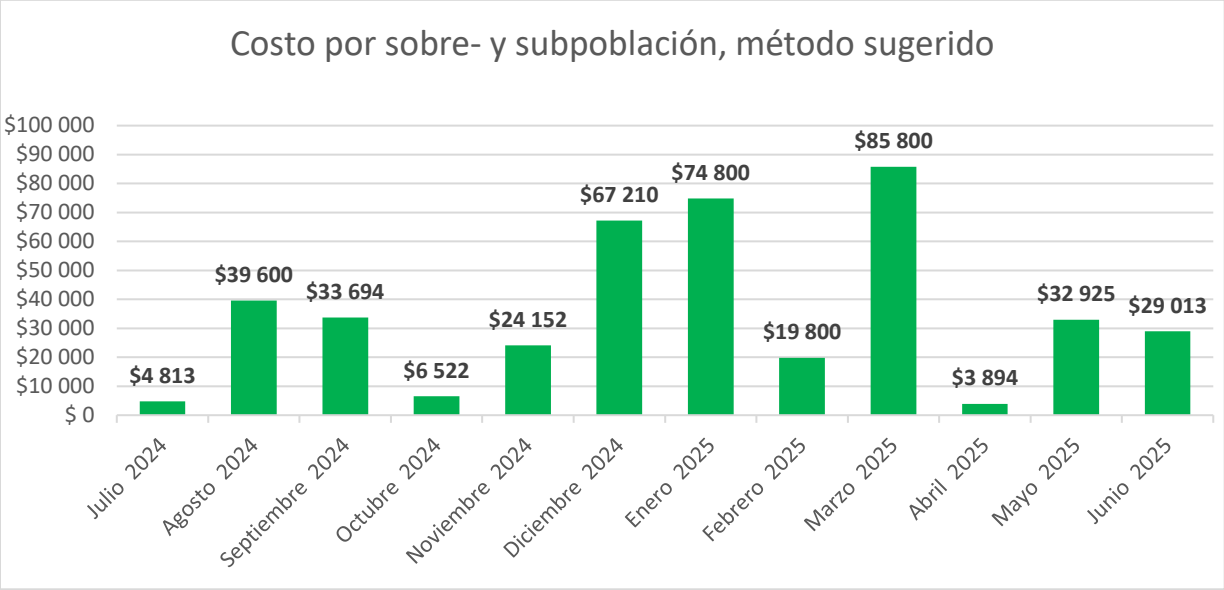
Figura 5.18: Gráfico de barras de la diferencia de agentes, dimensionamiento necesario real (B) vs. dimensionamiento con el modelo de selección experta



Fuente: Elaboración propia, 2025.

El gráfico presenta una menor diferencia de agentes en total comparándolo con los anteriores escenarios. Los montos asociados a estas diferencias se aprecian en el siguiente gráfico:

Figura 5.19: Costos por sobre- y subdimensionamiento necesario real (B) vs. dimensionamiento con el modelo de selección experta



Fuente: Elaboración propia, 2025.

Este ejercicio de comparación aprueba la efectividad del método nuevo (PBF 2.0), el cual permite seleccionar todo un modelo y no la combinación de estos. También, verifica que para el Proyecto Banco este modelo es el más preciso, al tener un ahorro en los costos con respecto al dimensionamiento del método actual (A) de **$ 125 446** o un ahorro de **$ 40 187** en comparación al dimensionamiento de personal real (B), en el periodo de estudio. La siguiente tabla expone los resultados:

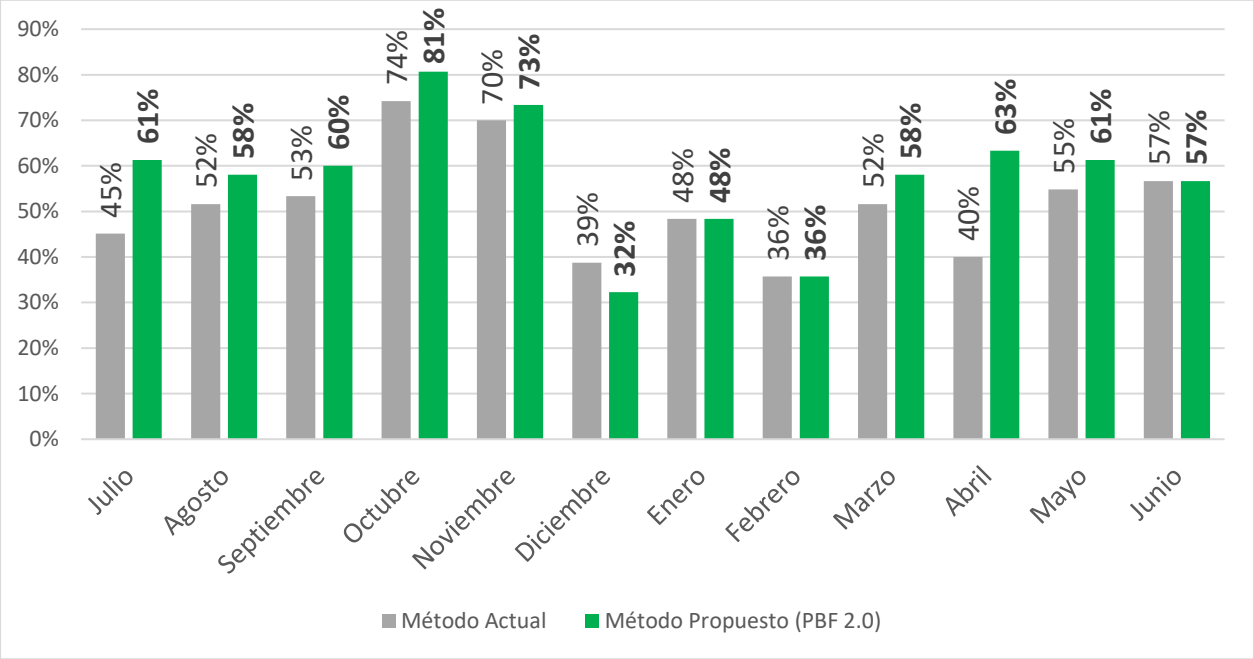
Tabla 5.5 Comparativo de las pérdidas del método actual y el método nuevo

Escenarios	Costo por sobre- y subdimensionamiento	Diferencia vs. nuevo método
Escenario 1 (método actual A)	$ 547 669	-$ 125 446
Escenario 2 (referencia B)	$ 462 411	-$ 40 187
Escenario 3 (nuevo método)	$ 422 223	--

Fuente: Elaboración propia, 2025.

Por último, se realiza el siguiente gráfico comparativo del desempeño en el error de pronóstico entre el método actual y el método nuevo (PBF 2.0), seleccionando un solo modelo, a saber, selección experta:

Figura 5.20: Gráfico de barras comparativo del método actual vs. el método nuevo (PBF 2.0)



Fuente: Elaboración propia, 2025.

Como se evidencia en el anterior gráfico, el método nuevo (PBF 2.0), que posibilita la selección de todo un modelo y no la combinación de estos, tiene un mejor desempeño en el periodo de estudio, mejorando o igualando la precisión del método actual en la mayoría de los meses; en concreto, mejora la precisión en 8 de los 12 meses (56,7 %) y la iguala en 3 de los 4 restantes.

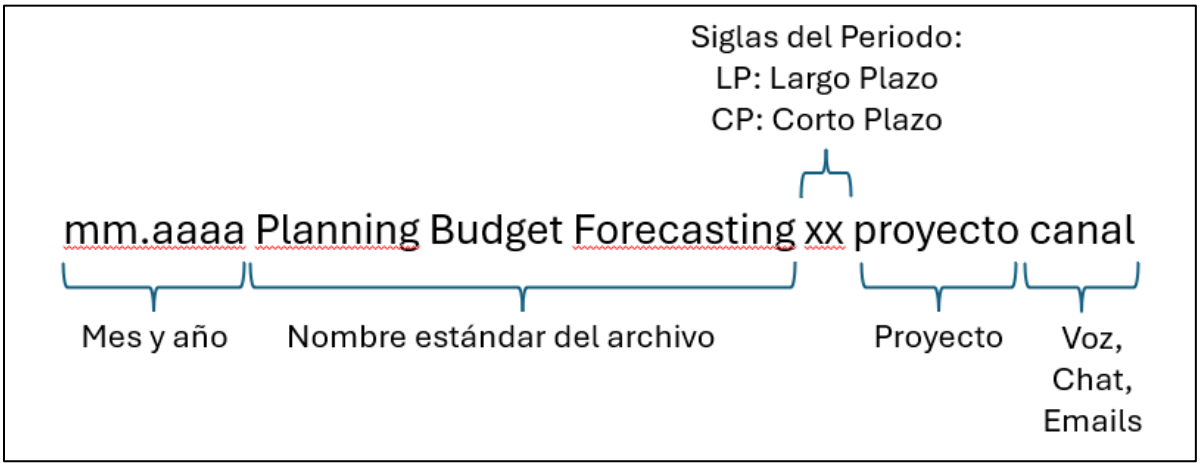
5.2 CONTROLAR

5.2.1 Control de versiones

El nuevo modelo permite almacenar todos los modelos predictivos utilizados, por consiguiente, se propone implementar un control de versiones en el repositorio web (Sharepoint). Así, en este el analista debe mantener el PBF 2.0 en una carpeta llamada “Modelado de datos” para las respectivas comprobaciones por realizar después en busca

de nuevas tendencias, estacionalidades o cambio del modelo predictivo empleado. El resultado histórico de cada modelo se analiza bajo el siguiente formato de nombre:

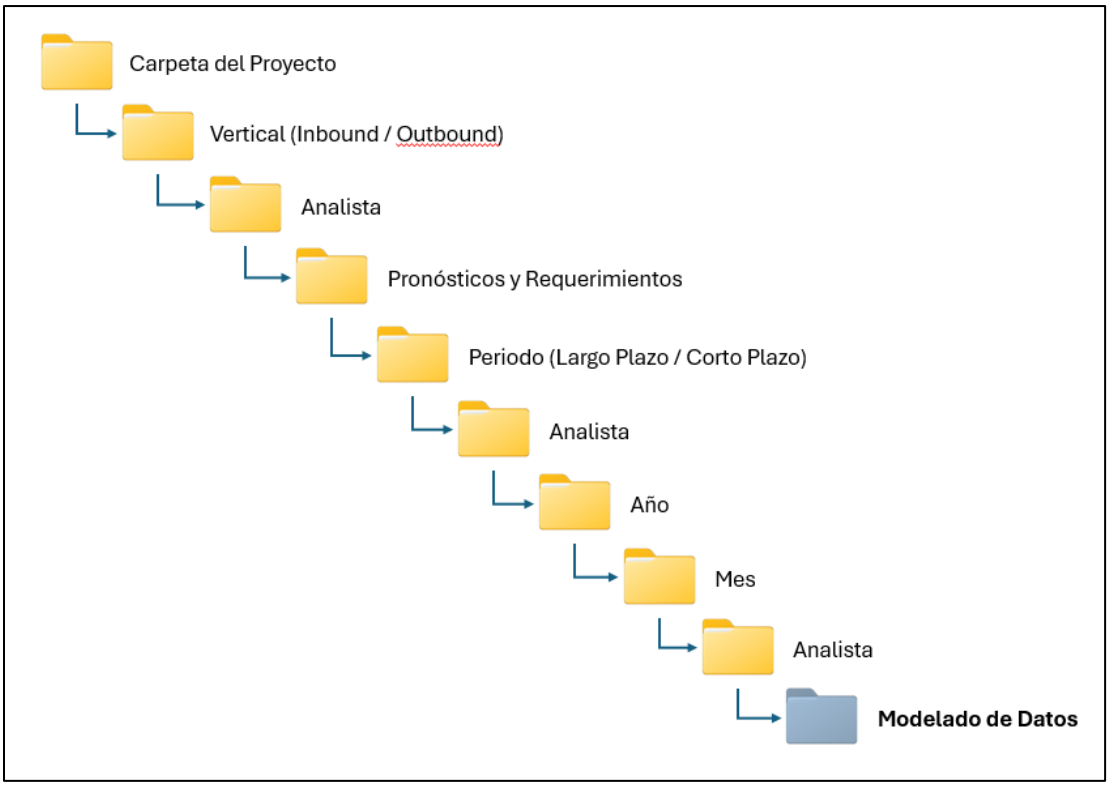
Figura 5.21: Formato de nombre para el almacenamiento del nuevo PBF 2.0



Fuente: Elaboración propia, 2025.

