UAB
Universitat Autònoma de Barcelona

Un operador 3PL bajo el signo de la incertidumbre

Memoria del Trabajo Fin de Grado en Gestión Aeronáutica

realizado por

Alba Alguacil Piqué

y dirigido por

Aleksandar Jovanovic

Escuela de Ingeniería

Sabadell, Julio de 2026

El abajo firmante, Aleksandar Jovanovic director/a del Trabajo de Fin de Grado, profesor de la Escuela de Ingeniería de la UAB.

CERTIFICA:

Que el trabajo al que corresponde la presente memoria ha sido realizado bajo su dirección por

Alba Alguacil Piqué

Y para que conste firma la presente en Sabadell, Junio de 2026.

Firmado: Aleksandar Jovanovic

Índice

1. Introducción 8
1.1 La importancia del transporte 8
1.2 Planteamiento del problema 9
1.3 Objetivos 10
1.4 Propósito 11
2. Marco teórico 13
2.1 Operadores logísticos 3PL 13
2.1.1 Concepto y rol en la supply chain 13
2.1.2 Tipos de operadores logísticos 14
2.1.3 Funcionamiento operativo de un 3PL: tareas y flujo de mercancía 17
2.2 Planificación operativa en logística 19
2.2.1 Tipos de servicio 19
2.2.2 Planificación operativa basada en el volumen de actividad 23
2.2.3 Problemas habituales en entornos reales 26
2.3 Predicción de la demanda 29
2.3.1 Concepto y fundamentos 29
2.3.2 Importancia en la toma de decisiones 30
2.3.3 Limitaciones reales de hacer forecasting desde la perspectiva del operador 32
2.4 Analítica predictiva e inteligencia artificial 34
2.4.1 Tipos de herramientas y modelos 34
2.4.2 Fundamentos técnicos 39
2.4.3 Limitaciones y barreras de adopción 44
3. Caso específico: Clientes tipo tender 46
3.1 Características de los contratos tender 46
3.2 Información disponible vs. información real 48
3.3 De la limitación a la utilidad 52
4. Caso práctico y evaluación 54
4.1 Descripción del caso y datos utilizados 54
4.2 Propuesta metodológica 59
4.3 Resultados obtenidos 60
4.4 Comparación de métodos y evaluación de métodos de predicción 65
4.5 Limitaciones y líneas futuras 67
5. Conclusiones 69

5.1 Conclusiones principales 69
5.2 Respuesta a los objetivos 70
5.3 Implicaciones para el sector 72
Referencias 73
Anexos 76

Índice de figuras

Figura 1: Esquema de carga de un camión estándar…….....20

Figura 2: Gráficos de evolución mensual (2020-2025), número de expediciones entregadas por cliente…… 57

Figura 3: Gráficos comparativos entre el volumen contratado vs el volumen real entregado de los ocho clientes……58

Figura 4: Gráficos cliente 1. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo……62

Figura 5: Gráficos cliente 2. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo……...62

Figura 6: Gráficos cliente 3. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo……...63

Figura 7: Gráficos cliente 4. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo……...63

Figura 8: Gráficos cliente 5. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo…….....64

Figura 9: Gráficos cliente 6. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo……...64

Figura 10: Gráficos cliente 7. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo……...65

Figura 11: Gráficos cliente 8. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo……...65

Índice de tablas

Tabla 1: Tipos de operadores logísticos…….....16

Tabla 2: Tabla descriptiva de los campos de información de un RFQ……49

Tabla 3: Tabla comparativa entre la información ideal y la real……51

Tabla 4: Tabla descriptiva de los ocho clientes simulados……56

Tabla 5: Tabla comparativa de métrica de error: MAE, RMSE y MAPE……61

1. Introducción

1.1 La importancia del transporte

La importancia del transporte en la economía es incuestionable: la riqueza de los países y su crecimiento económico dependen en gran medida de él. Gran parte del funcionamiento de la cadena de suministro se basa en el movimiento de mercancías, ya sea por vía terrestre, marítima o aérea. En un mercado globalizado y en una sociedad cada vez más orientada al consumo inmediato, la capacidad de mover mercancía de forma rápida, eficiente y coordinada resulta imprescindible. A simple vista, gestionar el proceso de un solo producto puede parecer sencillo, pero la verdadera complejidad reside en coordinar simultáneamente miles de operaciones, recursos, rutas, vehículos, almacenes y necesidades de clientes distintos, asegurando que todos los procesos estén integrados y sincronizados.

La planificación y la gestión del transporte pueden beneficiarse enormemente del análisis de datos y la predicción de la demanda. Muchos de los problemas habituales de los operadores logísticos como la asignación de recursos, la consolidación de la mercancía o la organización de las rutas, pueden modelarse y abordarse mediante técnicas predictivas. Dada la alta complejidad de estos sistemas y la elevada combinatoria de sus variables, estas técnicas permiten reducir significativamente el tiempo requerido para su resolución. La aparición de nuevas tecnologías, software especializado y herramientas de análisis de datos ha facilitado el tratamiento e interpretación de grandes volúmenes de información, permitiendo transformar datos históricos en conocimiento útil para la toma de decisiones.

La calidad de la información disponible condiciona directamente la calidad de las decisiones que se toman. Actualmente, muchos operadores basan su planificación en datos históricos de años anteriores sin realizar ningún tratamiento analítico sobre ellos. Esta información rara vez se transforma en una predicción estructurada de la demanda futura: con frecuencia se asume que la actividad pasada se repetirá de forma similar, algo que en la práctica resulta poco realista. Como consecuencia, la planificación termina apoyándose

principalmente en la experiencia acumulada de los equipos o en decisiones tomadas de forma reactiva en el día a día.

Este modelo de gestión reactiva tiene un impacto directo sobre el funcionamiento interno del operador. El personal encargado de la planificación se ve sometido a una presión continua que genera desgaste en los equipos y reduce la capacidad de análisis de las situaciones. Además, la necesidad de reaccionar continuamente ante cambios imprevistos tiende a deteriorar tanto la calidad como la rapidez de las operaciones, ya que muchas decisiones deben adoptarse en plazos muy cortos y con información limitada. El foco del problema no radica únicamente en la variabilidad inherente a la demanda, sino en el método que se aplica para combatirla: los análisis manuales y los métodos tradicionales no permiten identificar patrones de comportamiento ni generar escenarios alternativos de forma sistemática.

El presente trabajo estudia esta problemática en el contexto específico de un tipo de contrato logístico de larga duración conocido como tender. Este tipo de contratos representan un escenario especialmente relevante para analizar cómo la capacidad de anticipar la demanda impacta en el rendimiento operativo de un operador logístico 3PL.

1.2 Planteamiento del problema

Muchas empresas continúan basándose en datos poco fiables y no hacen un buen uso de ellos. A veces, la incorporación de nuevos métodos puede recular desconocido y arriesgado. Sin embargo, este trabajo trata de poner en manifiesto la importancia de adaptar nuevas estrategias en el análisis de datos y la predicción de la demanda dentro de la planificación logística.

¿Es realmente imprescindible arriesgarse a modificar la manera de trabajar de un operador logístico? ¿Qué beneficios reales puede obtener haciendo una predicción de la demanda de rutas de sus clientes?

Los clientes tender suelen proporcionar históricos con las rutas que quieren realizar, el volumen total de veces que se llevará a cabo la ruta y la media de peso de la mercancía por ruta.

Rara vez estos datos recrean una descripción real del escenario que se realizará en el futuro.

En la práctica se presentan variaciones significativas, que como consecuencia pueden crear ineficiencias relacionadas con la infrautilización de recursos, sobrecostes operativos o mala optimización de consolidación de las cargas. Traducido en grandes pérdidas económicas o malas decisiones operativas.

Usualmente la operativa no dispone de información precisa hasta el momento que el cliente realiza los bookings o reservas de dicha ruta. Es ahí cuando se conoce una información creíble y se puede empezar a plantear la gestión de la operación.

La variabilidad de la demanda es una realidad en la que se van a encontrar los operadores, y en general cualquier actividad condicionada por el comportamiento del mercado y del consumo.

Aunque resulte imposible eliminar esta incertidumbre, si que existe la posibilidad de reducir su impacto operativo y económico mediante una mejora capacidad de anticipación.

1.3 Objetivos

El objetivo principal de este trabajo reside en analizar cómo la predicción de la demanda puede contribuir en una mejora en la operativa de un operador logístico 3PL. Especialmente en servicios de grupaje, LTL y FTL. Reduciendo así la incertidumbre y mejorando la toma de decisiones relacionada con la gestión del volumen de actividad.

Objetivos específicos:

- Estudiar y desglosar el funcionamiento operativo de un operador logístico.
    - Cómo se estructuran las tareas diarias dentro de este departamento.
    - Comprender los procesos de recepción de mercancía, consolidación de cargas, planificación de rutas, asignación de recursos y expedición de la mercancía.
- Entender el impacto real de la incertidumbre en la planificación.

    - Analizar cómo la falta de visibilidad sobre la actividad futura puede afectar a la operativa diaria, generando problemas.
- Comprender cómo trabajan los clientes tipo tender y sus limitaciones.
    - Investigar el funcionamiento de los contratos tender, analizar diferencias entre precisiones teóricas proporcionadas por el cliente y el comportamiento real.
- Identificar el papel de la predicción de la demanda en la toma de decisiones.
    - Estudiar hasta donde puede mejorar las decisiones tener la capacidad de anticipación del volumen de actividad.
- Simular un entorno logístico real mediante datos.
    - Construir una base de datos simulada representando distintos clientes tender, con rutas y patrones de actividad, incluyendo variaciones de demanda y comportamiento estacional.
- Aplicar técnicas de análisis y predicción sobre los datos obtenidos.
    - Utilizar herramientas de análisis y modelos predictivos para estudiar el comportamiento del volumen de rutas y generar previsiones para el año 2026 de manera mensual.

1.4 Propósito

El propósito de este trabajo surge del interés por comprender el impacto negativo que puede llegar a tener, en un operador logístico, el desconocimiento de la demanda futura, y en consecuencia cómo afecta la mala planificación en las decisiones operativas.

Mi enfoque se centra en analizar la problemática desde una perspectiva general en términos de impacto empresarial. Más allá de la mejora puramente operativa, adquirir la competencia de anticipar la demanda acaba siendo un factor estratégico para la compañía.

La planificación representa uno de los escenarios que más caracteriza y diferencia a una empresa, ya que condiciona directamente su capacidad de adaptación, eficiencia y crecimiento. Aunque en este trabajo el foco resida en la planificación operativa, la realidad es que este concepto puede extenderse mucho más allá.

Este sector es muy exigente y demandante, ya que se caracteriza por márgenes ajustados y presión constante sobre costes y tiempos de entrega, pequeñas mejoras en la planificación pueden traducirse en ventajas muy significativas a nivel económico y organizativo.

La evolución del sector delata lo positivos que pueden ser estos cambios. Cada vez más empresas optan por modelos apoyados en el análisis de datos, la automatización y las técnicas predictivas. Muchas empresas líderes en el sector nos lo han demostrado con sus excelentes resultados.

Finalmente, creo que diferenciarse y adaptarse es la clave para poder seguir liderando el sector logístico, y es por eso, que mi tfg trata de analizar el impacto de implementar predicción de la demanda en el volumen de rutas, además de estudiar las herramientas que existen para poder combatir el problema.

2. Marco teórico

2.1 Operadores logísticos 3PL

2.1.1 Concepto y rol en la supply chain

El concepto de supply chain es una red coordinada de organizaciones, personas, actividades, información y recursos involucrados en el proceso de producción y distribución de un producto. Tiene como objetivo asegurar disponibilidad de los productos y por lo tanto complacer la demanda. [1]

Abarca el ciclo de vida de un producto, incluyendo el diseño inicial, la obtención de materias primas, la fabricación, la distribución, la venta al por menor y la gestión de devoluciones / logística inversa.