Esto debe llevarse a cabo en el repositorio web del Sharepoint, en el grupo de trabajo del Departamento de WFM, de acuerdo con el siguiente esquema:

Figura 5.22: Estructura de almacenamiento del nuevo PBF 2.0



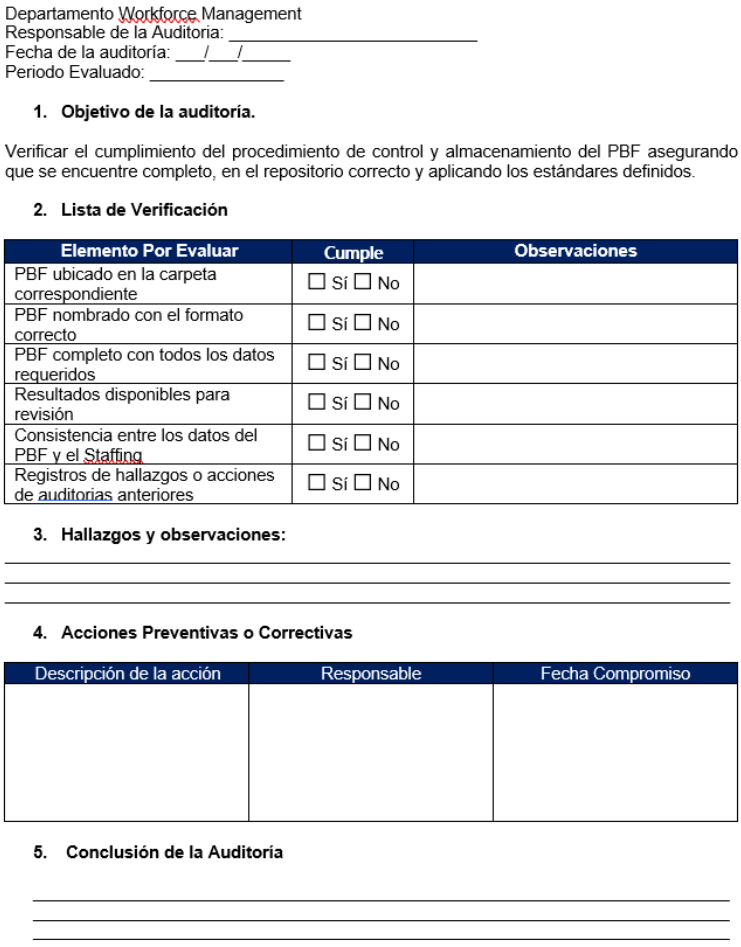
Fuente: Elaboración propia, 2025.

5.2.2 Auditorías internas

El PBF 2.0 de cada mes se almacena en el repositorio web; de este modo, es una necesidad que este se utilice de manera correcta. Por lo tanto, se proponen auditorías internas de forma periódica a cargo del coordinador de WFM con el fin de verificar que los archivos del PBF 2.0 estén en las carpetas correspondientes y completos con todos los datos requeridos, pues esto facilita evaluar los resultados obtenidos y el correcto uso del método. Adicional, los hallazgos permiten distinguir oportunidades de mejora y reforzar el cumplimiento de los estándares del nuevo modelo.

Esta auditoría se lleva a cabo con base en el formato indicado en el apéndice 2 del presente estudio. El propósito de este formato es llenarse y enviarse por correo al analista auditado, a efectos de registro y seguimiento.

Figura 5.23: Ejemplo del apéndice 2 correspondiente al formato de auditoría del nuevo PBF 2.0



Departamento Workforce Management
Responsable de la Auditoria: _____
Fecha de la auditoría: ___/___/_____
Periodo Evaluado: _____

1. Objetivo de la auditoría.

Verificar el cumplimiento del procedimiento de control y almacenamiento del PBF asegurando que se encuentre completo, en el repositorio correcto y aplicando los estándares definidos.

2. Lista de Verificación

Elemento Por Evaluar	Cumple	Observaciones
PBF ubicado en la carpeta correspondiente	☐ Sí ☐ No	
PBF nombrado con el formato correcto	☐ Sí ☐ No	
PBF completo con todos los datos requeridos	☐ Sí ☐ No	
Resultados disponibles para revisión	☐ Sí ☐ No	
Consistencia entre los datos del PBF y el Staffing	☐ Sí ☐ No	
Registros de hallazgos o acciones de auditorias anteriores	☐ Sí ☐ No	

3. Hallazgos y observaciones:

_____
_____
_____

4. Acciones Preventivas o Correctivas

Descripción de la acción	Responsable	Fecha Compromiso

5. Conclusión de la Auditoría

_____
_____
_____

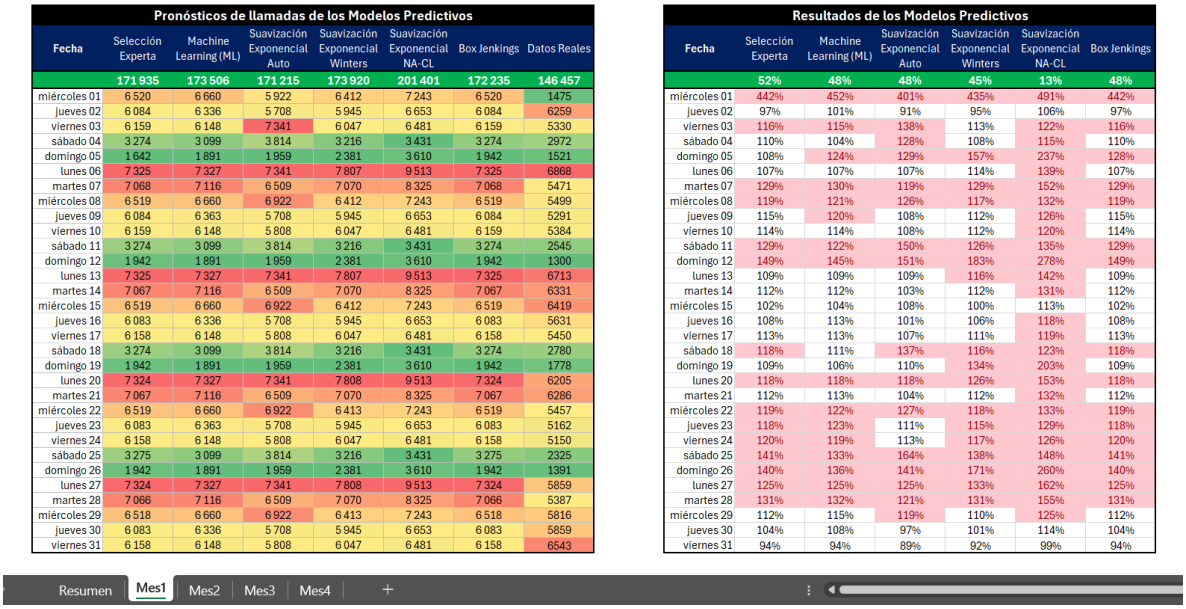
Fuente: Elaboración propia, 2025.

5.2.3 Reuniones periódicas

Además de los anteriores métodos de control, se propone hacer reuniones lideradas por el coordinador de proyecto y con la participación obligatoria del analista encargado, de periodicidad cuatrimestral. En estas se plantea evaluar los resultados obtenidos de los pronósticos realizados y efectuar el ejercicio de precisión del pronóstico de todos los modelos predictivos almacenados gracias al control de versiones mencionado en la sección 5.2.1 del presente estudio. La finalidad de este ejercicio es comparar la precisión de cada modelo predictivo y confirmar si el modelo seleccionado, junto con los ajustes hechos, es el mejor escenario para cada mes.

Los hallazgos en las reuniones ayudan a confirmar la selección del modelo predictivo para el proyecto y, en caso de cambios en la tendencia, estacionalidades o incluso el producto del cliente, evaluar si un nuevo modelo predictivo es mejor modelando estos cambios. Para facilitar la revisión, se crea una plantilla de Excel (apéndice 3) para estas reuniones periódicas, que se llena con los resultados, como las tablas representadas en la siguiente figura:

Figura 5.24: Ejemplo de las tablas en la plantilla de control de las reuniones periódicas



Pronósticos de llamadas de los Modelos Predictivos

Fecha	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings	Datos Reales
	171 935	173 506	171 215	173 920	201 401	172 235	146 457
miércoles 01	6 520	6 660	5 922	6 412	7 243	6 520	1475
jueves 02	6 084	6 336	5 708	5 945	6 653	6 084	6259
viernes 03	6 159	6 148	7 341	6 047	6 481	6 159	5330
sábado 04	3 274	3 099	3 814	3 216	3 431	3 274	2972
domingo 05	1 642	1 891	1 959	2 381	3 610	1 942	1521
lunes 06	7 325	7 327	7 341	7 807	9 513	7 325	6868
martes 07	7 068	7 116	6 509	7 070	8 325	7 068	5471
miércoles 08	6 519	6 660	6 922	6 412	7 243	6 519	5499
jueves 09	6 084	6 363	5 708	5 945	6 653	6 084	5291
viernes 10	6 159	6 148	5 808	6 047	6 481	6 159	5384
sábado 11	3 274	3 099	3 814	3 216	3 431	3 274	2545
domingo 12	1 942	1 891	1 959	2 381	3 610	1 942	1300
lunes 13	7 325	7 327	7 341	7 807	9 513	7 325	6713
martes 14	7 067	7 116	6 509	7 070	8 325	7 067	6331
miércoles 15	6 519	6 660	6 922	6 412	7 243	6 519	6419
jueves 16	6 083	6 336	5 708	5 945	6 653	6 083	5631
viernes 17	6 158	6 148	5 808	6 047	6 481	6 158	5450
sábado 18	3 274	3 099	3 814	3 216	3 431	3 274	2780
domingo 19	1 942	1 891	1 959	2 381	3 610	1 942	1778
lunes 20	7 324	7 327	7 341	7 808	9 513	7 324	6205
martes 21	7 067	7 116	6 509	7 070	8 325	7 067	6286
miércoles 22	6 519	6 660	6 922	6 413	7 243	6 519	5457
jueves 23	6 083	6 363	5 708	5 945	6 653	6 083	5162
viernes 24	6 158	6 148	5 808	6 047	6 481	6 158	5150
sábado 25	3 275	3 099	3 814	3 216	3 431	3 275	2325
domingo 26	1 942	1 891	1 959	2 381	3 610	1 942	1391
lunes 27	7 324	7 327	7 341	7 808	9 513	7 324	5859
martes 28	7 066	7 116	6 509	7 070	8 325	7 066	5387
miércoles 29	6 518	6 660	6 922	6 413	7 243	6 518	5816
jueves 30	6 083	6 336	5 708	5 945	6 653	6 083	5859
viernes 31	6 158	6 148	5 808	6 047	6 481	6 158	6543

Resultados de los Modelos Predictivos

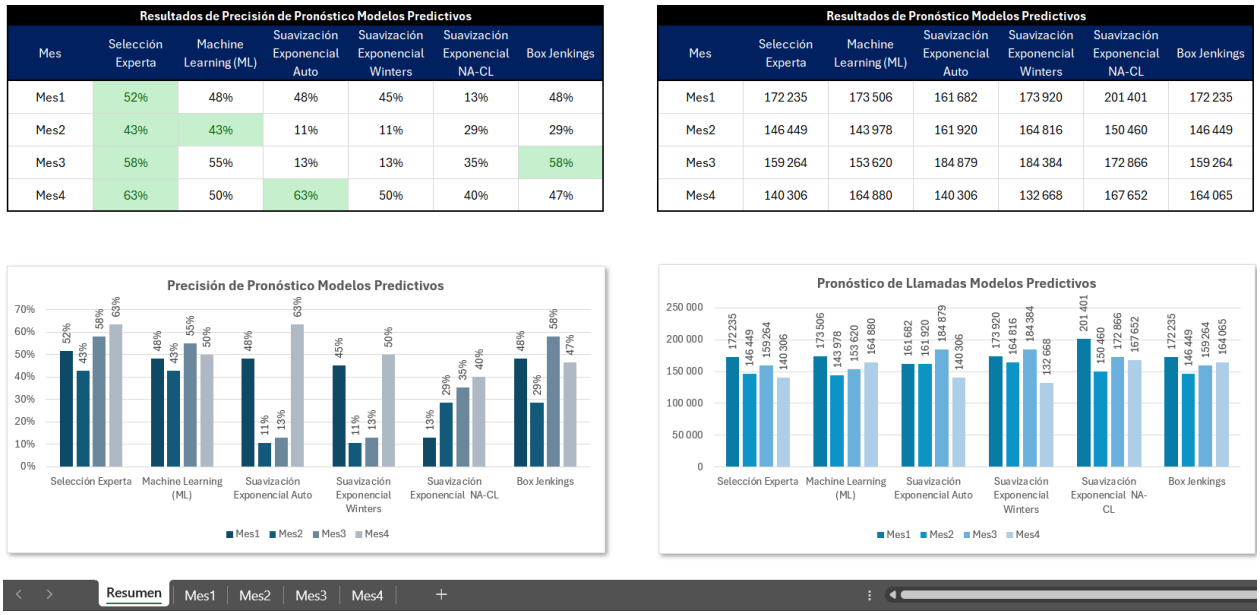
Fecha	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings
	52%	48%	48%	45%	13%	48%
miércoles 01	442%	452%	401%	435%	491%	442%
jueves 02	97%	101%	91%	95%	106%	97%
viernes 03	116%	115%	138%	113%	122%	116%
sábado 04	110%	104%	128%	108%	115%	110%
domingo 05	108%	124%	129%	157%	237%	128%
lunes 06	107%	107%	107%	114%	139%	107%
martes 07	129%	130%	119%	129%	152%	129%
miércoles 08	119%	121%	126%	117%	132%	119%
jueves 09	115%	120%	108%	112%	126%	115%
viernes 10	114%	114%	108%	112%	120%	114%
sábado 11	129%	122%	150%	126%	135%	129%
domingo 12	149%	145%	151%	183%	278%	149%
lunes 13	109%	109%	109%	116%	142%	109%
martes 14	112%	112%	103%	112%	131%	112%
miércoles 15	102%	104%	108%	100%	113%	102%
jueves 16	108%	113%	101%	106%	118%	108%
viernes 17	113%	113%	107%	111%	119%	113%
sábado 18	118%	111%	137%	116%	123%	118%
domingo 19	109%	106%	110%	134%	203%	109%
lunes 20	118%	118%	118%	126%	153%	118%
martes 21	112%	113%	104%	112%	132%	112%
miércoles 22	119%	122%	127%	118%	133%	119%
jueves 23	118%	123%	111%	115%	129%	118%
viernes 24	120%	119%	113%	117%	126%	120%
sábado 25	141%	133%	164%	138%	148%	141%
domingo 26	140%	136%	141%	171%	260%	140%
lunes 27	125%	125%	125%	133%	162%	125%
martes 28	131%	132%	121%	131%	155%	131%
miércoles 29	112%	115%	119%	110%	125%	112%
jueves 30	104%	108%	97%	101%	114%	104%
viernes 31	94%	94%	89%	92%	99%	94%

*Datos con fines ilustrativos

Fuente: Elaboración propia, 2025.

Esta información sirve para el cálculo en la Hoja de Resumen, la cual funciona como apoyo durante la reunión en la que se analizan los resultados obtenidos y la continuidad del modelo predictivo seleccionado: si continúa siendo el de mejor desempeño o, en caso de no ser así, si debe hacerse el respectivo cambio por otro modelo.

Figura 5.25: Ejemplo de las tablas en la plantilla de control de las reuniones periódicas



Resultados de Precisión de Pronóstico Modelos Predictivos

Mes	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings
Mes1	52%	48%	48%	45%	13%	48%
Mes2	43%	43%	11%	11%	29%	29%
Mes3	58%	55%	13%	13%	35%	58%
Mes4	63%	50%	63%	50%	40%	47%

Resultados de Pronóstico Modelos Predictivos

Mes	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings
Mes1	172 235	173 506	161 682	173 920	201 401	172 235
Mes2	146 449	143 978	161 920	164 816	150 460	146 449
Mes3	159 264	153 620	184 879	184 384	172 866	159 264
Mes4	140 306	164 880	140 306	132 668	167 652	164 065

*Datos con fines ilustrativos

Fuente: Elaboración propia, 2025.

5.3 RENTABILIDAD DE LAS SOLUCIONES

Con el objetivo de evaluar el impacto económico de la implementación del nuevo método, se determina el ROI a partir de los cálculos hechos sobre el periodo histórico comprendido desde julio 2024 hasta junio 2025, bajo el supuesto de que si se hubiera utilizado solo un modelo como el de selección experta, se hubieran reducido las pérdidas para este periodo de 12 meses en **$ 40 187**.

En cuestión de la inversión, para este caso se contemplan las horas profesionales invertidas, las mismas son un total de 96 horas con un valor de referencia sobre el salario del analista de **$ 693** en la creación del nuevo modelo y los costos asociados a las horas por invertir en la implementación, las cuales se proyectan en 7 horas con un valor de referencia sobre el salario del analista de **$ 51.**

Fórmula utilizada

$$ROI = \frac{Ganacia\ -\ Inversión}{Inversión}$$

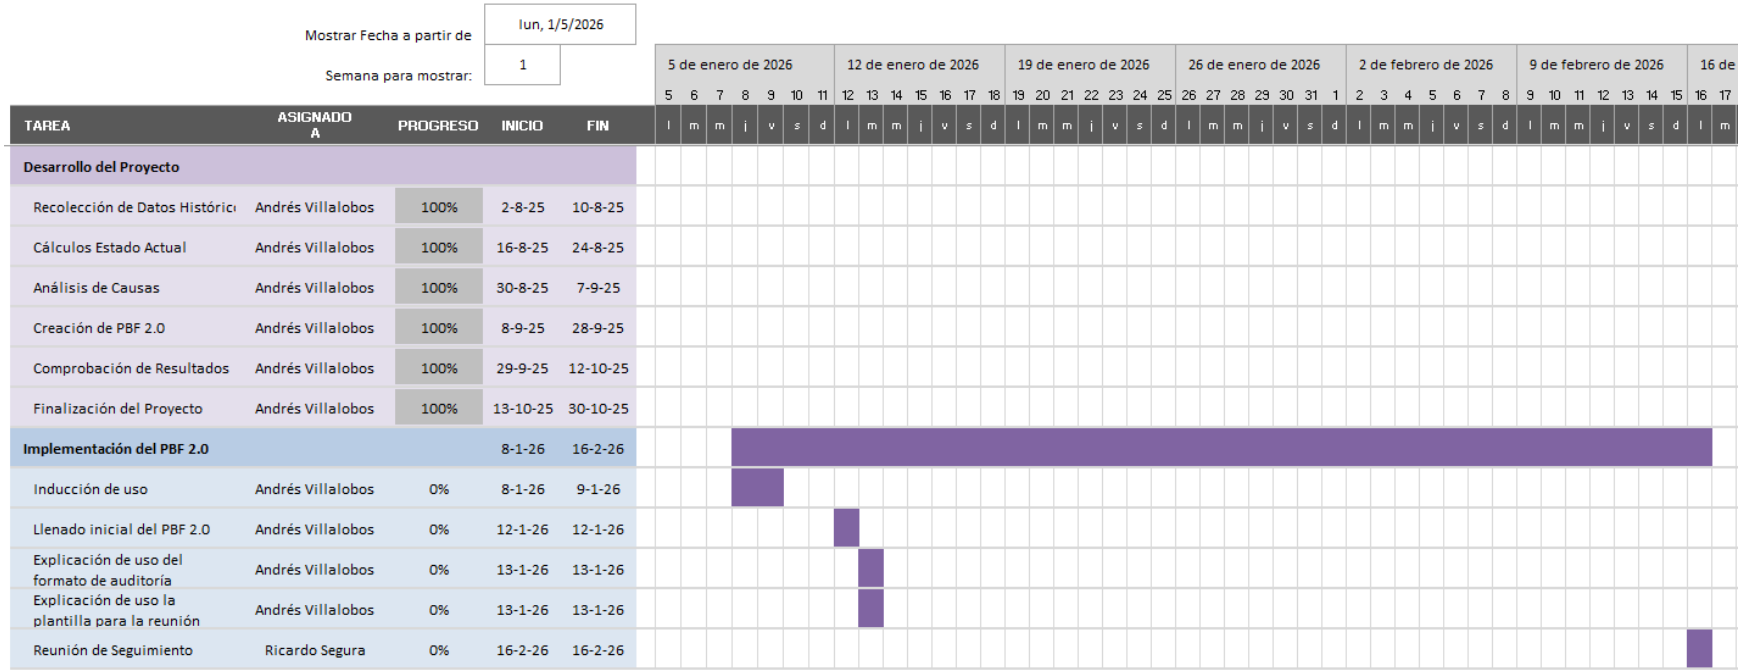
$$ROI = \frac{\$40\ 187\ -\ (693 + 51)}{(693 + 51)}$$

$$ROI = 53$$

Se establece que el ROI es de 53 sobre la ganancia para el periodo evaluado de los 12 meses:

5.3.1 Diagrama de Gantt

Figura 5.26: Diagrama de Gantt del desarrollo del proyecto e implementación



Mostrar Fecha a partir de: lun, 1/5/2026

Semana para mostrar: 1

TAREA	ASIGNADO A	PROGRESO	INICIO	FIN
Desarrollo del Proyecto				
Recolección de Datos Históric	Andrés Villalobos	100%	2-8-25	10-8-25
Cálculos Estado Actual	Andrés Villalobos	100%	16-8-25	24-8-25
Análisis de Causas	Andrés Villalobos	100%	30-8-25	7-9-25
Creación de PBF 2.0	Andrés Villalobos	100%	8-9-25	28-9-25
Comprobación de Resultados	Andrés Villalobos	100%	29-9-25	12-10-25
Finalización del Proyecto	Andrés Villalobos	100%	13-10-25	30-10-25
Implementación del PBF 2.0			8-1-26	16-2-26
Inducción de uso	Andrés Villalobos	0%	8-1-26	9-1-26
Llenado inicial del PBF 2.0	Andrés Villalobos	0%	12-1-26	12-1-26
Explicación de uso del formato de auditoría	Andrés Villalobos	0%	13-1-26	13-1-26
Explicación de uso la plantilla para la reunión	Andrés Villalobos	0%	13-1-26	13-1-26
Reunión de Seguimiento	Ricardo Segura	0%	16-2-26	16-2-26

En el anterior diagrama de Gantt, se muestran las fases de desarrollo e implementación que conforman este proyecto. En la fase de **desarrollo**, se aprecian las etapas más importantes desde la recolección de datos hasta la finalización y entrega del documento escrito. Asimismo, en la segunda fase se describen las tareas de la **implementación del PBF 2.0**, estas comprenden desde la inducción de uso hasta la primera reunión de seguimiento.