Keith Oliver, un consultor de la firma Booz Allen Hamilton, en 1982 durante una entrevista para Financial Times, lo definió por primera vez como:

“El proceso de planificación, ejecución y control de las operaciones de la cadena de suministro, con el fin de satisfacer las necesidades de los clientes de la forma más eficiente posible. Abarca todos los movimientos y el almacenamiento de materias primas, existencias de productos en curso y productos acabados desde el punto de origen hasta el punto de consumo”. [2]

Este enfoque destaca la importancia de coordinar todos los eslabones del proceso para asegurar su correcto funcionamiento.

En este contexto, los operadores logísticos se sitúan como uno de los elementos clave de la cadena, principalmente para las tareas de almacenamiento, transporte y distribución.

La posición del operador logístico es clave para que fluya la cadena, actuando como responsable de gestionar y optimizar total o parcialmente las operaciones logísticas de sus clientes. Sus servicios abarcan desde el transporte y la distribución hasta la gestión de inventarios, almacenamiento o embalaje. Ofreciendo soluciones integrales adaptadas a las necesidades específicas de cada empresa.

La esencia radica en asumir la responsabilidad de las operaciones logísticas, permitiendo a sus clientes centrarse en su núcleo de negocio. Y es por esto, que un operador logístico es un socio estratégico para sus clientes, ya que tiene la capacidad de aportar valor añadido a lo largo de toda la cadena.
Si logra tener una buena capacidad para gestionar la información, coordinar sus flujos y entender los cambios de la demanda, se convierte en un factor clave para la eficiencia y competitividad.

En definitiva, los operadores logísticos no pueden entenderse de forma aislada, sino como parte integrante de la supply chain. Su existencia y su función están directamente ligadas a la necesidad de coordinar y optimizar los flujos físicos y de información que permiten que un producto llegue desde su origen hasta el cliente final de la forma más eficiente posible.

2.1.2 Tipos de operadores logísticos

Para poder clasificar bien los operadores logísticos y entender la externalización de los servicios logísticos ofrecidos, hay que introducir el concepto de PL (Party Logistics). Esto es muy importante ya que un operador logístico dentro de la supply chain puede abarcar diversas tareas, incluso a veces puede parecer abstracto el trabajo que realizan. [3]

Por eso nace el PL, para definir quién gestiona la logística, cuánto control tiene la empresa y qué nivel de integración existe en la supply chain.

Existen 5 niveles de clasificación:

- 1PL: Corresponde a empresas que gestionan internamente sus operaciones logísticas, siendo autosuficientes del transporte, almacenamiento y distribución de sus productos. Este tipo de operador no es proveedor del servicio logístico.

- 2PL: Es el primer paso para la externalización de algunas tareas logísticas por parte de una empresa fabricante, entre ellas transporte.

El operador logístico 2PL trabaja en un ámbito más amplio que el operador 1PL, pero continúa ofreciendo servicios estándar, principalmente en el área nacional.

En este caso, el fabricante o empresa contratante coordina la flota de transporte y prepara los pedidos a clientes en su almacén.

- 3PL: Este modelo ya ofrece una externalización de gran parte de las operaciones a cargo de un operador logístico.

El operador 3PL actúa como intermediario entre el fabricante y sus clientes, proporcionando no solo servicios de transporte y almacenaje en sus instalaciones, sino también utilizando su flota de vehículos, organizando las operaciones de transporte, la trazabilidad de la mercancía y operaciones del almacén: preparación de pedidos, cross-docking, gestión de inventarios o logística inversa. De esta forma, se optimiza la gestión de la cadena de suministro de la empresa contratante, integrando las tareas logísticas y liberando la gestión de esos procesos.

En este caso, el fabricante sigue siendo el propietario de los bienes almacenados y transportados por el operador 3PL.

Para el cliente no hay diferencia entre un operador 3PL y un fabricante gestionando su propia logística.

Al integrar más fases de la logística, los servicios de estos operadores son más personalizados y se adaptan mejor a las necesidades de la empresa contratante y de sus clientes. Por lo tanto, los acuerdos entre los proveedores de la logística externos y la empresa contratante suelen ser a largo plazo, lo que permite al 3PL conocer y optimizar la parte de la cadena de suministro que gestiona.

- 4PL: Es un proveedor logístico que proporciona servicios logísticos personalizados de consultoría, planificación, gestión, localización e integración de nuevas tecnologías, actuando como supervisor del funcionamiento de la cadena de suministro. El operador 4PL no ejerce tareas físicas de transporte y almacenaje, que son delegadas al operador 3PL.

De esta manera, el proveedor 4PL controla totalmente la cadena de suministro del fabricante, encargándose de diseñar y optimizar al máximo la eficiencia cada

proceso, gracias a la experiencia y capacidad tecnológica como operador logístico. Además, sus tareas incluyen la contratación de los proveedores 3PL que realizarán las tareas físicas y ejercer como interlocutor único con los diferentes proveedores logísticos y los clientes.

- 5PL: Es el operador que engloba la ejecución de los servicios físicos de transporte y logística del proveedor 3PL con la optimización de la cadena de suministro del proveedor 4PL. [4]

Type of PL	**Responsabilidad**	**Servicios ofrecidos**	**Ventajas**
1PL	Empresa propia	Transporte terrestre y almacenaje	Control total, sin dependencia externa
2PL	Proveedor externo	Transporte o almacenaje	Reducción de costes fijos, acceso a infraestructura
3PL	Colaboración Operativa	Logística integrada: almacenaje, transporte, picking	Escalabilidad, mejora del servicio, reducción de tiempos, etc.
4PL	Gestión estratégica	Coordinación de varios 3PL, optimización global	Visión completa, eficiencia, toma de decisiones basada en datos
5PL	Gestión digital avanzada	Automatización, big data, inteligencia artificial	Alta eficiencia, flexibilidad, ideal para e-commerce

Tabla 1: Tipos de operadores logísticos.

Fuente [5]

2.1.3 Funcionamiento operativo de un 3PL: tareas y flujo de mercancía

Con el tiempo las empresas 3PL han evolucionado de ser meros proveedores de transporte y almacenamiento, a socios integrados que ofrecen soluciones de cadena de suministro de principio a fin. A diferencia de una subcontratación puntual, el 3PL participa de manera continua bajo acuerdos de niveles de servicio (SLA), NDA 's (Acuerdos de confidencialidad), KPI' s.

Sus servicios principales, aunque puede variar mucho, incluyen almacenamiento y gestión de existencias, gestión de pedidos, coordinación de envíos y transporte, gestión aduanera y documental en operaciones internacionales, y la logística inversa. Más allá de estas tareas operativas, los 3PL participan activamente en funciones estratégicas como el análisis y diseño de proyectos logísticos, estudios de viabilidad y cotización de servicios. Esto refleja que el operador no se limita a ejecutar, sino que aporta valor en la planificación y mejora continua de la cadena de suministro de sus clientes.

Los operadores 3PL aportan múltiples ventajas y beneficios a sus clientes. A parte de reducir la carga operativa y permitir a sus clientes centrarse en su negocio, ofrece ventajas estructurales estratégicas.

Dan opción a una escalabilidad operativa sin inversión fija, es decir que, las empresas pueden optar a ampliar la capacidad de su capacidad logística sin invertir en infraestructuras flota o personal propio. Permitiendo el crecimiento o reducción del volumen de operaciones de manera flexible según va evolucionando el negocio.

Contactando con un operador de este tipo, las empresas tienen acceso directo y conocimiento super especializado. Los 3PL trabajan con múltiples sectores y mercados, con procesos complejos de logística internacional y distintos trámites.

También permiten optimizar sus costes, reduciendo costes derivados de ineficiencias internas y pueden aprovechar economías de escala y mejores tarifas de transporte negociadas por el operador.

Una de las ventajas más destacables es la posibilidad de enfoque en el ‘core business’, es decir, el cliente se saca una tarea tan compleja como la logística de sus responsabilidades y así puede centrarse en actividades estratégicas para su negocio cómo el marketing, el desarrollo de producto o las ventas.

Además, mejora en nivel de calidad y de fiabilidad del servicio, mediante el uso de procesos estandarizados y tecnología avanzada, con sistemas como el TMS (Transportation Management System: Software logístico diseñado para planificar, ejecutar y optimizar el movimiento físico de las mercancías).

Un punto importantísimo, es que los clientes se acaban beneficiando de las tecnologías que apliquen los operadores. Cómo más avanzados sean los sistemas y la precisión de su trabajo, más visibilidad de información tienen los clientes

El flujo operativo de la mercancía es el motor principal de cualquier 3PL y se clasifica en las siguientes bases:

1. Booking del cliente: El cliente registra su necesidad en el WMS del operador, indicando origen, destino y volumen aproximado. En muchas ocasiones esta información llega incompleta o con poca antelación, lo que obliga a actuar con rapidez.
2. Entrada de mercancía (Inbound): Recepción, verificación y ubicación de la mercancía en el almacén. En algunos casos se utilizan ASN (Avisos de Envío Anticipado) para preparar mejor la recepción.
3. Almacenaje o cross-docking: La mercancía puede almacenarse o salir el mismo día. Esta decisión depende del volumen y de la planificación disponible.
4. Preparación de pedidos: Picking, packing y consolidación de cargas.
5. Planificación de salida (Outbound): Asignación de rutas, vehículos y organización de las cargas.
6. Expedición y seguimiento: Carga de camiones, salida y trazabilidad hasta el destino final.

El rendimiento de este flujo se mide mediante KPIs como la precisión de pedidos, los tiempos de espera o la exactitud del inventario, que permiten identificar ineficiencias y actuar sobre ellas.

La falta de previsión de la demanda es uno de los principales factores de ineficiencia en este proceso. Cuando el volumen futuro no se anticipa correctamente, se generan problemas en tres ámbitos clave:

- Costes y rentabilidad: La infrautilización de recursos en periodos de baja demanda y la saturación en picos obligan a recurrir a transporte urgente y fletes acelerados, elevando drásticamente los costes. La incapacidad de consolidar cargas correctamente y la mala optimización de rutas agravan esta situación.
- Nivel de servicio y KPIs: Los errores de forecast se traducen en incumplimientos de plazos de entrega, afectando directamente la confianza del cliente en el 3PL.
- Gestión del personal y la flota: Sin visibilidad sobre el volumen futuro, la asignación de recursos humanos y materiales se vuelve reactiva, aumentando la probabilidad de errores, accidentes y sobrecostes imprevistos.

En definitiva, la calidad de las decisiones operativas no depende únicamente de la ejecución, sino de la información disponible en el momento de tomarlas. Disponer de una previsión estructurada de la demanda permite pasar de una gestión reactiva a una anticipada, mejorando la eficiencia, la rentabilidad y la calidad del servicio ofrecido.

2.2 Planificación operativa en logística

2.2.1 Tipos de servicio

El transporte terrestre puede clasificarse en diferentes tipos de servicios en función de la oferta del operador logístico, el modelo operativo en el que decida especializarse y los criterios de clasificación utilizados.

De forma general estos servicios se dividen en tres modalidades generales en función de la carga transportada. Para ello es imprescindible entender cómo se mide la mercancía en el ámbito logístico, ya que su peso, volumen y espacio ocupado dentro del vehículo condicionan la elección del servicio de manera directa.

- Peso: ¿Cuánto pesa la carga?
- Volumen: ¿Cuánto ocupa la carga (m^3)?
- Metros lineales ¿Cuánto mide la carga?