CAPÍTULO VI. CONCLUSIONES Y RECOMENDACIONES

A continuación, se detallan las principales conclusiones y recomendaciones obtenidas en el desarrollo del presente estudio.

Conclusiones

- El análisis realizado permitió identificar que el método de selección de modelos predictivos presentaba deficiencias derivadas de la combinación de estos modelos, lo que aumentaba el error de presión del pronóstico de llamadas y afectaba la planeación del personal. El cumplimiento de este método alcanzó la meta de EPP en solo 7 de los 12 meses, es decir, un 58 % de los meses en el periodo de estudio.

- La aplicación de la metodología DMAIC facilitó, mediante las herramientas utilizadas, la medición y el análisis del método actual, así como la identificación de las causas por medio de la combinación de la lluvia de ideas y el diagrama de Ishikawa. A su vez, mediante el multivoto y Pareto, fue posible asignarles el peso correspondiente para determinar las causas por trabajar. Esto ayudó a diseñar un nuevo método estandarizado con la integración de parámetros estadísticos que mejoraron la precisión del pronóstico en 8 de los 12 meses, cumpliendo la meta en 9 de los 12 meses, o sea, un 75 %.

- El desarrollo e implementación del PBF 2.0 permitió seleccionar un solo modelo e incorporar mejoras como parámetros estadísticos, para de este modo lograr una disminución del error de pronóstico y una mejora en la consistencia de los resultados, obteniendo un ahorro de **$ 40 187** si se hubiera aplicado este nuevo modelo.

- Las herramientas de control propuestas, como las auditorías internas y las reuniones periódicas, garantizan la continuidad del proceso y la verificación de los resultados a lo largo del tiempo; asimismo, aportan insumos para la toma de decisiones informadas y la aplicación de un plan de mejora continua que posibilite mejores resultados.

- La estandarización y el control de versiones, además de permitir posteriores análisis, funcionan como respaldo y evidencia para las certificaciones a las que se expone la empresa, como la auditada por COPC e ISO (Organización Internacional de Normalización).

- Se cumplió el objetivo general del estudio al optimizar el método de selección del modelo predictivo de llamadas mediante la aplicación de herramientas estadísticas y metodologías que fortalecen la gestión del pronóstico dentro del Departamento de WFM, lo que aumentó el cumplimiento en un 17 % y pasó de un 58 % en los meses evaluados a un 75 % en cumplimiento.

Recomendaciones

- Continuar con la capacitación del personal de WFM en temas relacionados al modelado de datos y análisis estadístico aplicado al pronóstico.

- Buscar capacitaciones externas que permitan explotar todas las funciones y lograr un uso experto de la herramienta Forecast PRO.

- Considerar el uso de herramientas de modelado de datos como R Studio y Phyton para realizar y evaluar la etapa de entrenamiento y pronóstico en un solo entorno.

- Considerar con el Departamento de Desarrollo la creación de una herramienta web que posibilite sustituir el uso de Excel, con la intención de estandarizar aún más el proceso, mejorar la versatilidad e incluir restricciones.

- Evaluar, en futuras fases de implementación, herramientas de pronóstico e inclusiones de modelos de inteligencia artificial como PROPHET, que mejoren la precisión del pronóstico.

REFERENCIAS

Libros

Ander-Egg, E. (2002). *Cómo hacer reuniones eficaces*. Editorial CCS.

Barrantes, R. (2014). *Investigación: un camino al conocimiento. Un enfoque cualitativo, cuantitativo y mixto*. EUNED.

Bernal, C. (2010). *Metodología de la investigación: administración, economía, humanidades y ciencias sociales*. Pearson Educación.

Cuatrecasas, L. (2010). *Gestión integral de la calidad: implantación, control y certificación.* Profit.

Gallardo, E. (2017). *Metodología de la investigación.* Universidad Continental.

Gutiérrez, H. y De la Vara, R. (2009). *Control estadístico de calidad y seis sigma.* McGraw Hill.

Hanke, J. y Wichern, D. (2010). *Pronósticos en los negocios*. (9° ed.). Pearson Educación.

Hernández, R., Fernández, C. y Baptista, M. (2014). *Metodologías de la investigación.* (6° ed.). McGraw Hill.

Herrara, R. J. y Fontalvo, T. J. (2011). *Seis sigma métodos estadísticos y sus aplicaciones.* EUMED. https://biblioteca.utec.edu.sv/siab/virtual/elibros_internet/55821.pdf

Instituto Uruguayo de Normas Técnicas. (2009). *Herramientas para la mejora de la calidad*. Instituto Uruguayo de Normas Técnicas.

Marqués, M. (2011). *Bases de datos.* Universitat Jaume.

Molina, Z. (1997). *Planeamiento didáctico: fundamentos, principios, estrategias y procedimientos para su desarrollo*. EUNED.

Proyectos de investigación

Alán, K., Delgado, S. y González, R. (2022). *Diseño de un sistema de planificación y control de inventario del Grupo CIISA Food Service* [Proyecto de graduación de licenciatura, Universidad de Costa Rica]. https://repositorio.sibdi.ucr.ac.cr/server/api/core/bitstreams/79557b8e-336b-4521-85ee-47a173877886/content

Alfaro, C., Castro, O. y Solano, C. (2019). *Rediseño del sistema de planificación y control de la producción del área de premezclas de la empresa Laboratorios Faryvet S. A.* [Tesis de licenciatura, Universidad de Costa Rica]. https://repositorio.sibdi.ucr.ac.cr/items/52b1e47d-8be7-47b8-9d09-8e6a8595ba76

Alfaro, J. D. y Rodríguez, A. Z. (2017). *Rediseño del sistema de administración de la cadena de suministro interna de la empresa ALRO* [Proyecto de graduación de licenciatura, Universidad de Costa Rica]. https://repositorio.sibdi.ucr.ac.cr/server/api/core/bitstreams/9818f3e3-f265-4b4c-899d-5cf34d85041e/content

Altuna, L. y Alva, I. (2018). *Lead time y su influencia en el nivel de servicio de las empresas de servicio de entrega rápida para las importaciones de Estados Unidos*. [Trabajo de graduación de Negocios Internacionales, Universidad Peruana de Ciencias Aplicadas]. Repositorio de la Universidad Peruana de Ciencias Aplicadas.

Blandón, J. (2017). *Disminución del tiempo de ensamble del cuello de botella en las líneas de producción de fórceps*. [Trabajo de graduación de Ingeniería Industrial, Universidad Central]. Repositorio de la Universidad Central.

Castillo, M., Claro, L. y Majluf, M. (2018). *Diseño de un sistema de planificación de la demanda y del inventario en Distribuidora del Caribe S. A.* [Proyecto de graduación de licenciatura, Universidad de Costa Rica]. https://repositorio.sibdi.ucr.ac.cr/bitstreams/78c449bc-2881-48ed-b21b-b1490ab02f68/download

Castro, J. (2020). *Modelo de pronósticos* [Trabajo de ingeniería, Universidad Técnica del Norte]. https://repositorio.utn.edu.ec/handle/123456789/11553

Guerrero, J., Vargas, M. y Zoch, R. (2019). *Rediseño de los procesos de planificación y administración de inventarios del CEDI Metropolitano de la empresa Cargill* [Proyecto de graduación de licenciatura, Universidad de Costa Rica]. https://kimuk.conare.ac.cr/Record/KUCR_9750f13fd892266fdec06e79c65e1a55?lng=tr

Handl, K. A. (2014). *Aplicación práctica del diagrama de Gantt en la administración de un proyecto* [Trabajo final de licenciatura, Universidad Nacional de Tucumán]. https://face.unt.edu.ar/web/iadmin/wp-content/uploads/sites/2/2014/12/Aplicaci%C3%B3n-pr%C3%A1ctica-Diagrama-de-Gantt-para-Jornada-IA-Handl.pdf

Montenegro, C. L. A. (2019). *Evaluación de métodos de pronósticos para predecir las ventas de los productos de la línea cardiológica de la Botica San Carlos* [Tesis de licenciatura, Universidad Técnica del Norte]. https://alicia.concytec.gob.pe/vufind/Record/USAT_758195d7f9a43d5adf39efb8763902b3/Details

Peña, J. A. (2020). *Pronósticos con algoritmos de aprendizaje automático. Estudio comparativo* [Tesis de Ingeniería Industrial, Universidad Nacional Autónoma de México].

http://www.ptolomeo.unam.mx:8080/jspui/bitstream/132.248.52.100/17444/6/Portada.pdf

Rabanales, M. R. (2016). *Diseño de la investigación del desarrollo de un modelo de pronósticos por medio del método ABC para la reducción de merma por daño de productos cárnicos en un supermercado*. [Trabajo de graduación de Ingeniería Industrial, Universidad de San Carlos de Guatemala]. http://biblioteca.usac.edu.gt/tesis/08/08_3334_IN.pdf

Torres, A. (2015). *Teoría de pronósticos y modelos de inventario aplicados en el consumo de papel para la impresión de un periódico* [Tesis de Ingeniería Industrial, Universidad Nacional Autónoma de México]. https://tesiunamdocumentos.dgb.unam.mx/ptd2015/octubre/0736794/0736794.pdf

Fuentes de Internet

Acuña, A. P. (2012). *La gestión de los stakeholders. Análisis de los diferentes modelos*. https://www.fundacionseres.org/lists/informes/attachments/1064/la%20gesti%C3%B3n%20de%20los%20stakeholders.%20an%C3%A1lisis%20de%20los%20diferentes%20modelos.pdf

Aguilar, M. (2006). El mapa conceptual: una herramienta para aprender y enseñar. *Plasticidad y Restauración Neurológica, 5*(1). https://www.medigraphic.com/pdfs/plasticidad/prn-2006/prn061b.pdf

Alfaro, F. (s.f.). *Matriz de decisiones*. http://fcaenlinea1.unam.mx/anexos/1624/1624_u9_Matriz_de_decisiones.pdf

American Society for Quality. (2025). *What is a fishbone diagram?* https://asq.org/quality-resources/fishbone?srsltid=AfmBOor3QZfvCMaPLAqUygpGJVm4ip3J0sl0zTRka8BdKsake5DyEkvW

Araújo, P. (2011). "Universidades lean": contribución para la reflexión. *Revista de la Educación Superior, XL(4)*(160), 135-155. https://www.redalyc.org/pdf/604/60422569007.pdf

Arce, S. (2013). *Guía taller: acta de constitución del proyecto*. https://repository.unipiloto.edu.co/bitstream/handle/20.500.12277/6975/01%20ACTA%20DE%20CONSTITUCION%20QUAD.pdf?sequence=10&isAllowed=y

Consejo Nacional de Evaluación de la Política de Desarrollo Social. (2014). *Manual para el diseño y la construcción de indicadores. Instrumentos principales para el monitoreo de programas sociales de México*. https://www.coneval.org.mx/Informes/Coordinacion/Publicaciones%20oficiales/MANUAL_PARA_EL_DISENO_Y_CONTRUCCION_DE_INDICADORES.pdf

Frechin, M. (2015). *Crónicas por equipos 2015 estadísticas.* https://ceipmarcosfrechinchess.wordpress.com/2015/04/

García, S. y Sánchez, F. (2021). *Guía para la elaboración de manuales de procedimientos del ITCR.* TEC. https://www.tec.ac.cr/sites/default/files/media/doc/gaceta_no._716-2020_0.pdf

Hayes, D. S. (2000). Evaluation and application of a project charter template to improve the project planning process. *Project Management Journal, 31*(1), 14–23. https://www.pmi.org/learning/library/project-charter-template-improving-planning-process-1986

Hermida, M., Menestrina, B. y Giosso, L. (2014). *Multivotación o voto múltiple*. https://blogs.ead.unlp.edu.ar/practicafarmaceutica/2014/08/21/multivotacion-o-voto-multiple/

Ingenieria de Software 3CV3. (2025). *Práctica 2.* https://ingenieria3cv3.wordpress.com/practicas/practica-2/

Kaizen Institute. (2025). *Comprender el diagrama de Ishikawa: una herramienta clave para el análisis de la causa raíz*. https://kaizen.com/es/insights-es/diagrama-ishikawa-analisis-causa-raiz/

Mauricio, J. A. (2007). *Introducción al análisis de series temporales.* https://www.ucm.es/data/cont/docs/518-2013-11-11-JAM-IAST-Libro.pdf

Mendoza, V. H. (s.f.). *Qué son los stakeholders y métodos para su análisis.* https://www.uaeh.edu.mx/divulgacion-ciencia/stakeholders-metodos/

Microsoft. (2025). *SharePoint Server 2019.* https://www.microsoft.com/es-es/microsoft-365/sharepoint/sharepoint-server

Minitab. (2025a). *Explicación de los cuadrados medios.* https://support.minitab.com/es-mx/minitab/help-and-how-to/statistical-modeling/anova/supporting-topics/anova-statistics/understanding-mean-squares/

Minitab. (2025b). *Interpretar los resultados clave para MARS®.* https://support.minitab.com/es-mx/minitab/help-and-how-to/statistical-modeling/predictive-analytics/how-to/mars-regression/interpret-the-results/key-results/

Minitab. (2025c). *Interpretar todos los estadísticos para regresión de los mejores subconjuntos.* https://support.minitab.com/es-mx/minitab/help-and-how-to/statistical-modeling/time-series/how-to/moving-average/interpret-the-results/all-statistics-and-graphs/

Minitab. (2025d). *Interpretar todos los estadísticos y gráficas para promedio móvil.* https://support.minitab.com/es-mx/minitab/help-and-how-to/statistical-modeling/regression/how-to/best-subsets-regression/interpret-the-results/all-statistics/

Minitab. (2025e). *¿Qué es el estadístico q de Ljung-Box (LBQ)?* https://support.minitab.com/es-mx/minitab/help-and-how-to/statistical-modeling/time-series/supporting-topics/diagnostic-checking/what-is-the-ljung-box-q-statistic/

Moreira, J. A. (2024). *Tormenta de ideas (brainstorming): la guía definitiva para generar soluciones innovadoras.* https://es.linkedin.com/pulse/tormenta-de-ideas-brainstorming-la-gu%C3%ADa-definitiva-moreira-d%C3%ADaz-q6koe

NETCOM. (2025). *Servicios.* https://www.netcom.com.pa/es/servicios

NUMXL. (2016). *MAPE-error medio de porcentaje absoluto.* https://support.numxl.com/hc/es/articles/215959443-MAPE-Error-medio-de-porcentaje-absoluto

NUMXL. (2017). *MASE–error de escala absoluta de media*. https://support.numxl.com/hc/es/articles/115001223523-MASE-Error-de-Escala-Absoluta-de-Media

Rodríguez, J. (2019). *5 porqués, ¿cómo aplicar correctamente esta metodología?* https://spcgroup.com.mx/5-porque-como-aplicar-correctamente-esta-metodologia/

Rodríguez, M. A., Terrazas, L. E. y Zorrilla, F. (2024). Estimación de demanda estudiantil en una institución educativa para calcular capacidad docente y aulas utilizando modelo de pronósticos. *Revista Iberoamericana para la Investigación y el*

Desarrollo Educativo, 14(28). https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-74672024000100612&lang=es

Santos, D. (2023). *Project charter: qué es, cómo crearlo y ejemplos*. https://blog.hubspot.es/marketing/project-charter

Secchi, M., Díaz, V. y Dubois, M. J. (2024). *Tormenta de ideas.* Instituto Nacional de Tecnología Industrial. https://www.laborando.com.ar/wp-content/uploads/tormenta-de-ideas.pdf

Socconini, L. (2025). *The lean six sigma DMAIC methodology explained*. https://leansixsigmainstitute.org/es/explicacion-de-la-metodologia-dmaic-de-lean-six-sigma/

Stellwagen, E. A. y Goodrich, R. L. (2017). *Forecast pro: statistical reference manual.* https://www.forecastpro.com/wp-content/uploads/2018/10/Forecast-Pro-Statistical-Reference-Manual.pdf

Stepanets, A. (2024). *La matriz de decisiones para hacer una selección acertada.* https://blog.ganttpro.com/es/matriz-de-decision/

Universidad Americana de Europa [UNADE]. (2025). *Diagrama de Ishikawa*: *herramienta clave para la identificación de causas*. https://unade.edu.mx/diagrama-de-ishikawa-herramienta-clave-para-la-identificacion-de-causas/

Villardefrancos, A. y Rivera, Z. (2006). La auditoría como proceso de control: concepto y tipología. *Ciencias de la Información, 37*(2-3), 53-59. https://www.redalyc.org/pdf/1814/181418190004.pdf

APÉNDICES Y ANEXOS

APÉNDICE 1: Glosario de términos

WFM: Departamento de Work Force Management (Gestión de la Fuerza Laboral), encargado de los aspectos estadísticos, cálculos de dimensionamiento, capacidad, proyecciones, horarios, entre otras funciones.

***Burnout*:** Estado de agotamiento físico, emocional y mental causado por el estrés laboral y que se manifiesta en fatiga, desmotivación y una disminución en la eficacia profesional.

Vertical: Segmento especializado dentro de un sector industrial más amplio.

***Inbound*:** Segmento especializado en las interacciones entrantes como atención de llamadas, chats, correos, entre otros.

***Outbound*:** Segmento especializado en las interacciones salientes como ventas, cobros o campañas informativas.

IVR: Respuesta de voz interactiva, son las grabaciones de voz que se escuchan en los centros de llamadas.

***Text to speech*:** Conversión de las llamadas a texto.

Tableau: Plataforma de inteligencia de negocios y análisis de datos.

PBF: Archivo de Excel en el cual se realiza el cálculo del EPP y la selección del mejor modelo predictivo por día.

Staffing: Archivo de Excel en el que se efectúa el dimensionamiento de personal mediante la teoría de colas de Erlang.

Nivel de servicio: Cantidad de llamadas contestadas antes del umbral.

Umbral de servicio: Umbral de tiempo en segundos para contabilizar el nivel de servicio (20 segundos para el Proyecto Banco).

Tasa de respuesta: Cantidad de llamadas contestadas.

Outliers: Valor atípico en un conjunto de datos.

EPP: Error de precisión del pronóstico.

MAD: *Mean absolute deviation* o desviación absoluta media. Mide el promedio de las diferencias absolutas entre los valores pronosticados y los reales. Indica en promedio cuánto se desvía el modelo del valor observado.

MAPE: *Mean absolute percentage error* o error porcentual absoluto medio. Mide el error promedio del pronóstico en términos porcentuales. Permite interpretar el error relativo al valor real.

RMSE: *Root mean squared error* o raíz del error cuadrático medio. Calcula la raíz cuadrada del promedio de los errores al cuadrado. Penaliza con más fuerza los errores grandes, por lo que es útil cuando existen desviaciones significativas.

R^2: Coeficiente de determinación. Indica qué proporción de la variabilidad de los datos reales puede explicarse por medio del modelo. Sus valores van de 0 a 1, donde 1 significa una predicción perfecta y 0 indica que el modelo no explica la variación de los datos.

***Lower*:** Término que se refiere al límite inferior de un rango de datos.

***Upper*:** Término que se refiere al límite inferior de un rango de datos.

APÉNDICE 2: Auditoría interna PBF 2.0

Departamento Workforce Management
Responsable de la auditoría: _____
Fecha de la auditoría: ___/___/_____
Periodo evaluado: _____

1. Objetivo de la auditoría

Verificar el cumplimiento del procedimiento de control y almacenamiento del PBF asegurando que se encuentre completo, en el repositorio correcto, y aplicando los estándares definidos.

2. Lista de verificación

Elemento por evaluar	Cumple	Observaciones
PBF ubicado en la carpeta correspondiente	☐ Sí ☐ No	
PBF nombrado con el formato correcto	☐ Sí ☐ No	
PBF completo con todos los datos requeridos	☐ Sí ☐ No	
Resultados disponibles para revisión	☐ Sí ☐ No	
Consistencia entre los datos del PBF y el Staffing	☐ Sí ☐ No	
Registros de hallazgos o acciones de auditorías anteriores	☐ Sí ☐ No	

3. Hallazgos y observaciones

_____
_____
_____

4. Acciones preventivas o correctivas

Descripción de la acción	Responsable	Fecha del compromiso

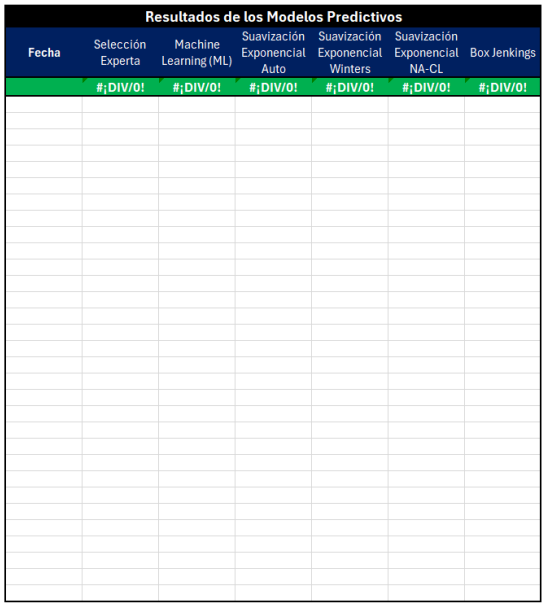
5. Conclusión de la auditoría

_____
_____
_____

APÉNDICE 3: Plantilla de Excel para la revisión de resultados en las reuniones periódicas

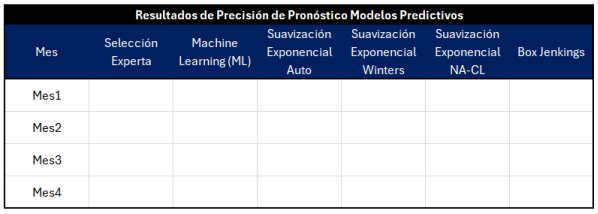


Pronósticos de llamadas de los Modelos Predictivos							
Fecha	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings	Datos Reales
	0	0	0	0	0	0	0

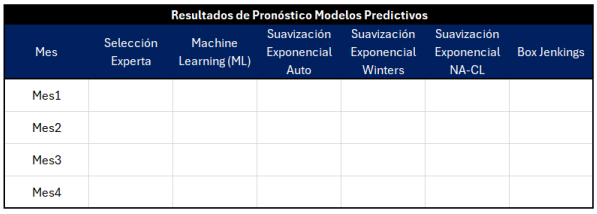


Resultados de los Modelos Predictivos						
Fecha	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings
	#¡DIV/0!	#¡DIV/0!	#¡DIV/0!	#¡DIV/0!	#¡DIV/0!	#¡DIV/0!