Para comprender bien la clasificación, es importante tener en cuenta las dimensiones de un camión estándar y las distintas formas en las que se puede aprovechar y distribuir su capacidad. Un tráiler estándar presenta las siguientes características:

- Longitud: 13,6 metros
- Anchura: 2,4 metros
- Altura útil: 2,6 metros
- Capacidad máxima de carga: ~ 24 toneladas
- Capacidad aproximada: 33 euro pallet (1,20 x 0,80 m)

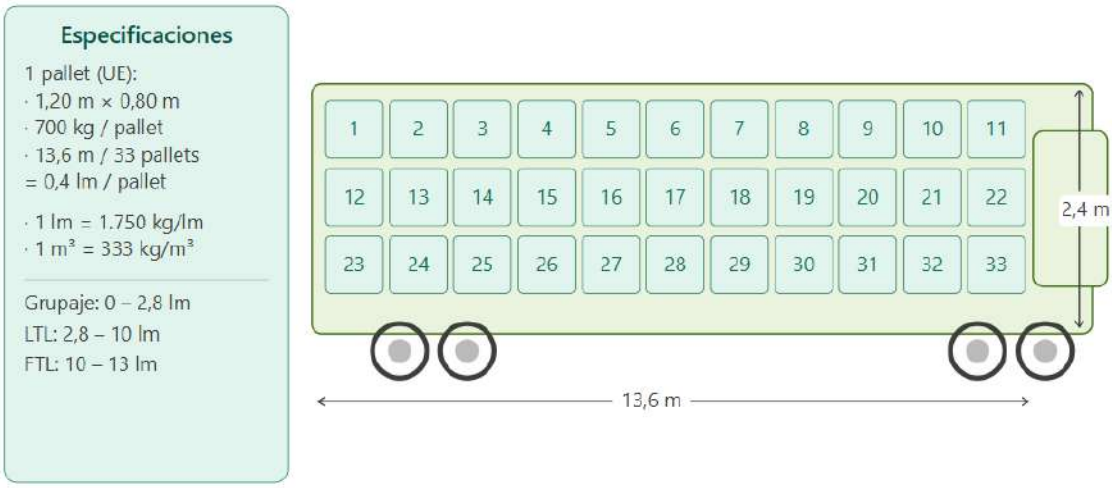

Figura 1: Esquema de carga de un camión estándar.

En este contexto, la mercancía se transporta habitualmente paletizada, siendo el euro pallet la unidad de carga más utilizada en el transporte de carretera.

Para poder comparar y gestionar de manera correcta los distintos tipos de mercancía, se emplean medidas estandarizadas y factores de conversión que permiten unificar la forma en la que se valoriza la carga. Como resultado es más fácil comunicarse con el cliente ya que se establece un lenguaje común entre cliente y operador.

A partir de la capacidad de un camión estándar, se obtienen los siguientes valores referencia.

Peso medio por 1 pallet:

- 24.000 kg / 33 pallets ≈ **700 kg por pallet.**

Factor de conversión en LDM:

- 24.000 kg / 13,6 ldm ≈ 1750 **kg por LDM.**

Factor de conversión en CBM:

- 24.000 kg / 90 m³ ≈ 266 kg --- En la práctica, se utiliza un valor operativo de 333 **kg por CBM.**

Equivalencia pallet en LDM:

- 13,6 m / 33 pallets ≈ **0,4 LDM por pallet.**

Estas unidades permiten transformar diferentes magnitudes en una unidad común, facilitando el proceso selección del servicio para ambas partes.

- Carga Completa (FTL): Como el propio nombre indica, implica el transporte de mercancías que llenan un contenedor de camión entero. Usualmente se utiliza cuando un cliente tiene un volumen de carga suficiente para ocupar todo un remolque, aproximadamente entre 10 y 13,6 metros lineales (ldm). Y toda la ocupación de un camión pertenece a un único remitente.
    - El tiempo de entrega es más rápido que en otros tipos de servicios.
    - La carga se transporta directamente de un punto A a un punto B sin paradas intermedias.

- El remitente tiene control total sobre el contenido de la carga.
- La tarifa es más elevada que en otros servicios, por eso es importante usar eficientemente el espacio del camión.
- El uso del espacio depende del cliente.

Esta opción suele utilizarse cuando la mercancía es frágil o delicada, ya que, al reducirse la cantidad de carga a terceros, el riesgo es menor. Además, si los plazos de entrega son ajustados es la mejor opción, por ejemplo, cuando hablamos de productos perecederos o carga de automoción.

- Carga parcial (LTL): Implica llenar todo el camión con más de 1 cliente, lo que reduce el precio del transporte. En este caso, la carga ocupa solo una parte del vehículo, situándose generalmente entre 2,5 y 10 metros lineales (LDM).

  El propio transportista tiene la libertad de llenar el espacio del camión con las mercancías (clientes) que desee. Los proveedores construyen sus redes para consolidar y desconsolidar de manera eficiente según los flujos de volumen, es decir, son rutas que se adaptan a la demanda.

  Por lo general, el transportista llegará al origen deseado, se agregará la carga de un cliente X a la carga de un cliente Y, ya existente en el camión, y el transportista llevará esa carga a través de diferentes nodos de clasificación hasta que llegue a su destinatario.

  Dependiendo de la distancia y del nivel de servicio, puede haber muy pocos nodos de clasificación o muchos nodos de clasificación.

  - El tiempo de entrega es más lento que en FTL.
  - El camión realiza varias paradas para recoger y entregar las cargas.
  - Los remitentes no tienen control total sobre el contenido de la carga.
  - La tarifa suele ser más baja que en el FTL debido al espacio compartido.
  - Los envíos se pueden manipular varias veces durante el tránsito.

- Grupaje: Consiste en el transporte de envíos pequeños con salidas regulares, generalmente inferiores a 2.5 metros lineales. A diferencia del FTL, donde el recorrido es directo, o del LTL, donde la planificación puede ser más flexible, en el grupaje el operador trabaja sobre una red fija de conexiones entre plataformas logísticas. [6]

  El funcionamiento habitual sería:

  - La mercancía pasa por uno o varios centros de clasificación (hubs), donde se consolida y se redistribuye en función del destino final.

2.2.2 Planificación operativa basada en el volumen de actividad

La planificación operativa en la logística constituye uno de los elementos más importantes para garantizar eficiencia dentro del funcionamiento de un operador logístico. Su objetivo no reside únicamente en ejecutar el transporte, sino en coordinar de manera lógica los recursos disponibles, como: vehículos, personal, espacio en el almacén, capacidad de carga… para responder al volumen de actividad esperado. En este contexto la planificación operativa es el nexo entre las previsiones teóricas y la realidad diaria de la operación.

De forma general existen 3 niveles de planificación:

- Planificación Estratégica: Se centra a corto plazo, como inversiones de infraestructuras, apertura de nuevos almacenes o aplicación de proveedores o flota.
- Planificación Táctica: Se centra en horizontes temporales medios, como la asignación de capacidad y la organización de los recursos.
- Planificación Operativa: Se centra en la ejecución diaria de la actividad, trata de ajustar continuamente operaciones en función de la demanda real y teniendo en cuenta incidencias o situaciones inesperadas.

Dentro del contexto de un operador logístico, la planificación operativa adquiere una relevancia brutal, ya que gran parte de las decisiones deben tomarse en horizontes temporales muy reducidos. Aspectos como la consolidación de la mercancía, la asignación de rutas, la ocupación de vehículos o la organización de las salidas dependen directamente del volumen de carga esperado.

Además, gran parte de los operadores logísticos trabajan mediante la subcontratación de la flota.

Escenario de ejemplo: El operador logístico acuerda un precio en enero del 2026 con un proveedor para un camión completo. El cliente que ha contratado al operador logístico, hasta mayo del 2026 no empieza a operar esa ruta. El precio en mayo es el mismo que se acordó en enero.

¿Qué ha cambiado?

La situación geopolítica en oriente medio ha habido un incremento muy brusco en el precio del fuel en un período reducido de tiempo. En este escenario, un operador logístico que haya ofrecido un precio fijo a su cliente meses antes puede encontrarse con una estructura de costes completamente distinta a la prevista inicialmente, reduciendo drásticamente su margen operativo o incluso generando pérdidas en determinadas rutas.

Aunque existan factores externos imposibles de controlar o predecir, como el escenario descrito anteriormente, resulta fundamental prever aquellos elementos sobre los que sí es posible obtener cierta visibilidad y especialmente en volumen de actividad y demanda esperada.

En la práctica las empresas deben adaptarse continuamente a cambios de demanda y excepciones operativas. No se suele conocer la exactitud de expediciones que surgirán a un mes vista, qué tipo de flota deberá de estar disponible o si habrá suficiente carga para optimizar determinados trayectos.

Un aspecto para destacar es la búsqueda de cargas de retorno. En muchas ocasiones, la rentabilidad de un viaje depende de la posibilidad de evitar kilómetros en vacío y conseguir mercancía de vuelta. Pongamos el caso que hay

una expedición Barcelona - > Madrid con un camión FTL, si el vehículo regresa a Barcelona vacío la empresa deberá asumir combustible, peajes, horas de conducción y desgaste del vehículo sin generar ingresos durante este segundo trayecto. Si el operador hace una buena predicción, probablemente, con una o dos semanas de antelación tendrá en cuenta que realizará este trayecto. Por lo que se podrá asegurar que ese vehículo realiza el trayecto de vuelta lleno.

Operativa debe ser capaz de responder con rapidez a preguntas que aparecen diariamente en la actividad de un operador:

- ¿Se debe lanzar un camión de inmediatamente o esperar para consolidar más mercancía?
- ¿Cuántos envíos LTL habrá durante la jornada?
- ¿Existen cargas de retorno que permitan aprovechar el viaje y minimizar kilómetros vacíos?
- ¿Será necesario cancelar algún vehículo por falta de volumen?
- ¿Cuántos proveedores deben activarse para cubrir la demanda prevista?
- ¿Cómo debe organizarse el personal operativo durante la semana?
- ¿Habrá disponibilidad suficiente de vehículos especializados, como camiones frigoríficos o ADR?
- ¿Qué tipo de mercancía debe priorizarse según rentabilidad, urgencia o compatibilidad?
- ¿Cuáles son los transit times comprometidos con cada cliente y cómo afectan a la planificación?

Aunque muchas de estas decisiones pueden llegar a intuirse gracias a la experiencia y al conocimiento operativo adquirido con los años, en la mayoría de los casos siguen tomándose prácticamente en tiempo real y con un margen de reacción reducido. Los trabajadores terminan desarrollando una capacidad de detectar patrones, prever comportamiento de clientes o estimar volúmenes aproximados según el día de la semana o la época del año.

Esta situación cambiaria considerablemente si, en lugar de realizar estas preguntas diariamente, la empresa pudiera planificar parte de su operativa con varias semanas de antelación, o incluso con el horizonte temporal que se

considere adecuado según el tipo de operación y las necesidades del negocio. [7]

2.2.3 Problemas habituales en entornos reales

La gestión de la capacidad es uno de los factores más determinantes del rendimiento de la cadena de suministro, especialmente en entornos donde la actividad está condicionada por volúmenes comerciales fluctuantes, cuellos de botella en corredores, picos estacionales y limitaciones de infraestructura.

El objetivo principal del buen dimensionamiento es garantizar que las operaciones sigan funcionando incluso cuando las condiciones cambien rápida y abruptamente. Es decir, poder responder a la demanda prevista de forma eficiente. [8]

En otras palabras, se busca mantener un equilibrio entre instalaciones, flota y personal, con el volumen de mercancías real que circulan en el sistema.

Esta característica describe cuando un operador es capaz de planificar, controlar y optimizar los recursos. Y así, toda la cadena puede satisfacer la demanda sin necesidad de gastar, más en sobrecapacidad o por debajo de ella.

Dentro de un operador logístico, esta capacidad no depende únicamente del transporte, sino de la coordinación conjunta de múltiples recursos.

Por este motivo, la planificación de capacidad puede estructurarse en cinco fases principales, lo que nos permite comprender de forma más clara cómo los operadores transforman previsiones de actividad en decisiones operativas claras.

- Previsión de la demanda: Esta fase es dónde se analizan datos y volúmenes históricos, previsiones de clientes, estacionalidades, y factores externos. [9]

Esta etapa es el punto de partida de toda planificación, ya que condiciona directamente el resto de las decisiones. Este trabajo se centra especialmente en esta primera fase, estudiando cómo una mejora en la capacidad de predicción puede contribuir a optimizar la gestión operativa.

- Evaluación de la capacidad: Una vez estimada la demanda futura, el operador debe evaluar hasta qué punto sus recursos pueden soportar la actividad futura.

En el contexto de esta tesis, se tendrán en cuenta los siguientes recursos:

  - Capacidad de transporte.
    - Número de camiones propios/subcontratados disponibles.
    - Tipología del vehículo. (tautliner, box, frigo…)
    - Planificación de viajes de ida y vuelta, en función de la demanda prevista por relación origen-destino.
    - Restricciones por tipo de mercancía (ADR, temperatura, volumen, fragilidad, valor…)
  - Capacidad del almacén.
    - Metros cuadrados y metros cúbicos disponibles.
    - Límites operativos recomendados.
    - Número de muelles necesarios según el flujo previsto de vehículos.
  - Capacidad de mano de obra operativa.
    - Dimensionamiento de equipos de inbound, picking/packing y outbound.
    - Necesidad de turnos extras u horas punta según patrones semanales o estacionales.
  - Capacidad tecnológica y gestión de muelles.
    - Herramientas de “dock appointment scheduling” que ajustan las citas de camiones a la capacidad real de muelles y personal.
    - Sistemas TMS/WMS que usan el forecast para generar cargas y rutas con antelación. [10]

- Identificación de brechas: Una vez comparadas las previsiones de actividad con los recursos reales disponibles, el operador identifica posibles desequilibrios o limitaciones operativas. Esta fase trata de realizar simulacros, ‘¿qué pasaría si…?’, para interrupciones comunes. Estas brechas pueden manifestarse cómo:
  - Falta de espacio en el almacén.

    - Insuficiencia de vehículos.
    - Escasez del personal.
    - Saturación de muelles.
    - Incapacidad de absorber ciertos picos de demanda.
- Desarrollo de estrategias o toma de decisiones: Tras identificar posibles limitaciones, el siguiente paso es desarrollar estrategias que permitan solucionar y adaptar la capacidad a la demanda prevista. Entre estas decisiones, destacan:
    - Reasignación de recursos.
    - Contratación adicional de flota.
    - Ampliación de turnos.
    - Reorganización de rutas.
    - Reserva anticipada de capacidad.
    - Preparación previa de mercancía para evitar congestiones.

  En esta fase, cómo más precisa sea la predicción, más fuertes y claves pueden ser las decisiones.
- Implementación: Finalmente se ejecuta la planificación diseñada y se realizan seguimientos mediante herramientas en tiempo real.
    - Ocupación del almacén.
    - Rendimiento de la flota.
    - Tiempos de carga.
    - Retrasos.

Como conclusión, la capacidad impacta directamente sobre la fluidez de la cadena de suministro.

Cuando se consigue que los recursos estén aliados con la demanda, la carga se mueve de forma predecible y controlada.

Por este motivo, la predicción de la demanda adquiere un papel fundamental en la planificación logística. La capacidad de anticipar el volumen futuro de rutas, pallets, metros lineales o expediciones permite transformar el forecast en unidades reales de trabajo, facilitando el dimensionamiento de recursos y la planificación operativa.

2.3 Predicción de la demanda

2.3.1 Concepto y fundamentos

La previsión de la demanda es el proceso mediante el cual se estiman las necesidades futuras de bienes o servicios necesarios para que un negocio funcione de la manera más rentable posible. Sin esta, las empresas corren el riesgo de generar sobrecostes, o directamente pierden oportunidades por no anticiparse a escenarios futuros.

Usualmente estos análisis están soportados en tecnologías modernas que potencian la predicción y la hacen mucho más fiable y precisa. Las organizaciones con visión a futuro están recurriendo a herramientas de IA, machine learning, análisis predictivo y automatización en su enfoque de previsión de demanda.

IBM destaca que la inteligencia artificial tendrá un papel cada vez más relevante dentro de las operaciones de la cadena de suministro en los próximos años. En este sentido, la automatización, el análisis avanzado de datos y los sistemas inteligentes están transformando los flujos de trabajo. Además, estos avances no solo afectan al transporte o a la distribución, sino también a la evaluación del coste asociado a cada decisión empresarial, que debe de considerarse desde un inicio para mejorar la eficiencia global de la cadena de suministro.

"No se trata solo de explicar cómo llegarán los materiales del punto A al punto B. También se trata de medir el coste de la cadena de suministro de cada decisión empresarial y de asegurarse de que esos costes se tienen en cuenta desde el principio", dice el informe. [11]

Hay varios aspectos para tener en cuenta en este estudio fundamental, entre los cuales se encuentran la evolución histórica de las ventas, la época del año, el mercado, las normativas del sector y la situación económica local y global.

En las operaciones logísticas de un 3PL, una buena precisión ayuda a los almacenes a optimizar su inventario, gestionar operaciones de manera eficaz y a garantizar el cumplimento de los tiempos de tránsito.

Existen varios tipos de previsión de demanda para implementar en operaciones logísticas, incluyendo:

- Previsión Cualitativa: Consiste en utilizar información subjetiva como las tendencias de mercado, el comportamiento del consumidor. Se utilizan métodos como: encuestas, método Delphi, opinión de expertos.
- Previsión Cuantitativa: Implica el uso de modelos predictivos y datos históricos para predecir la demanda. Es el núcleo de todo el proceso de predicción. Utiliza métodos como: medias móviles, regresión, series temporales, modelos econométricos. [12]

La predicción de la demanda puede ser influida por factores externos, que incluyen la situación del mercado, los ingresos de los consumidores, las tasas de empleo, leyes y regulaciones y aspectos sociales tales como la cultura, la moda o las tendencias. O factores internos condicionas por las decisiones de la empresa, cómo disponibilidad de productos o servicios, precio y calidad, atención al cliente y promociones que se ofrezcan.

2.3.2 Importancia en la toma de decisiones

Disponer de una precisión de la demanda fiable, abre al operador 3PL un abanico de decisiones que de otro modo no serían posibles. A continuación, se describen las principales áreas de decisión donde el forecasting tiene un impacto directo y tangible.

- Decisiones de capacidad y subcontratación:

Esta es una de las decisiones más críticas y recurrentes en el departamento operativo. Determinar qué volumen de carga se puede absorber con flota propia y qué parte requiere subcontratación. Esta decisión no es puntual, se toma semana a semana, y su coste depende enormemente del momento en que se ejecuta.

Cuando el operador dispone de una previsión de volumen con suficiente antelación, idealmente con una o dos semanas de horizonte, puede reservar capacidad de transportistas externos a tarifa negociada, en lugar de acudir al mercado spot en el último momento, donde los precios son notablemente más elevados y la disponibilidad no está garantizada. Esta decisión, repetida de forma sistemática a lo largo del año, tiene un impacto directo y acumulado sobre el margen operativo.

Del mismo modo, la previsión permite anticipar picos estacionales de actividad como campañas de promociones, cierres de trimestre o periodos de mayor rotación de producto y activar con antelación acuerdos con proveedores de capacidad puntual, garantizando la cobertura sin recurrir a soluciones de emergencia. [13]

- Decisiones de planificación de rutas y consolidación:

En transporte de distribución, la rentabilidad de una ruta depende en gran medida del grado de ocupación del vehículo. Un operador que conoce con antelación los volúmenes previstos por origen-destino puede tomar decisiones activas de consolidación como agrupar expediciones de distintos clientes en el mismo vehículo, ajustar la frecuencia de las rutas según la demanda esperada, o decidir si es más eficiente lanzar un vehículo parcialmente cargado hoy o esperar a mañana para completar la carga.

Este tipo de decisiones que en la práctica se conocen como planificación de carga requieren visibilidad anticipada del volumen. Sin previsión, el planificador trabaja únicamente con los pedidos confirmados en el momento, lo que reduce el margen de maniobra y obliga a tomar decisiones poco óptimas con la información disponible en el instante.

- Decisiones sobre la red logística y asignación de rutas tender:

En el contexto de los contratos tender, el operador se compromete con una estructura de rutas, frecuencias y tarifas antes de conocer el volumen real que el cliente va a generar. La previsión de demanda es, en este caso, la herramienta que permite calcular si las condiciones del contrato son sostenibles a lo largo del tiempo.

Una vez el contrato entra en vigor, la previsión permite tomar decisiones sobre la asignación de rutas entre flota propia y subcontratada, sobre qué rutas conviene potenciar o renegociar en la siguiente licitación, y sobre si la red actual está sobredimensionada o infra dimensionada respecto a la actividad real del cliente. Estas decisiones tienen un impacto directo en la rentabilidad del contrato y en la relación comercial a largo plazo.

- Decisiones de planificación de personas y turnos

La demanda operativa no solo condiciona la flota, también determina las necesidades de personal en plataforma, los turnos de carga y descarga, y la coordinación con los almacenes de los clientes. Un operador que anticipa un pico de actividad para la próxima semana puede planificar turnos adicionales, coordinar con las plataformas de cross-docking y garantizar que los recursos humanos están disponibles en el momento adecuado.

Esta dimensión de la previsión es especialmente relevante en operadores con estructuras de personal flexibles trabajadores a tiempo parcial, empresas de trabajo temporal donde la activación de recursos tiene un lead time mínimo que debe respetarse. La previsión amplía ese margen y convierte una necesidad reactiva en una decisión planificada.

- De la reacción a la anticipación: el valor real del forecasting

El conjunto de decisiones descritas comparte una característica común, que todas se toman mejor con tiempo que sin él. La previsión de la demanda no elimina la incertidumbre inherente a la operación logística, pero sí amplía el horizonte de decisión del operador, permitiéndole pasar de una lógica puramente reactiva a una lógica anticipatoria de prepararse para lo que va a llegar. En un sector donde los márgenes son ajustados y la eficiencia operativa es la principal palanca de competitividad, esta capacidad de anticipación constituye una ventaja real y sostenible.

2.3.3 Limitaciones reales de hacer forecasting desde la perspectiva del operador

En el caso concreto de los operadores logísticos 3PL, la predicción de la demanda presenta una particularidad importante: el operador no controla

directamente la actividad comercial que origina la a la actividad logística, sino que depende de ventas, pedidos y decisiones operativas de sus clientes. Usualmente los clientes de este tipo de operadores son fabricantes y distribuidores de mercancía general, empresas de retail y e-commerce, así como sectores especializados como el farmacéutico o el textil. Normalmente registran su actividad comercial mediante sistemas propios, como ERP, CRM o plataformas de venta.

En cambio, el operador logístico trabaja con sistemas orientados a la ejecución operativa, como el WMS en almacén o el TMS en transporte, donde se reflejan rutas, pedidos logísticos, expediciones, volúmenes y mercancía registrada… Pero no acostumbran a obtener la totalidad de información del cliente. Por este motivo, cuanto mayor sea la integración entre los sistemas del cliente y los sistemas operativos del operador logístico, mayor capacidad existirá para anticipar comportamientos futuros de la demanda. Gracias a la integración el operador no solo reacciona a los bookings, sino que detecta patrones de comportamiento del cliente y puede anticipar picos de demanda y necesidades de recursos. [14]

No obstante, en la práctica existen limitaciones importantes. En primer lugar, el acceso a históricos comerciales completos del cliente no siempre es posible por razones de confidencialidad, restricciones de acceso o falta de integración entre plataformas. [15]

En segundo lugar, los operadores no suelen gestionar el 100% de la actividad logística de un cliente, sino solamente una parte de ella. Por lo que, la información que se podría facilitar representa una fracción de la demanda real. Esto condiciona el alcance del forecasting, ya que los patrones identificados responden al segmento de actividad canalizada a través del operador, y no necesariamente al comportamiento global del cliente.