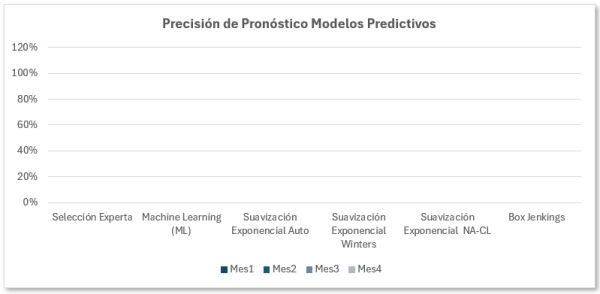


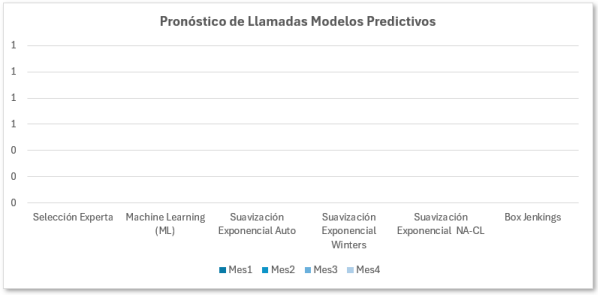


Resultados de Precisión de Pronóstico Modelos Predictivos						
Mes	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings
Mes1						
Mes2						
Mes3						
Mes4						



Resultados de Pronóstico Modelos Predictivos						
Mes	Selección Experta	Machine Learning (ML)	Suavización Exponencial Auto	Suavización Exponencial Winters	Suavización Exponencial NA-CL	Box Jenkings
Mes1						
Mes2						
Mes3						
Mes4						





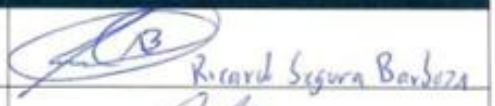


APÉNDICE 4: Multivoto

Multivoto **2/9/2025**

Objetivo: La multivotación tiene como objetivo asignar un peso a las causas identificadas en el diagrama Ishikawa para posteriormente aplicar la regla de Pareto

Participantes

Participantes	Nombre	Asistencia
1	Ricardo Segura	
2	Andrés Villalobos	
3	Mauricio Vargas	
4	Francisco Gonzalez	

La votación se tipificó en un documento de Excel, como lo representa la siguiente imagen:

Total	100	100	100	100	400
Subcausas	Participant	Participant	Participant	Participant	Total
Capacitación limitada	5	1	5	5	**16**
Desconocimiento de métricas estadísticas	5	1	5	2	**13**
Ausencia de Métricas	30	1	15	50	**96**
Calculo Económico del EPP poco Frecuente	1	1	5	4	**11**
Falta de Reporte en Tableau	1	1	1	4	**7**
Ciclo de Pronóstico	1	1	1	5	**8**
Periodicidad de Pronóstico	1	1	3	5	**10**
Combinación de Modelos Estadísticos	30	70	20	10	**130**
Selección de Modelo basada en EPP	25	20	40	10	**95**
Procesos manuales en Excel	1	3	5	5	**14**

ANEXO 1: Registro histórico, julio 2024

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/7/2024	Machine Learning	Información Confidencial		6449	7679	7584	7612	8193	6449
2/7/2024	Suavización NA-CL			6719	6828	7551	7542	8231	6719
3/7/2024	Suavización NA-CL			6527	6889	7292	7289	8149	6527
4/7/2024	Suavización NA-CL			6428	6889	7066	7047	8201	6428
5/7/2024	Suavización NA-CL			6032	6824	6954	6958	7098	6032
6/7/2024	Selección Experta			3302	3623	3814	3795	3712	3302
7/7/2024	Selección Experta			1787	2118	1984	1971	2123	1787
8/7/2024	Suavización NA-CL			6448	7679	7584	7612	8193	6448
9/7/2024	Selección Experta			6718	6828	7551	7542	8231	6718
10/7/2024	Selección Experta			6526	6889	7292	7289	8149	6526
11/7/2024	Selección Experta			6427	6889	7066	7047	8201	6427
12/7/2024	Selección Experta			6032	6824	6954	6958	7098	6032
13/7/2024	Selección Experta			3302	3623	3814	3795	3712	3302
14/7/2024	Selección Experta			1787	2118	1984	1971	2123	1787
15/7/2024	Selección Experta			6447	7679	7584	7612	8193	6447
16/7/2024	Selección Experta			6717	6828	7551	7542	8231	6717
17/7/2024	Selección Experta			6525	6889	7292	7289	8149	6525
18/7/2024	Selección Experta			6427	6889	7066	7047	8201	6427
19/7/2024	Suavización NA-CL			6031	6824	6954	6958	7098	6031
20/7/2024	Selección Experta			3303	3623	3814	3796	3712	3303
21/7/2024	Selección Experta			1788	2118	1984	1971	2123	1788
22/7/2024	Suavización NA-CL			6446	7679	7584	7612	8193	6446
23/7/2024	Selección Experta			6716	6828	7551	7542	8231	6716
24/7/2024	Selección Experta			6524	6889	7292	7289	8149	6524
25/7/2024	Selección Experta			6426	6889	7066	7047	8201	6426
26/7/2024	Selección Experta			6030	6824	6954	6958	7098	6030
27/7/2024	Selección Experta			3303	3623	3814	3796	3712	3303
28/7/2024	Selección Experta			1789	2118	1984	1972	2123	1789
29/7/2024	Selección Experta			6445	7679	7584	7612	8193	6445
30/7/2024	Selección Experta			6715	6828	7551	7542	8231	6715
31/7/2024	Suavización Exp Aut			6523	6889	7292	7289	8149	6523

Fuente: NETCOM, 2025.

ANEXO 2: Registro histórico, agosto 2024

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/8/2024	Selección Experta	Información Confidencial		6759	7082	7224	7266	8300	6759
2/8/2024	Suavización NA-CL			6173	7082	6694	6706	7163	6173
3/8/2024	Selección Experta			3405	3139	3660	3669	3737	3405
4/8/2024	Machine Learning			1886	1685	1990	1999	2145	1886
5/8/2024	Suavización NA-CL			6517	7082	7494	7501	8189	6517
6/8/2024	Selección Experta			6980	7082	7629	7668	8335	6980
7/8/2024	Selección Experta			6806	7082	7378	7415	8243	6806
8/8/2024	Selección Experta			6757	7082	7224	7266	8300	6757
9/8/2024	Selección Experta			6172	7082	6694	6706	7163	6172
10/8/2024	Machine Learning			3406	3139	3660	3669	3737	3406
11/8/2024	Machine Learning			1887	1685	1990	1999	2145	1887
12/8/2024	Selección Experta			6515	7082	7494	7502	8189	6515
13/8/2024	Selección Experta			6978	7082	7629	7668	8335	6978
14/8/2024	Selección Experta			6805	7082	7378	7415	8243	6805
15/8/2024	Selección Experta			6756	7082	7224	7267	8300	6756
16/8/2024	Suavización NA-CL			6171	7082	6694	6707	7163	6171
17/8/2024	Selección Experta			3407	3139	3660	3670	3737	3407
18/8/2024	Selección Experta			1888	1685	1990	2000	2145	1888
19/8/2024	Suavización NA-CL			6514	7082	7494	7502	8189	6514
20/8/2024	Selección Experta			6976	7082	7629	7669	8335	6976
21/8/2024	Selección Experta			6803	7082	7378	7416	8243	6803
22/8/2024	Selección Experta			6754	7082	7224	7267	8300	6754
23/8/2024	Selección Experta			6170	7082	6694	6707	7163	6170
24/8/2024	Machine Learning			3407	3139	3660	3670	3737	3407
25/8/2024	Machine Learning			1889	1685	1990	2000	2145	1889
26/8/2024	Selección Experta			6512	7082	7494	7503	8189	6512
27/8/2024	Selección Experta			6974	7082	7629	7669	8335	6974
28/8/2024	Selección Experta			6801	7082	7378	7416	8243	6801
29/8/2024	Selección Experta			6752	7082	7224	7268	8300	6752
30/8/2024	Selección Experta			6168	7082	6694	6707	7163	6168
31/8/2024	Machine Learning			3408	3139	3660	3670	3737	3408

Fuente: NETCOM, 2025.

ANEXO 3: Registro histórico, septiembre 2024

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/9/2024	Selección Experta	Información Confidencial		1890	1993	1990	2000	2145	1890
2/9/2024	Suavización NA-CL			6511	6529	7494	7503	8189	6511
3/9/2024	Machine Learning			6972	6435	7629	7670	8335	6972
4/9/2024	Machine Learning			6799	6419	7378	7417	8243	6799
5/9/2024	Machine Learning			6750	6419	7224	7268	8300	6750
6/9/2024	Selección Experta			6167	6151	6694	6708	7163	6167
7/9/2024	Selección Experta			3408	3477	3660	3670	3737	3408
8/9/2024	Selección Experta			1891	1993	1990	2000	2145	1891
9/9/2024	Machine Learning			6509	6529	7494	7504	8189	6509
10/9/2024	Machine Learning			6971	6435	7629	7670	8335	6971
11/9/2024	Machine Learning			6798	6419	7378	7417	8243	6798
12/9/2024	Selección Experta			6749	6419	7224	7269	8300	6749
13/9/2024	Suavización NA-CL			6166	6151	6694	6708	7163	6166
14/9/2024	Selección Experta			3409	3477	3660	3671	3737	3409
15/9/2024	Selección Experta			1892	1993	1990	2000	2145	1892
16/9/2024	Suavización NA-CL			6508	6529	7494	7504	8189	6508
17/9/2024	Machine Learning			6969	6435	7629	7671	8335	6969
18/9/2024	Machine Learning			6796	6419	7378	7418	8243	6796
19/9/2024	Machine Learning			6747	6419	7224	7269	8300	6747
20/9/2024	Selección Experta			6165	6151	6694	6709	7163	6165
21/9/2024	Selección Experta			3409	3477	3660	3671	3737	3409
22/9/2024	Selección Experta			1893	1993	1990	2000	2145	1893
23/9/2024	Machine Learning			6506	6529	7494	7505	8189	6506
24/9/2024	Selección Experta			6967	6435	7629	7671	8335	6967
25/9/2024	Machine Learning			6794	6419	7378	7418	8243	6794
26/9/2024	Machine Learning			6745	6419	7224	7270	8300	6745
27/9/2024	Selección Experta			6164	6151	6694	6709	7163	6164
28/9/2024	Machine Learning			3410	3477	3660	3671	3737	3410
29/9/2024	Machine Learning			1894	1993	1990	2000	2145	1894
30/9/2024	Selección Experta			6505	6529	7494	7505	8189	6505

Fuente: NETCOM, 2025.

ANEXO 4: Registro histórico, octubre 2024

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/10/2024	Selección Experta	Información Confidencial		6874	8869	8334	8809	7665	6874
2/10/2024	Selección Experta			6535	7634	7839	8291	6751	6535
3/10/2024	Machine Learning (4-180)			6177	7542	7502	7938	6257	6177
4/10/2024	Selección Experta			6075	7718	7480	7916	6626	6075
5/10/2024	Suavización NA-CL			3158	5118	3830	4057	3153	3158
6/10/2024	Selección Experta			1756	4927	2143	2270	1776	1756
7/10/2024	Machine Learning (4-180)			6484	9819	8194	8682	7101	6484
8/10/2024	Selección Experta			6873	8869	8334	8830	7665	6873
9/10/2024	Selección Experta			6534	7634	7839	8311	6751	6534
10/10/2024	Selección Experta			6176	7542	7502	7957	6257	6176
11/10/2024	Selección Experta			6075	7718	7480	7935	6626	6075
12/10/2024	Suavización NA-CL			3158	5118	3830	4067	3153	3158
13/10/2024	Selección Experta			1756	4927	2143	2276	1776	1756
14/10/2024	Selección Experta			6484	9819	8194	8703	7101	6484
15/10/2024	Selección Experta			6873	8869	8334	8852	7665	6873
16/10/2024	Selección Experta			6534	7634	7839	8331	6751	6534
17/10/2024	Selección Experta			6176	7542	7502	7976	6257	6176
18/10/2024	Suavización NA-CL			6074	7718	7480	7955	6626	6074
19/10/2024	Machine Learning (4-180)			3158	5118	3830	4077	3153	3158
20/10/2024	Selección Experta			1757	4927	2143	2281	1776	1757
21/10/2024	Selección Experta			6483	9819	8194	8724	7101	6483
22/10/2024	Selección Experta			6872	8869	8334	8873	7665	6872
23/10/2024	Selección Experta			6533	7634	7839	8351	6751	6533
24/10/2024	Selección Experta			6175	7542	7502	7995	6257	6175
25/10/2024	Selección Experta			6074	7718	7480	7974	6626	6074
26/10/2024	Suavización NA-CL			3158	5118	3830	4087	3153	3158
27/10/2024	Selección Experta			1757	4927	2143	2287	1776	1757
28/10/2024	Suavización NA-CL			6483	9819	8194	8745	7101	6483
29/10/2024	Selección Experta			6871	8869	8334	8894	7665	6871
30/10/2024	Selección Experta			6533	7634	7839	8371	6751	6533
31/10/2024	Selección Experta			6175	7542	7502	8014	6257	6175

Fuente: NETCOM, 2025.

ANEXO 5: Registro histórico, noviembre 2024

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/11/2024	Selección Experta	Información Confidencial		6074	7718	7480	7993	6626	6074
2/11/2024	Suavización NA-CL			3159	5118	3830	4097	3153	3159
3/11/2024	Selección Experta			1757	4927	2143	2292	1776	1757
4/11/2024	Machine Learning (4-180)			6482	9819	8194	8766	7101	6482
5/11/2024	Selección Experta			6871	8869	8334	8916	7665	6871
6/11/2024	Selección Experta			6532	7634	7839	8391	6751	6532
7/11/2024	Selección Experta			6175	7542	7502	8034	6257	6175
8/11/2024	Selección Experta			6073	7718	7480	8012	6626	6073
9/11/2024	Suavización NA-CL			3159	5118	3830	4106	3153	3159
10/11/2024	Selección Experta			1758	4927	2143	2298	1776	1758
11/11/2024	Selección Experta			6482	9819	8194	8787	7101	6482
12/11/2024	Selección Experta			6870	8869	8334	8937	7665	6870
13/11/2024	Selección Experta			6532	7634	7839	8411	6751	6532
14/11/2024	Selección Experta			6174	7542	7502	8053	6257	6174
15/11/2024	Suavización NA-CL			6073	7718	7480	8031	6626	6073
16/11/2024	Machine Learning (4-180)			3159	5118	3830	4116	3153	3159
17/11/2024	Selección Experta			1758	4927	2143	2303	1776	1758
18/11/2024	Selección Experta			6481	9819	8194	8808	7101	6481
19/11/2024	Selección Experta			6870	8869	8334	8958	7665	6870
20/11/2024	Selección Experta			6531	7634	7839	8431	6751	6531
21/11/2024	Selección Experta			6174	7542	7502	8072	6257	6174
22/11/2024	Selección Experta			6072	7718	7480	8050	6626	6072
23/11/2024	Suavización NA-CL			3159	5118	3830	4126	3153	3159
24/11/2024	Selección Experta			1758	4927	2143	2309	1776	1758
25/11/2024	Selección Experta			6481	9819	8194	8829	7101	6481
26/11/2024	Selección Experta			6869	8869	8334	8980	7665	6869
27/11/2024	Selección Experta			6531	7634	7839	8451	6751	6531
28/11/2024	Suavización Exp Aut			6173	7542	7502	8091	6257	6173
29/11/2024	Suavización Exp Aut			6072	7718	7480	8070	6626	6072
30/11/2024	Machine Learning (4-180)			3160	5118	3830	4136	3153	3160

Fuente: NETCOM, 2025.

ANEXO 6: Registro histórico, diciembre 2024

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/12/2024	Machine Learning (ML)	Información Confidencial		1894	1645	1946	1951	1705	1894
2/12/2024	Suavización Exp Aut			6567	6566	7512	7513	7059	6567
3/12/2024	Machine Learning (ML)			6827	5953	7492	7505	7107	6827
4/12/2024	Machine Learning (ML)			6295	5927	6812	6817	6381	6295
5/12/2024	Machine Learning (ML)			6336	5927	7067	708	6772	6336
6/12/2024	Machine Learning (ML)			6209	5927	6988	7005	667	6209
7/12/2024	Machine Learning (ML)			3331	2948	3483	3501	3382	3331
8/12/2024	Machine Learning (ML)			1896	1558	1946	1952	1705	1896
9/12/2024	Machine Learning (ML)			6564	6566	7512	7514	7059	6564
10/12/2024	Machine Learning (ML)			6824	5953	7492	7505	7107	6824
11/12/2024	Machine Learning (ML)			6293	5927	6812	6817	6381	6293
12/12/2024	Machine Learning (ML)			6333	5927	7067	708	6772	6333
13/12/2024	Suav Exp Winters			6207	5927	6988	7005	667	6207
14/12/2024	Machine Learning (ML)			3332	2948	3483	3501	3382	3332
15/12/2024	Suavización Exp Aut			1899	1683	1946	1952	1705	1899
16/12/2024	Suavización Exp Aut			6561	6566	7512	7514	7059	6561
17/12/2024	Suav Exp Winters			682	5953	7492	7505	7107	682
18/12/2024	Machine Learning (ML)			629	5927	6812	6817	6381	629
19/12/2024	Machine Learning (ML)			633	5927	7067	708	6772	633
20/12/2024	Selección Experta			6204	5927	6988	7005	667	6204
21/12/2024	Machine Learning (ML)			3334	2867	3483	3501	3382	3334
22/12/2024	Machine Learning (ML)			1902	1476	1946	1952	1705	1902
23/12/2024	Machine Learning (ML)			6558	6485	7512	7514	7059	6558
24/12/2024	Machine Learning (ML)			6817	6013	7492	7505	7107	6817
25/12/2024	Machine Learning (ML)			6288	5846	6812	6817	6381	6288
26/12/2024	Machine Learning (ML)			6328	5846	7067	708	6772	6328
27/12/2024	Suav Exp Winters			6202	5846	6988	7005	667	6202
28/12/2024	Suav Exp Winters			3336	2765	3483	3501	3382	3336
29/12/2024	Suav Exp Winters			1904	1438	1946	1952	1705	1904
30/12/2024	Machine Learning (ML)			6555	6274	7512	7514	7059	6555
31/12/2024	Machine Learning (ML)			6813	5802	7492	7505	7107	6813

Fuente: NETCOM, 2025.

ANEXO 7: Registro histórico, enero 2025

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/1/2025	Suav Exp Winters	Información Confidencial		6520	6660	5922	6412	7243	6520
2/1/2025	Machine Learning (ML)			6084	6336	5708	5945	6653	6084
3/1/2025	Box Jenkings			6159	6148	5808	6047	6481	6159
4/1/2025	Box Jenkings			3274	3099	2814	3216	3431	3274
5/1/2025	Box Jenkings			1942	1891	1959	2381	3610	1942
6/1/2025	Suav Exp Winters			7325	7327	7341	7807	9513	7325
7/1/2025	Selección Experta			7068	7116	6509	7070	8325	7068
8/1/2025	Selección Experta			6519	6660	5922	6412	7243	6519
9/1/2025	Selección Experta			6084	6363	5708	5945	6653	6084
10/1/2025	Selección Experta			6159	6148	5808	6047	6481	6159
11/1/2025	Box Jenkings			3274	3099	2814	3216	3431	3274
12/1/2025	Box Jenkings			1942	1891	1959	2381	3610	1942
13/1/2025	Box Jenkings			7325	7327	7341	7807	9513	7325
14/1/2025	Selección Experta			7067	7116	6509	7070	8325	7067
15/1/2025	Selección Experta			6519	6660	5922	6412	7243	6519
16/1/2025	Selección Experta			6083	6336	5708	5945	6653	6083
17/1/2025	Selección Experta			6158	6148	5808	6047	6481	6158
18/1/2025	Box Jenkings			3274	3099	2814	3216	3431	3274
19/1/2025	Box Jenkings			1942	1891	1959	2381	3610	1942
20/1/2025	Box Jenkings			7324	7327	7341	7808	9513	7324
21/1/2025	Selección Experta			7067	7116	6509	7070	8325	7067
22/1/2025	Selección Experta			6519	6660	5922	6413	7243	6519
23/1/2025	Selección Experta			6083	6363	5708	5945	6653	6083
24/1/2025	Box Jenkings			6158	6148	5808	6047	6481	6158
25/1/2025	Box Jenkings			3275	3099	2814	3216	3431	3275
26/1/2025	Box Jenkings			1942	1891	1959	2381	3610	1942
27/1/2025	Box Jenkings			7324	7327	7341	7808	9513	7324
28/1/2025	Selección Experta			7066	7116	6509	7070	8325	7066
29/1/2025	Machine Learning (ML)			6518	6660	5922	6413	7243	6518
30/1/2025	Selección Experta			6083	6336	5708	5945	6653	6083
31/1/2025	Machine Learning (ML)			6158	6148	5808	6047	6481	6158

Fuente: NETCOM, 2025.

ANEXO 8: Registro histórico, febrero 2025

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/2/2025	Machine Learning (ML)	Información Confidencial		3321	3104	3605	3666	3402	3321
2/2/2025	Machine Learning (ML)			1838	1691	1903	1935	1749	1838
3/2/2025	Suav Exp Winters			6932	6733	7437	7562	7325	6632
4/2/2025	Machine Learning (ML)			6599	6188	7206	7328	6817	6599
5/2/2025	Machine Learning (ML)			6184	6126	6830	6946	6267	6184
6/2/2025	Suavización NA-CL			5923	6126	6624	6737	5631	5923
7/2/2025	Machine Learning (ML)			6125	6126	6875	6993	6424	6125
8/2/2025	Machine Learning (ML)			3022	3104	3605	3668	3402	3322
9/2/2025	Machine Learning (ML)			1839	1691	1903	1937	1749	1839
10/2/2025	Machine Learning (ML)			6630	6733	7437	7566	7325	6630
11/2/2025	Machine Learning (ML)			6597	6188	7206	7332	6817	6597
12/2/2025	Machine Learning (ML)			6183	6031	6830	6950	6267	6183
13/2/2025	Selección Experta			5922	6126	6624	6741	5631	5922
14/2/2025	Suav Exp Winters			6123	6126	6875	6997	6424	6123
15/2/2025	Machine Learning (ML)			3323	3104	3605	3670	3402	3323
16/2/2025	Suav Exp Winters			1841	1691	1903	1938	1749	1841
17/2/2025	Suav Exp Winters			6627	6733	7437	7571	7325	6627
18/2/2025	Suav Exp Winters			6594	6188	7206	7337	6817	6594
19/2/2025	Selección Experta			6181	6126	6830	6954	6267	6181
20/2/2025	Suav Exp Winters			5921	6066	6624	6745	5631	5921
21/2/2025	Selección Experta			6122	6126	6875	7001	6424	6122
22/2/2025	Selección Experta			3324	3104	3605	3672	3402	3324
23/2/2025	Machine Learning (ML)			1843	1691	1903	1939	1749	1843
24/2/2025	Selección Experta			6625	6490	7437	7576	7325	6625
25/2/2025	Machine Learning (ML)			6592	6188	7206	7341	6817	6592
26/2/2025	Machine Learning (ML)			6179	6126	6830	6959	6267	6179
27/2/2025	Suav Exp Winters			5919	6126	6624	6749	5631	5919
28/2/2025	Machine Learning (ML)			6120	6126	6875	7006	6424	6120

Fuente: NETCOM, 2025.