En este contexto, la presente investigación se limita a trabajar con los datos operativos disponibles en el propio operador logístico, dado que el acceso a

históricos comerciales completos del cliente no siempre es posible. Esta restricción no impide el análisis, sino que lo orienta hacia una perspectiva más realista y aplicable, basada en información como rutas, expediciones y volúmenes transportados. A partir de estos registros, y especialmente si se dispone de una adecuada integración entre sistemas, es posible detectar patrones de actividad y obtener previsiones útiles para la toma de decisiones operativas.

Por tanto, más que predecir la demanda comercial en sentido estricto, el objetivo de este trabajo consiste en anticipar la demanda operativa que dicha actividad genera sobre los recursos, la capacidad y la red logística del operador 3PL.

2.4 Analítica predictiva e inteligencia artificial

2.4.1 Tipos de herramientas y modelos

La analítica predictiva aplicada a la logística abarca un conjunto de herramientas y metodologías muy amplio, que van desde hojas de cálculo con fórmulas estadísticas básicas hasta modelos de aprendizaje automático entrenados sobre millones de registros. La elección de una u otra no depende únicamente de su capacidad técnica, sino también del volumen y calidad de los datos disponibles, de la madurez analítica de la organización y de los recursos humanos y tecnológicos con los que cuenta el operador. Este apartado describe el panorama general de las herramientas más utilizadas en el sector, y justifica la selección de las tres empleadas en el caso práctico del trabajo: Excel, SARIMA y ANN.

Microsoft Excel:

Excel es, con diferencia, la herramienta de forecasting más utilizada en operadores logísticos de tamaño pequeño y mediano. A pesar de no ser una plataforma diseñada específicamente para la analítica predictiva, su fácil accesibilidad la convierten en el punto de partida habitual para cualquier ejercicio de previsión.

Su elección es con el objetivo de representar el nivel de entrada real al que cualquier operador, sin necesidad de inversión, puede acceder hoy mismo.

En Excel la tendencia y el pronóstico son dos conceptos diferentes, aunque relacionados nos permiten analizar y predecir el comportamiento de los datos a lo largo del tiempo. La tendencia es la dirección general o el patrón de cambio en los datos a medida que transcurre el tiempo. Permite identificar si los valores están aumentando, disminuyendo o manteniéndose estables. Por otro lado, el pronóstico es la estimación o predicción de los valores en función de datos históricos y la tendencia identificada.

Dentro de Excel el método empleado es la función PREVISION.ETS (FORECAST.ETS), accesible también a través de la herramienta “Hoja de previsión” del menú Datos. Esta función implementa un suavizado exponencial triple, que lo que hace es descomponer la serie histórica en tres componentes: nivel, tendencia y estacionalidad. Y los combina para generar una previsión que da más peso a las observaciones recientes que a las antiguas. A diferencia de una media móvil simple, este método detecta automáticamente el patrón estacional de la serie (en este trabajo, un ciclo de 12 meses).

Además de su papel como base, Excel cumple una función de validación y comunicación de resultados. El cálculo del error pronóstico, especificado más adelante, puede realizarse íntegramente mediante fórmulas de hoja de cálculo. [16]

SARIMA (modelización estadística de series temporales con estacionalidad):

SARIMA (Seasonal Autoregressive Integrated Moving Average), es una extensión del modelo ARIMA. Es uno de los modelos predictivos más utilizados para la previsión de demanda en entornos con patrones recurrentes asociados al mes o la época del año, algo muy habitual en operadores 3PL.

Frente a Excel, SARIMA incorpora de forma explícita la estructura temporal de la serie (su tendencia, su componente autorregresiva y su ciclo estacional) mediante un conjunto de parámetros que se ajustan estadísticamente a los datos históricos.

El modelo SARIMA es especialmente adecuado cuando se dispone de un histórico de datos suficientemente largo y estructurado, y cuando la relación

entre el pasado y el futuro de la serie puede capturarse mediante combinaciones lineales de valores retardados.

En el contexto de este trabajo, SARIMA se aplica sobre datos operativos del operador logístico expediciones, volúmenes y rutas para modelizar la estacionalidad de la demanda y obtener previsiones a corto y medio plazo.

La inclusión de SARIMA en este trabajo responde a su posición intermedia entre la simplicidad de Excel y la complejidad de una red neuronal. Esta combinación de capacidad analítica e interpretabilidad lo convierte en un candidato natural para operadores que dispongan de histórico suficiente pero no necesariamente de equipos de ciencia de datos. [17]

Redes Neuronales Artificiales (ANN): Aprendizaje automático para patrones complejos.

Las redes neuronales artificiales (ANN) son modelos de aprendizaje automático capaces de aprender relaciones directamente a partir de los datos, sin necesidad de asumir una forma concreta para la serie.

En este trabajo, la ANN se aplica transformando la serie histórica en pares de entrada-salida mediante una ventana deslizante, de modo que la red aprende a predecir el valor de un mes a partir de los valores de meses anteriores.

Frente a SARIMA, las ANN ofrecen mayor flexibilidad para capturar patrones complejos e interacciones no lineales entre variables, como la combinación del día de la semana, el mes y el comportamiento específico de un cliente

En este trabajo, las ANN se utilizan como modelo alternativo a SARIMA, con el objetivo de evaluar si la captura de patrones no lineales aporta una mejora real en la precisión predictiva sobre los datos operativos disponibles. La comparación entre ambos modelos, junto con Excel como base, constituye el núcleo del análisis práctico. [18]

Más allá de las tres herramientas seleccionadas para este trabajo, el sector logístico dispone de una tendencia creciente de plataformas y metodologías orientadas a la predicción de la demanda operativa. Su adopción varía en función del tamaño del operador, su grado de digitalización y la complejidad de su red logística.

Sistemas TMS con módulo predictivo:

Los principales sistemas de gestión de transporte (Transportation Management System) de gama alta, como SAP TM, Oracle Transportation Management o Blue Yonder TMS, incorporan módulos de forecasting integrados que alimentan directamente la planificación de rutas y la asignación de capacidad. Estos sistemas trabajan con los datos operativos del propio TMS como expediciones históricas, rutas, tiempos de tránsito y generan previsiones que se trasladan automáticamente a la planificación de la semana siguiente. Su principal ventaja es la integración nativa con el flujo operativo; su principal limitación es el coste y la complejidad de implementación. [19]

Plataformas de Business Intelligence con capacidades de forecasting:

Herramientas como Microsoft Power BI, Tableau o Qlik incorporan funcionalidades de análisis predictivo que permiten construir modelos de previsión sobre los datos operativos del operador sin necesidad de programación. Power BI, en particular, integra Azure Machine Learning y permite entrenar modelos de series temporales directamente desde la interfaz gráfica. Estas plataformas son especialmente adecuadas para operadores con cultura analítica establecida, pero sin recursos técnicos especializados en ciencia de datos. [20]

Prophet (Meta):

Prophet es una librería de forecasting de código abierto desarrollada por Meta (Facebook), diseñada específicamente para series temporales con estacionalidad múltiple y efectos de calendario (festivos, eventos puntuales). Su principal ventaja es la facilidad de uso y la robustez ante datos irregulares o con valores ausentes, lo que la hace especialmente atractiva para equipos técnicos que necesitan resultados rápidos sin una configuración exhaustiva de

parámetros. En el sector logístico se utiliza para modelizar series de expediciones diarias o semanales con patrones estacionales complejos.

Modelos de regresión con variables exógenas (ARIMAX / SARIMAX):

Una extensión natural de SARIMA es la incorporación de variables externas que puedan explicar parte del comportamiento de la serie. En logística, estas variables pueden incluir indicadores de actividad del cliente (ventas previstas, campañas de promoción), variables de calendario (festivos nacionales, días hábiles) o indicadores macroeconómicos. El modelo SARIMAX combina la estructura estadística de SARIMA con la capacidad explicativa de la regresión múltiple, ofreciendo un enfoque más rico cuando el operador dispone de información adicional más allá del histórico de expediciones.

El papel de la IA en la mejora de estas herramientas. La entrada de la inteligencia artificial en el sector logístico no ha substituido las herramientas de forecasting descritas anteriormente, sino que las ha potenciado de forma significativa, en tres dimensiones clave: la automatización del proceso de modelización, la incorporación de fuentes de datos no estructurados y la capacidad de adaptación dinámica del modelo.

Automatización y selección de modelos (AutoML).

Las plataformas de AutoML (Automated Machine Learning) permiten entrenar, evaluar y seleccionar automáticamente el mejor modelo predictivo para una serie temporal dada, sin intervención manual en la configuración de hiperparámetros. Herramientas como Azure Automated ML, Google Vertex AI o H2O.ai aplican este enfoque sobre datos logísticos, reduciendo el tiempo de desarrollo de modelos de semanas a horas y democratizando el acceso a técnicas avanzadas para operadores sin equipos de data science propios.

Incorporación de datos no estructurados.

Los modelos de IA, especialmente los basados en Large Language Models (LLM) y procesamiento de lenguaje natural, permiten incorporar al proceso de forecasting información que los modelos predictivos clásicos no pueden procesar: correos electrónicos de clientes con previsiones de pedidos, noticias sectoriales, alertas de disrupciones en la cadena de suministro o comentarios de

los equipos comerciales. Esta capacidad amplía el horizonte informativo del modelo más allá de los datos estructurados disponibles en el TMS o el WMS.

Modelos adaptativos y aprendizaje continuo.

A diferencia de los modelos predictivos clásicos, que se entrenan una vez sobre un histórico y se actualizan de forma periódica, los modelos de IA pueden diseñarse para aprender de forma continua a medida que llegan nuevos datos. En un entorno logístico donde los patrones de demanda pueden cambiar de forma abrupta —por la incorporación de un nuevo cliente, un cambio en la red de distribución o un evento externo inesperado—, esta capacidad de adaptación dinámica representa una ventaja operativa real frente a los enfoques más estáticos.

En definitiva, la inteligencia artificial no reemplaza la necesidad de comprender los datos ni la lógica operativa del negocio, pero sí amplía la capacidad de los operadores logísticos para extraer valor de sus datos históricos, reducir el esfuerzo manual del proceso de previsión y mejorar la precisión y la velocidad de las predicciones. La combinación de modelos predictivos robustos como SARIMA, técnicas de aprendizaje automático como las ANN y herramientas accesibles como Excel, potenciadas por las capacidades de la IA, define el estado actual de la analítica predictiva en el sector logístico.

2.4.2 Fundamentos técnicos

Una vez descrito el panorama general de herramientas usualmente utilizadas por operadores logísticos, este apartado profundiza en el funcionamiento interno de los dos modelos más relevantes utilizados en este trabajo: SARIMA y ANN. El objetivo no es ofrecer una formulación matemática exhaustiva, sino transmitir la lógica de funcionamiento de cada modelo con suficiente consistencia para comprende pro qué se comportan de la forma observada en los resultados del apartado 4.

SARIMA:

Antes de explicar SARIMA es necesario introducir dos conceptos previos: la serie temporal y la estacionalidad.

Una serie temporal es una secuencia de valores medidos a intervalos regulares, en este trabajo: el número de expediciones entregadas cada mes. Una serie se considera estacionario cuando sus propiedades estadísticas básicas se mantienen aproximadamente constantes a lo largo del tiempo, sin tendencias crecientes o decrecientes sostenidas.

Esto es importante por qué una serie estacionaria es más fácil de predecir, porque se puede asumir que el futuro se comportará de forma similar al pasado. Una serie con tendencia marcada, como es el caso del cliente 6 del apartado práctico que evoluciona en declive sostenido, no es estacionaria. Y por lo tanto, aplicar un modelo predictivo sobre ella sin tratamiento previo conduciría a estimaciones poco fiables, porque el modelo no sabría los limites hasta dónde puede seguir cayendo la serie.

La técnica habitual para convertir una serie no estacionaria es la diferenciación. En lugar de trabajar con los valores originales de la serie (100, 112, 108…) se trabaja con las diferencias entre los valores consecutivos. Esto hace que se transformen los datos dados, consigue que se elimine la tendencia porque ya no importa el nivel absoluto de la serie sino cuánto cambia de un mes a otro. Esta es precisamente la "I" (Integrado) del nombre SARIMA, y es el primer parámetro: denominado d, que se ajusta en la especificación del modelo.

Los componentes AR, I y MA.

El nombre SARIMA es un acrónimo de sus cuatro componentes: Seasonal (estacional), AutoRegressive (autorregresivo), Integrated (Integrado) y Moving Average (media móvil). Los tres últimos forman parte del modelo ARIMA clásico, sobre el que SARIMA añade un componente estacional.

- Componente Autorregresivo (AR): Asume que el valor de la serie en un momento determinado puede explicarse, en parte, como una combinación de sus propios valores anteriores. De forma simplificada, un modelo AR se expresa como:

$$y_t = c + \varphi_1 \cdot y_{t-1} + \varepsilon_t$$

donde y_t es el valor de la serie en el mes t, y_{t-1} es el valor del mes anterior, φ_1 (phi) es un coeficiente que el modelo estima a partir de los datos (y que indica cuánto "arrastra" el valor del mes anterior sobre el actual), c es una constante, y ε_t representa el error o ruido aleatorio que el modelo no puede explicar. En esencia, este componente nos dice: El valor de este mes depende, en cierta proporción, del valor del mes pasado.

- Componente Media Móvil (MA): A diferencia del componente AR, que utiliza valores pasados de la serie, el componente MA utiliza los errores de predicción pasados. Un modelo MA se expresa como:

$$y_t = c + \varepsilon_t + \theta_1 \cdot \varepsilon_{t-1}$$

donde ε_{t-1} es el error que el modelo cometió en el mes anterior, y θ_1 (theta) es el coeficiente que determina cuánto de ese error se traslada a la predicción del mes actual. Por lo tanto, este componente nos indica: Si el mes pasado me equivoqué por exceso, este mes corrijo ligeramente mi predicción a la baja.

- Componente Integrado (I): Como se ha explicado en el apartado anterior, este componente no añade una ecuación propia, sino que indica cuántas veces hay que diferenciar la serie original para convertirla en estacionaria antes de aplicar los componentes AR y MA. Se representa con el parámetro
    - d: d=0 significa que no es necesario diferenciar (la serie ya es estacionaria)
    - d=1 significa que se trabaja con las diferencias entre meses consecutivos.

  Combinando estos tres componentes se obtiene la notación ARIMA (p,d,q), donde p es el número de retardos autorregresivos (componente AR), d es el grado de diferenciación (componente I), y q es el número de términos de media móvil (componente MA).

El componente estacional de ARIMA a SARIMA.

El modelo ARIMA, descrito hasta ahora, solo tiene en cuenta la relación entre un mes y los meses inmediatamente anteriores. Sin embargo, las series de expediciones analizadas en este trabajo presentan un patrón adicional: la relación entre un mes y el mismo mes del año anterior. Por ejemplo, julio de 2025 puede parecerse más a julio de 2024 que a junio de 2025, porque ambos meses de julio comparten el mismo contexto estacional. De hecho, seguramente, en este contexto, tenga más relación con el mismo mes del año pasado que con el mes anterior.

SARIMA incorpora esta relación añadiendo una segunda versión de los componentes AR, I y MA, pero aplicados no al mes inmediatamente anterior, sino al mes situado s periodos atrás, donde s es la longitud del ciclo estacional. Para datos mensuales con un patrón que se repite cada año, s = 12.

La descripción seria:

$$SARIMA\ (p, d, q)\ (P, D, Q)_s$$

donde el primer paréntesis (p,d,q) corresponde a la parte regular, la relación entre meses consecutivos, exactamente igual que en ARIMA, y el segundo paréntesis $(P,D,Q)_s$ corresponde a la parte estacional.

La especificación SARIMA (1,1,1) (1,0,1,12) aplicada en el trabajo

En el caso práctico se ha utilizado la especificación SARIMA (1,1,1) (1,0,1,12), coherente con la indicación del tutor.

Traduciendo cada parámetro a su significado práctico:

- Parte regular (1,1,1): el valor de un mes depende del valor del mes anterior (p=1), se trabaja con la diferencia entre meses consecutivos para eliminar la tendencia a corto plazo (d=1), y se incorpora el error de predicción del mes anterior para corregir la estimación actual (q=1).
- Parte estacional (1,0,1,12): el valor de un mes depende también del valor del mismo mes del año anterior (P=1), no se aplica diferenciación

estacional adicional porque la diferenciación regular ya resulta suficiente para estabilizar la serie (D=0), y se incorpora el error de predicción cometido en el mismo mes del ciclo anterior (Q=1), con un ciclo estacional de 12 meses (s=12).

Esta especificación permite que el modelo capture simultáneamente tres fenómenos presentes en las series de expediciones analizadas:

- Dependencia a corto plazo entre meses consecutivos
- Tendencia general de cada cliente (creciente, decreciente o estable)
- Patrón estacional anual (caídas en verano o repuntes en el último trimestre)

ANN

Frente al enfoque estadístico de SARIMA, basado en una ecuación explícita con coeficientes interpretables, la red neuronal artificial sigue una lógica completamente distinta. En lugar de asumir una forma para la relación entre los datos, la red aprende esa relación directamente a partir de ejemplos.

Para aplicar una ANN a una serie temporal es necesario transformar la serie en un conjunto de ejemplos de entrenamiento mediante una ventana deslizante: para cada mes que se quiere predecir, se construye un "ejemplo" formado por unas entradas y una salida conocida.

En este trabajo, las entradas utilizadas para predecir el valor del mes t son tres:

- El valor del mes anterior (y_{t-1})
- El valor de dos meses antes (y_{t-2})
- El valor del mismo mes del año anterior (y_{t-12}).

La salida es el valor real del mes t, que la red utiliza durante el entrenamiento para ajustar sus parámetros internos.

Es interesante notar que la tercera entrada desempeña en la ANN un papel conceptualmente similar al de la componente estacional de SARIMA, ya que ambos modelos incorporan información sobre el ciclo anual, aunque lo hacen de formas muy distintas.

SARIMA lo hace mediante un coeficiente estadístico explícito (Φ_1 en la fórmula anterior) y la ANN lo hace de forma implícita, ajustando los pesos internos de sus

neuronas durante el entrenamiento sin que exista un coeficiente identificable que el analista pueda interpretar directamente.

Esto resume la principal diferencia entre ambos modelos: SARIMA ofrece una estructura interpretable a cambio de asumir una forma concreta para la serie y la ANN ofrece mayor flexibilidad para adaptarse a patrones.

2.4.3 Limitaciones y barreras de adopción

El potencial de las herramientas de analítica predictiva e IA en logística es real, pero su adopción en el sector avanza de forma desigual. Más allá de las limitaciones estructurales del forecasting en un entorno 3PL, existen barreras específicas relacionadas con la implementación de estas herramientas que explican por qué muchos operadores siguen dependiendo de métodos rudimentarios a pesar de tener acceso a soluciones mucho más avanzadas.

La primera de ellas es la resistencia organizativa al cambio. Introducir modelos predictivos en la operativa diaria no es únicamente un proyecto tecnológico, implica modificar la forma en la que los equipos toman decisiones. Los planificadores y los operarios acostumbrados a gestionar sobre la marcha y a confiar en la experiencia pueden percibir estos modelos con prejuicios, especialmente cuando las predicciones no coinciden con su intuición o cuando los primeros resultados no son suficientemente precisos. Esta resistencia no es irracional en un entorno de alta presión operativa, ya que adoptar una nueva herramienta supone asumir un riesgo inmediato para ganar un beneficio que puede tardar en materializarse.

A esto se le suman la falta de perfiles técnicos capaces de desarrollar, mantener e interpretar los modelos. Los operadores de tamaño medio raramente disponen de equipos de datos propios, y la adopción suele depender de iniciativas puntuales o de proyectos externalizados que no generan conocimiento interno. Es usual que el proyecto termine y el modelo queda huérfano, nadie en la organización sabe actualizarlo, interpretarlo ni adaptarlo al día a día. Esta

fragilidad es uno de los principales motivos por los que muchas implementaciones no llegan a consolidarse.

El tercer factor es el retorno de inversión percibido. Implementar una solución predictiva robusta requiere tiempo, recursos y un período de maduración durante el cual los resultados pueden llegar a ser modestos. Este sector, caracterizado por los márgenes ajustados y la presión constante sobre los costes operativos, la disposición a invertir en proyectos cuyo retorno es difuso a corto plazo es limitada. Esto explica por qué Excel sigue siendo la herramienta dominante en gran parte del sector: no porque sea la mejor opción técnica, sino porque es la más accesible y la más inmediata. La comparación entre Excel y modelos más avanzados no es solo una comparación de precisión predictiva, sino también una comparación de coste de adopción y de riesgo percibido.

Por supuesto estas barreras no invalidan el valor de la analítica predictiva, pero sí condicionan el enfoque con el que debe abordarse su implementación. El reto real no radica en encontrar el modelo técnicamente más sofisticado, sino en el que sea suficientemente preciso, interpretable e integrable en los procesos existentes del operador. Es desde esta perspectiva pragmática desde la que se plantea el caso práctico de este trabajo, no como una demostración de la capacidad técnica de los modelos en condiciones ideales, sino como una evaluación de su utilidad real en el contexto específico y con las limitaciones propias de un operador logístico 3PL. [21]

3. Caso específico: Clientes tipo tender

3.1 Características de los contratos tender

Se entiende por tender el proceso de concurso o licitación mediante el cual una empresa, organización o entidad convoca a varios proveedores logísticos o de transporte para que presenten sus propuestas, con el objetivo de seleccionar aquel con quien establecer una relación comercial a largo plazo.

En logística, el tender se articula como una petición de oferta estructurada: el cliente publica sus necesidades operativas y los operadores interesados presentan su propuesta para ganar la mayor cantidad de rutas. Los servicios objeto de licitación suelen incluir transporte, almacenaje y gestión operativa, y la selección del proveedor se realiza comparando criterios como el precio, la cobertura de la red, la calidad del servicio, la seguridad, los tiempos de tránsito y las condiciones comerciales. El proceso de tendering crea competencia entre los operadores, lo que favorece la obtención de mejores tarifas y compromisos de servicio, e introduce transparencia al permitir al cliente comparar múltiples propuestas de forma simultánea. [22]

Para ello, el cliente facilita a los operadores documentación detallada del servicio requerido, con información sobre rutas, volúmenes estimados, tiempos requeridos, tipo y peso de la mercancía, paradas intermedias, política de combustible y condiciones contractuales, entre otros aspectos. La calidad y completitud de esta información es determinante para el resultado del proceso: cuando los datos son incompletos o imprecisos, los operadores tienden a inflar sus tarifas para protegerse ante riesgos desconocidos; por el contrario, unos datos limpios y detallados permiten una tarificación precisa y compromisos más firmes.