ANEXO 9: Registro histórico, marzo 2025

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/3/2025	Suavización NA-CL	Información Confidencial		3254	2869	3822	3786	3333	3254
2/3/2025	Machine Learning (ML)			1782	1609	2040	2023	1964	1782
3/3/2025	Suavización NA-CL			6834	6677	7969	7969	8153	6834
4/3/2025	Selección Experta			6717	6040	7621	7620	7473	6717
5/3/2025	Machine Learning (ML)			6327	6040	7241	7232	6964	6327
6/3/2025	Suavización NA-CL			5870	6040	6869	6854	5731	5870
7/3/2025	Machine Learning (ML)			6068	6040	7200	7166	6236	6068
8/3/2025	Machine Learning (ML)			3254	2869	3822	3786	3333	3254
9/3/2025	Machine Learning (ML)			1782	1609	2040	2023	1964	1782
10/3/2025	Machine Learning (ML)			6833	6717	7969	7969	8153	6833
11/3/2025	Machine Learning (ML)			6717	6040	7621	7620	7473	6717
12/3/2025	Machine Learning (ML)			6327	6040	7241	7232	6964	6327
13/3/2025	Machine Learning (ML)			5869	6040	6869	6854	5731	5869
14/3/2025	Suavización NA-CL			6068	6040	7200	7166	6236	6068
15/3/2025	Suavización Exp Aut			3255	2869	3822	3786	3333	3255
16/3/2025	Selección Experta			1783	1609	2040	2023	1964	1783
17/3/2025	Machine Learning (ML)			6832	6602	7969	7970	8153	6832
18/3/2025	Selección Experta			6716	6040	7621	7620	7473	6716
19/3/2025	Machine Learning (ML)			6326	6040	7241	7233	6964	6326
20/3/2025	Selección Experta			5869	6040	6869	6854	5731	5869
21/3/2025	Selección Experta			6067	6040	7200	7166	6236	6067
22/3/2025	Suav Exp Winters			3255	2869	3822	3786	3333	3255
23/3/2025	Machine Learning (ML)			1784	1609	2040	2023	1964	1784
24/3/2025	Selección Experta			6831	6717	7969	7970	8153	6831
25/3/2025	Machine Learning (ML)			6715	6040	7621	7620	7473	6715
26/3/2025	Selección Experta			6325	6040	7241	7233	6964	6325
27/3/2025	Machine Learning (ML)			5868	6040	6869	6854	5731	5868
28/3/2025	Machine Learning (ML)			6067	6377	7200	7166	6236	6067
29/3/2025	Machine Learning (ML)			3255	3267	3822	3787	3333	3255
30/3/2025	Suavización Exp Aut			1784	2034	2040	2023	1964	1784
31/3/2025	Machine Learning (ML)			6830	6717	7969	7970	8153	6830

Fuente: NETCOM, 2025.

ANEXO 10: Registro histórico, abril 2025

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/4/2025	Suav Exp Winters	Información Confidencial		5795	6862	5795	5349	6701	6783
2/4/2025	Box Jenkings			5283	6703	5283	4809	5791	5938
3/4/2025	Selección Experta			5358	6239	5358	4998	6240	6148
4/4/2025	Box Jenkings			5517	6732	5517	5157	6475	6320
5/4/2025	Selección Experta			2449	4127	2449	2712	3459	3346
6/4/2025	Box Jenkings			1241	2118	1241	1611	2251	1919
7/4/2025	Box Jenkings			6664	7114	6664	6000	7873	7383
8/4/2025	Box Jenkings			5795	6357	5795	5349	6701	6782
9/4/2025	Box Jenkings			5283	6076	5283	4808	5791	5938
10/4/2025	Box Jenkings			5358	5940	5358	4997	6240	6148
11/4/2025	Box Jenkings			5517	6104	5517	5156	6475	6320
12/4/2025	Box Jenkings			2449	3128	2449	2711	3459	3346
13/4/2025	Box Jenkings			1241	1583	1241	1611	2251	1919
14/4/2025	Box Jenkings			6664	6536	6664	5999	7873	7383
15/4/2025	Box Jenkings			5795	7060	5795	5348	6701	6782
16/4/2025	Box Jenkings			5283	6688	5283	4807	5791	5938
17/4/2025	Box Jenkings			5358	6248	5358	4997	6240	6148
18/4/2025	Selección Experta			5517	6397	5517	5155	6475	6320
19/4/2025	Box Jenkings			2449	2978	2449	2711	3459	3346
20/4/2025	Box Jenkings			1241	1860	1241	1611	2251	1919
21/4/2025	Box Jenkings			6664	7708	6664	5998	7873	7383
22/4/2025	Box Jenkings			5795	6467	5795	5347	6701	6782
23/4/2025	Box Jenkings			5283	6164	5283	4807	5791	5938
24/4/2025	Box Jenkings			5358	5916	5358	4996	6240	6148
25/4/2025	Box Jenkings			5517	6088	5517	5154	6475	6320
26/4/2025	Selección Experta			2449	2937	2449	2710	3459	3346
27/4/2025	Box Jenkings			1241	1887	1241	1611	2251	1919
28/4/2025	Box Jenkings			6664	7499	6664	5997	7873	7383
29/4/2025	Box Jenkings			5795	6761	5795	5346	6701	6782
30/4/2025	Box Jenkings			5283	6603	5283	4806	5791	5938

Fuente: NETCOM, 2025.

ANEXO 11: Registro histórico, mayo 2025

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/5/2025	Machine Learning (ML)	Información Confidencial		5026	5573	5198	4481	5026	5683
2/5/2025	Machine Learning (ML)			5024	4905	5401	4694	5024	5775
3/5/2025	Machine Learning (ML)			2911	1622	2535	1584	2911	3233
4/5/2025	Selección Experta			1536	1075	1172	392	1536	1813
5/5/2025	Selección Experta			6574	6215	6463	5856	6574	6920
6/5/2025	Machine Learning (ML)			5879	5274	5681	4950	5879	6400
7/5/2025	Selección Experta			5476	5129	5243	4479	5476	5835
8/5/2025	Machine Learning (ML)			5026	5129	5198	4481	5026	5697
9/5/2025	Suavización Exp Aut			5024	5018	5401	4694	5024	5785
10/5/2025	Machine Learning (ML)			2911	1622	2535	1584	2911	3238
11/5/2025	Selección Experta			1536	1434	1172	392	1536	1816
12/5/2025	Suavización Exp Aut			6574	6215	6463	5856	6574	6922
13/5/2025	Machine Learning (ML)			5879	5274	5681	4950	5879	6401
14/5/2025	Suavización Exp Aut			5476	5129	5243	4479	5476	5835
15/5/2025	Machine Learning (ML)			5026	5129	5198	4481	5026	5697
16/5/2025	Suavización Exp Aut			5024	5018	5401	4694	5024	5784
17/5/2025	Machine Learning (ML)			2911	1622	2535	1584	2911	3239
18/5/2025	Machine Learning (ML)			1536	1075	1172	392	1536	1817
19/5/2025	Suavización Exp Aut			6574	6215	6463	5856	6574	6920
20/5/2025	Machine Learning (ML)			5879	5274	5681	4950	5879	6399
21/5/2025	Selección Experta			5476	5086	5243	4479	5476	5834
22/5/2025	Machine Learning (ML)			5026	5192	5198	4481	5026	5696
23/5/2025	Selección Experta			5024	5082	5401	4694	5024	5784
24/5/2025	Machine Learning (ML)			2911	1727	2535	1584	2911	3240
25/5/2025	Selección Experta			1536	1075	1172	392	1536	1818
26/5/2025	Suavización Exp Aut			6574	6160	6463	5856	6574	6918
27/5/2025	Suavización Exp Aut			5879	5274	5681	4950	5879	6398
28/5/2025	Machine Learning (ML)			5476	5129	5243	4479	5476	5833
29/5/2025	Machine Learning (ML)			5026	5129	5198	4481	5026	5696
30/5/2025	Selección Experta			5024	5129	5401	4694	5024	5783
31/5/2025	Selección Experta			2911	1622	2535	1584	2911	3241

Fuente: NETCOM, 2025.

ANEXO 12: Registro histórico, junio 2025

Fecha	Modelos Predictivos	Real	Combinado	Selección Experta	Machine Learning (ML)	Suavización Exponencial Automática	Suavización Exponencial Winters	Suavización NA-CL	Box Jenkings
1/6/2025	Machine Learning (ML)	Información Confidencial		1651	1652	1192	1217	1651	1859
2/6/2025	Selección Experta			6615	6525	6563	6587	6615	6954
3/6/2025	Machine Learning (ML)			5652	5875	5642	5666	5652	6044
4/6/2025	Selección Experta			5330	5673	5144	5170	5330	5353
5/6/2025	Machine Learning (ML)			5326	5673	5263	5289	5326	5673
6/6/2025	Machine Learning (ML)			5995	5673	5616	5645	5995	6072
7/6/2025	Suavización NA-CL			3254	2732	2610	2641	3254	3344
8/6/2025	Machine Learning (ML)			1651	1604	1192	1220	1651	1862
9/6/2025	Machine Learning (ML)			6615	6525	6563	6589	6615	6950
10/6/2025	Machine Learning (ML)			5652	5875	5642	5669	5652	6042
11/6/2025	Suavización Exp Aut			5330	5673	5144	5172	5330	5352
12/6/2025	Machine Learning (ML)			5326	5673	5263	5291	5326	5672
13/6/2025	Machine Learning (ML)			5995	5673	5616	5648	5995	6069
14/6/2025	Machine Learning (ML)			3254	2764	2610	2643	3254	3346
15/6/2025	Machine Learning (ML)			1651	1674	1192	1222	1651	1865
16/6/2025	Suavización Exp Aut			6615	6525	6563	6592	6615	6945
17/6/2025	Machine Learning (ML)			5652	5875	5642	5671	5652	6039
18/6/2025	Selección Experta			5330	5673	5144	5175	5330	5351
19/6/2025	Selección Experta			5326	5673	5263	5294	5326	5670
20/6/2025	Machine Learning (ML)			5995	5673	5616	5650	5995	6067
21/6/2025	Machine Learning (ML)			3254	2732	2610	2646	3254	3348
22/6/2025	Machine Learning (ML)			1651	1624	1192	1225	1651	1868
23/6/2025	Suav Exp Winters			6615	6525	6563	6594	6615	6941
24/6/2025	Suavización Exp Aut			5652	5875	5642	5674	5652	6037
25/6/2025	Selección Experta			5330	5673	5144	5177	5330	5350
26/6/2025	Machine Learning (ML)			5326	5673	5263	5296	5326	5669
27/6/2025	Machine Learning (ML)			5995	5673	5616	5653	5995	6065
28/6/2025	Machine Learning (ML)			3254	2813	2610	2648	3254	3350
29/6/2025	Selección Experta			1651	1643	1192	1227	1651	1871
30/6/2025	Box Jenkings			6615	6525	6563	6596	6615	6937

Fuente: NETCOM, 2025.