Más allá de su dimensión operativa, el tender es un proceso de gran envergadura estratégica para ambas partes. Para el cliente no se trata únicamente de contratar un servicio de transporte puntual, sino de construir una red logística que deberá funcionar de forma eficiente durante un período prolongado,

habitualmente entre 1 y 3 años. Estos contratos suelen abarcar un volumen elevado de rutas, orígenes y destinos, y están concebidos como una estructura operativa estable sobre la que el cliente apoya su cadena de suministro. Por este motivo, detrás del lanzamiento de un tender existe siempre una estrategia: el cliente ha analizado previamente su red, ha identificado ineficiencias y tiene un objetivo claro respecto a cómo quiere que funcione su logística al finalizar el proceso. Para el operador, ganar un tender de estas características supone un compromiso de recursos significativo —flota, personal, infraestructura— y un impacto directo en su cuenta de resultados durante toda la vigencia del contrato. Las organizaciones más avanzadas han evolucionado desde modelos de licitación estrictamente anuales hacia enfoques de mejora continua, que equilibran la estabilidad de los contratos con la capacidad de respuesta ante cambios del mercado, transformando la relación cliente-operador de una transacción puntual en una verdadera asociación estratégica.

Dado el alcance y la complejidad de lo que se negocia, el proceso de tender es por naturaleza flexible e iterativo. Es habitual que se habiliten fases de preguntas y respuestas en las que los operadores pueden solicitar aclaraciones sobre el pliego de condiciones, y en las que el cliente puede matizar o ajustar ciertos requerimientos en función de las respuestas recibidas. Asimismo, cuando un operador no puede cumplir alguna condición específica, existe margen para negociar alternativas o excepciones, siempre que el conjunto de la propuesta sea competitivo. Permitir a los operadores proponer soluciones alternativas es una práctica recomendada, ya que en ocasiones estos identifican oportunidades de eficiencia que el cliente no había contemplado, como posibilidades de consolidación o optimizaciones de rutas. Esta flexibilidad no es una concesión, sino una necesidad inherente a la complejidad del proceso: un tender de gran escala difícilmente puede resolverse de forma rígida cuando las variables en juego son tantas y los intereses de ambas partes tan relevantes.

Es habitual que el proceso se desarrolle en dos fases. La primera, conocida como RFI (Request for Information), corresponde a la etapa inicial de recogida de información general sobre los proveedores, sus capacidades operativas y sus

ventajas diferenciales. A partir de esta fase, el cliente determina qué operadores cumplen los requisitos mínimos para pasar a la siguiente etapa. La segunda fase, conocida como RFQ (Request for Quotation), es el núcleo del proceso de tender. En esta etapa, los operadores preseleccionados durante la RFI reciben la documentación completa del concurso: el detalle de las rutas, los volúmenes estimados, los volúmenes movidos en años anteriores, las frecuencias requeridas, las condiciones operativas y las exigencias contractuales. A partir de esta información, cada operador elabora su propuesta económica y técnica, asignando tarifas a cada ruta o servicio licitado y definiendo las condiciones bajo las que se compromete a operar. [23]

La RFQ exige al operador un análisis riguroso: no se trata de ofertar el precio más bajo posible, sino de construir una propuesta que sea competitiva para el cliente y sostenible para el operador a lo largo de toda la vigencia del contrato. El coste más bajo raramente equivale al mejor valor en transporte: una evaluación completa debe considerar la fiabilidad del operador, su estabilidad financiera, sus capacidades tecnológicas y su alineación con los valores del cliente, factores que determinan el éxito de la relación a largo plazo. En esta fase es donde cobra especial relevancia la previsión de la demanda, ya que el operador debe estimar qué volumen real de carga va a circular por cada ruta para dimensionar correctamente sus recursos y calcular un coste por expedición que refleje la realidad operativa.

Una vez recibidas todas las propuestas, el cliente entra en una fase de evaluación y negociación. Es habitual que se realicen varias rondas de ajuste, en las que el cliente puede solicitar mejoras de tarifa, modificaciones en las condiciones de servicio o aclaraciones sobre aspectos concretos de la oferta. El proceso concluye con la adjudicación del contrato a uno o varios operadores, según la estrategia de red del cliente, que puede optar por concentrar el servicio en proveedores estratégicos en sus rutas de mayor volumen, o distribuirlo entre varios operadores para garantizar flexibilidad y redundancia en su red.

3.2 Información disponible vs. información real

En un proceso tender, la información que el cliente facilita al operador logístico no es un reflejo completo de su demanda real, es una aproximación histórica, agregada y estática, construida con el objetivo de obtener propuestas económicas comparables, no con el objetivo de habilitar un sistema de previsión. Esta distinción, aparentemente sutil, tiene consecuencias profundas sobre la capacidad del operador para anticipar lo que va a ocurrir una vez que el contrato esté en vigor.

Qué información facilita el cliente en el RFQ y qué significa para el operador logístico:

Durante esta fase, el cliente proporciona a los operadores un conjunto de campos estructurados que definen cada una de las rutas licitadas. En la práctica de los contratos de transporte internacional, esta información suele incluir los campos recogidos en la siguiente tabla:

Campo RFQ	**Descripción e interpretación operativa**	**Naturaleza del dato**
ID Ruta	Identificador único de cada par origen-destino licitado	Estructural
País / Ciudad / ZIP Origen	Localización del punto de recogida	Geográfico
País / Ciudad / ZIP Destino	Localización del punto de entrega	Geográfico
Peso bruto aprox. por envío (kg)	Peso histórico medio del año anterior. Estimación, no compromiso	Volumétrico histórico
Nº expediciones al año	Número de envíos realizados el año anterior en esa ruta	Frecuencia histórica

Tabla 2: Tabla descriptiva de los campos de información de un RFQ.

Hay dos aspectos que merecen especial atención. En primer lugar, tanto el peso por envío como el número de expediciones son datos históricos del año anterior, no compromisos contractuales para el período futuro. El cliente los facilita como referencia orientativa, para que el operador pueda usarlos en su estrategia de precios y tenga en cuenta el volumen de envíos o rutas que tendrá que destinar a este proyecto, si ganan la licitación. Es importante destacar que no hay una obligación de mantener esos volúmenes durante la vigencia del contrato.

En segundo lugar, el nivel de detalle temporal de los datos es muy variable según el cliente. En algunos casos el dato facilitado es estrictamente anual y agregado, sin ningún desglose temporal, lo que impide identificar patrones de estacionalidad o variabilidad directamente a partir de la información proporcionada. En otros casos, el cliente puede proporcionar datos con la fecha del booking, lo que permite una visión más detallada del comportamiento histórico de cada ruta. Esta variabilidad en la calidad y el detalle de la información facilitada es, en sí misma, una característica definitoria del proceso tender. El operador debe construir su propuesta y, posteriormente, su modelo de gestión, con un nivel de información que no controla y que puede diferir significativamente de un cliente a otro.

Hablamos de la brecha que existe entre lo disponible y lo necesario. Si se compara la información que el operador recibe durante el tender con la información que requeriría un modelo de forecasting robusto, la distancia entre ambas es considerable. La siguiente tabla ilustra esta brecha de forma estructurada.

Información ideal para forecasting	**Información disponible en el tender**	**Brecha**
Histórico diario/semanal de volumen por ruta (2-3 años)	Nº expediciones anuales y peso medio del año anterior	Dato sin desglose cronológico

Información ideal para forecasting	Información disponible en el tender	Brecha
Estacionalidad real del cliente (picos, campañas)	Dato anual agregado sin desglose mensual ni semanal	Estacionalidad no visible
Previsión comercial del cliente para el año siguiente	No se facilita. El cliente no comparte su forecast	Horizonte futuro desconocido
Variabilidad histórica por ruta	Solo valor medio. No hay información de dispersión	Incertidumbre no cuantificable
Motivos de picos o caídas de demanda	No se documenta. Queda en el conocimiento interno del cliente	Contexto explicativo ausente
Dato real post-adjudicación (actividad ejecutada)	Expediciones reales registradas en el TMS del operador	Dato disponible, pero con retardo

Tabla 3: Tabla comparativa entre la información ideal y la real.

La brecha no responde a una falta de voluntad del cliente, proviene de la naturaleza del tender. Básicamente el cliente comparte lo que necesita compartir para obtener ofertas comparables y ponerse en contacto con diferentes proveedores, para valorar lo que pueden ofrecerles.

A esto se añade una limitación estructural ya apuntada anteriormente, el operador logístico raramente gestiona el 100% de la actividad logística de un cliente. Es habitual que el cliente trabaje con varios operadores en paralelo, asignando distintas rutas a cada uno. Esto implica que los datos de los que dispone el operador representan solo una fracción de la demanda total del

cliente, lo que condiciona adicionalmente el alcance y la representatividad de cualquier modelo predictivo construido sobre esa base.

En este contexto, el dato operativo real es una fuente de valor infrautilizada. Una vez adjudicado el contrato y en plena ejecución el operador sí dispone de un activo de información valioso que son los registros reales de actividad generados por su propio TMS. Cada expedición ejecutada deja un rastro de datos ruta, fecha, peso, número de envíos, incidencias que, acumulado a lo largo del tiempo, conforma una serie histórica sobre la que es posible construir modelos predictivos.

Este dato operativo real es cualitativamente diferente al dato del RFQ, donde el RFQ ofrece una estimación anual estática, el histórico operativo ofrece granularidad temporal, variabilidad real y patrones de comportamiento observados. Su limitación es que solo está disponible una vez que el contrato ya está en marcha, por lo que no puede utilizarse en la fase de oferta, pero sí es la base fundamental para la gestión y optimización durante la vigencia del contrato.

En el presente trabajo, esta distinción es central, ya que el caso práctico parte precisamente de esta dualidad, combinando la información estructural del RFQ que define las rutas y establece el volumen de referencia con los datos de expediciones reales ejecutadas, que permiten modelizar el comportamiento efectivo de la demanda operativa a lo largo del tiempo.

3.3 De la limitación a la utilidad

A lo largo del análisis desarrollado se podría llegar a una conclusión pesimista, en la que el operador no tiene capacidad de predecir la demanda debido a la información incompleta del cliente y la fracción de la actividad logística con otros operadores. Sin embargo, existe un margen real para realizar el forecasting. Aunque este requiere replantear el objeto de la predicción y trabajar con los datos que realmente está disponibles.

El punto de partida es abandonar la pretensión de predecir la demanda comercial del cliente, y sustituirla por un objetivo más acotado y operativamente más útil. Se traduciría en predecir la demanda operativa que esa actividad comercial genera sobre los recursos del operador. En términos concretos, esto significa anticipar cuántas expediciones se producirán en cada ruta, qué volumen de carga moverán y con que frecuencia, a partir de los patrones observador en el histórico operativo disponible.

Este reencuadre no es una simplificación, es una adaptación metodológicamente rigurosa a las condiciones reales de información en las que opera un 3PL. El operador no necesita saber cuánto va a vender el cliente para planificar su capacidad, necesita saber cuántas expediciones va a recibir y qué volumen van a representar.

A partir de la combinación de datos que proporciona el RFQ, es posible construir predicciones útiles en tres dimensiones:

- Volumen por ruta: Conociendo el número de expediciones históricas y su peso medio, es posible proyectar el volumen esperado por ruta para el período siguiente, identificar rutas con alta variabilidad y estimar rangos de carga probables para la planificación de flota.
- Frecuencia y estacionalidad: Si el histórico operativo tiene suficientes datos semanales o mensuales durante al menos un año, es posible detectar patrones estacionales recurrentes, cómo picos de actividad, caídas en períodos festivos o comportamientos diferenciados geográficamente.
- Desviación entre lo contratado y lo ejecutado: Comparando los volúmenes del RFQ con las expediciones reales, el operador puede cuantificar el grado de cumplimiento del cliente respecto a los volúmenes comprometidos y utilizar esa brecha como variable correctora en sus modelos de previsión.

En el caso práctico de este trabajo se adoptará exactamente este enfoque. Los datos de partida combinarán dos fuentes complementarias: los volúmenes de referencia contratados en el RFQ (peso aproximado por envío y número de

expediciones anuales acordadas por el cliente) y los registros mensuales de las expediciones reales ejecutadas durante la vigencia del contrato. Como punto de partida, se realizará un análisis descriptivo de la desviación entre el volumen contratado y el volumen realmente ejecutado por cada cliente, lo que permitirá caracterizar empíricamente el problema de visibilidad descrito en los apartados anteriores y demostrar por qué el dato del RFQ no puede utilizarse directamente como previsión. A partir de ahí, se construirán para cada uno de los ocho clientes tender analizados dos series temporales paralelas: el número de expediciones mensuales realizadas y el volumen mensual estimado en kilogramos, obtenido como producto del peso de referencia del RFQ por las expediciones reales de cada período. El histórico abarcará de enero de 2020 a diciembre de 2025, proporcionando seis años completos de actividad mensual por cliente.

Sobre estas series se aplicarán tres enfoques predictivos de complejidad creciente: Microsoft Excel como herramienta de referencia que representa el método más extendido en la industria, SARIMA para capturar la estructura estacional y autorregresiva de la demanda mensual, y redes neuronales artificiales (ANN) para explorar si existen patrones no lineales que el modelo predictivo no puede capturar. La evaluación comparativa de los tres modelos, sobre expediciones, permitirá determinar qué nivel de sofisticación técnica está realmente justificado en un contexto de datos parciales como el que caracteriza la operativa de un 3PL

4. Caso práctico y evaluación

4.1 Descripción del caso y datos utilizados

El caso práctico de este trabajo toma como referencia el contexto operativo de un operador logístico 3PL que gestiona contratos tipo tender con múltiples clientes. Aunque los datos utilizados no han sido cogidos de proyectos reales, se han construido de forma sintética a partir de patrones operativos reales observados en proyectos logísticos, con el objetivo de preservar la confidencialidad de las empresas involucradas. Esta aproximación permite

trabajar sobre un escenario representativo de la realidad operativa sin comprometer información sensible.

El conjunto de datos está compuesto por ocho clientes tipo tender, cada uno con una serie temporal mensual de expediciones que abarca el período entre enero 2020 y diciembre 2025, lo que representa 72 meses por cliente. Para cada cliente se dispone de dos variables principales: el volumen de expediciones contratadas en el RFQ y el volumen de expediciones realmente ejecutadas durante la vigencia del contrato.

La variable objeto de predicción de este trabajo es la serie de expediciones realmente ejecutadas, ya que representa la demanda operativa real que el operador 3PL debe anticipar para dimensionar correctamente sus recursos.

Adicionalmente, se ha simulado un peso medio por expedición para cada cliente en función del tipo de servicio logístico que el cliente requería. De esta manera se puede estimar el volumen total de carga en kilogramos como producto de las expediciones previstas por el peso referencia. Esta conversión no forma parte del proceso de modelización predictiva, sino que constituye una capa adicional de interpretación operativa de los resultados.

Los ocho clientes han sido diseñados para representar perfiles de comportamiento distintos, reproduciendo la diversidad que caracteriza a la cartera de clientes tipo tender de un operador 3PL real. La distribución por tipo de servicio es la siguiente:

Cliente	**Tipo de servicio**	**Kg**	**Perfil de comportamiento**
Cliente 1	**Grupaje**	2.500 kg	Incumplimiento, con caída en verano.
Cliente 2	**Grupaje**	4.200 kg	Sobre entrega creciente.

Cliente	Tipo de servicio	Kg	Perfil de comportamiento
Cliente 3	**LTL**	8.500 kg	Incumplimiento severo.
Cliente 4	**LTL**	15.000 kg	Cliente fiable, cumplimiento estable.
Cliente 5	**FTL**	21.000 kg	Asimetría estacional, sobre entrega.
Cliente 6	**FTL**	22.500 kg	Cliente en declive, incumplimiento creciente.
Cliente 7	**FTL**	20.800 kg	Cliente creciente.
Cliente 8	**FTL**	23.200 kg	Incumplimiento moderado.

Tabla 4: Tabla descriptiva de los ocho clientes simulados.

Esta diversidad de perfiles es deliberada y responde a un objetivo metodológico concreto que es evaluar el comportamiento de los modelos predictivos en condiciones distintas de estacionalidad, tendencia y variabilidad. Un modelo que funciona bien únicamente con series estables y predecibles tiene un valor limitado en la práctica. La robustez de un método de forecasting se demuestra precisamente en su capacidad para manejar series complejas y heterogéneas.

El primer hallazgo relevante del análisis descriptivo es la existencia de desviaciones sistemáticas y significativas entre el volumen contratado y el entregado por cada cliente. Esta brecha, que en algunos casos supera el 20% del volumen comprometido, delata una evidencia que justifica la necesidad de aplicar modelos predictivos. El dato RFQ no puede utilizarse directamente como previsión operativa, porque en la práctica los clientes no ejecutan el volumen acordado.

La siguiente figura muestra la evolución mensual de las expediciones entregadas para los ocho clientes durante el período 2020-2025. Los meses de julio y agosto aparecen sombreados para evidenciar el patrón estacional de menor actividad

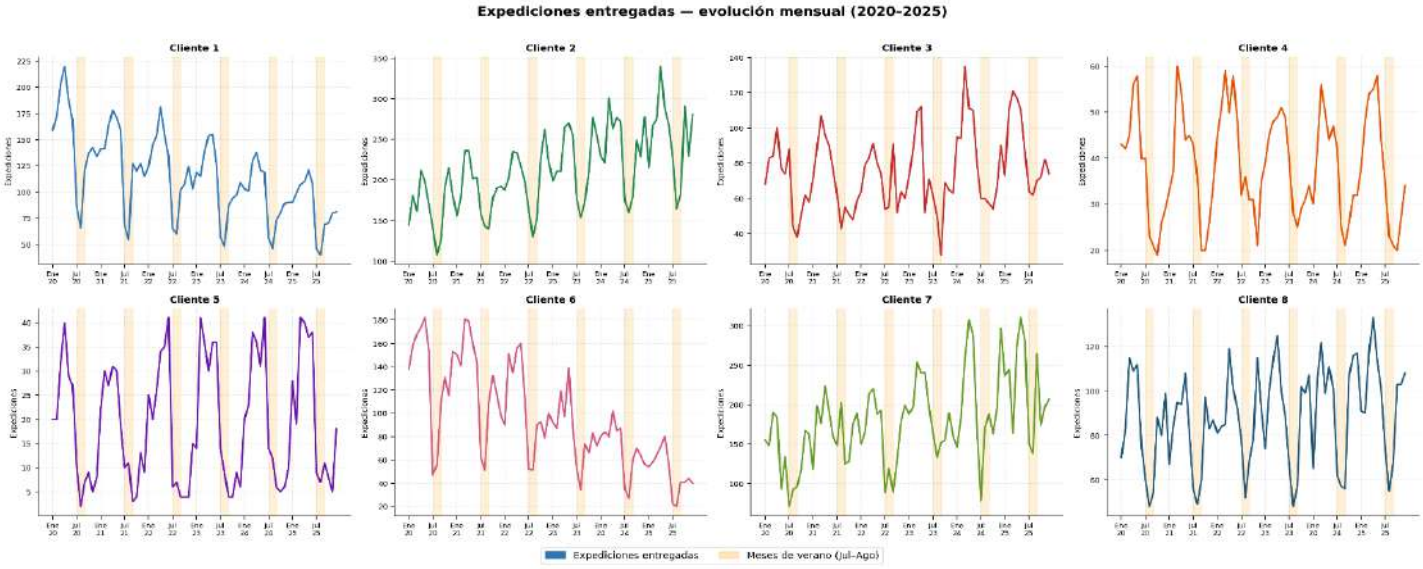

durante el verano, observable de forma recurrente en la mayoría de los clientes:

Figura 2: Gráficos de evolución mensual (2020-2025), número de expediciones entregadas por cliente.

La figura siguiente complementa el análisis comparando, para cada cliente, el volumen contratado en el RFQ (línea gris discontinua) frente al volumen realmente entregado (línea de color). El área sombreada entre ambas líneas representa la brecha de cumplimiento, y el porcentaje indicado en cada subgráfica es la tasa de cumplimiento media del período:

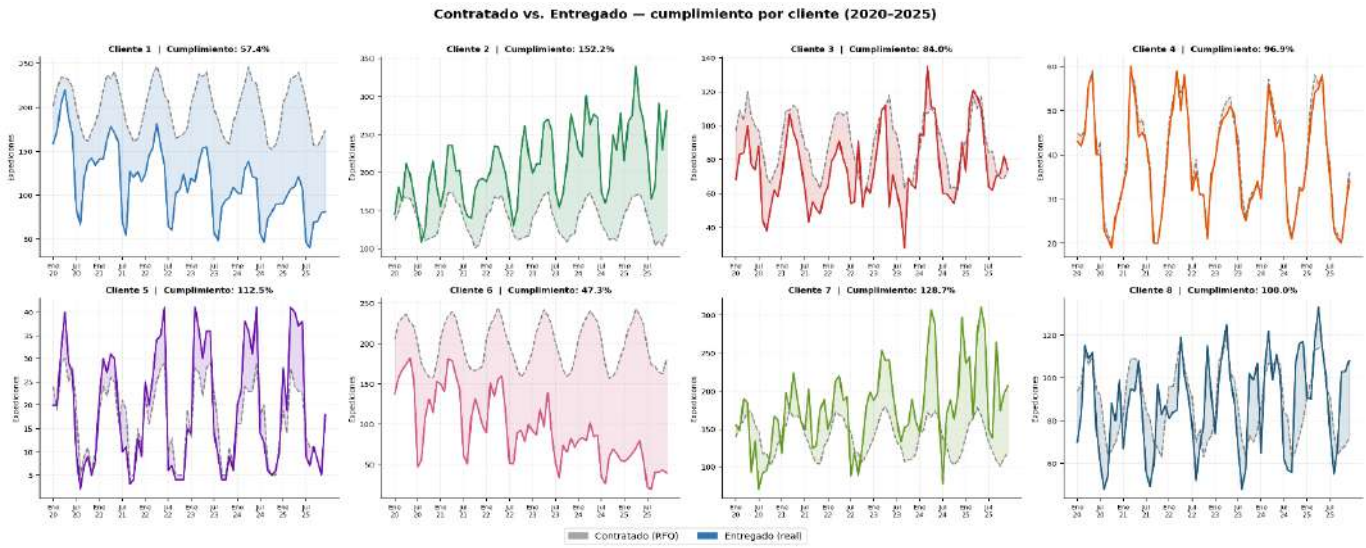

Figura 3: Gráficos comparativos entre el volumen contratado vs el volumen real entregado de los ocho clientes.

Las tasas de cumplimiento medias oscilan entre el 74% del cliente 3 y el 112% del cliente 2, lo que indica que el comportamiento puede desviarse considerablemente en ambas direcciones respecto al compromiso principal.

Asimismo, se observan patrones estacionales recurrentes en la mayoría de los clientes, con caídas de actividad durante los meses de verano y repuntes en el último trimestre del año.

El horizonte temporal se ha dividido en tres tramos con funciones distintas en el análisis. Los primeros 60 meses, enero 2020 hasta diciembre 2024 constituyen el período de entrenamiento, sobre el que se ajustan los parámetros de los modelos predictivos. Los 12 meses siguientes, enero 2025 hasta diciembre 2025, forman el período de validación, que se utiliza para evaluar la precisión de cada modelo comparando las predicciones con los valores reales conocidos.

Finalmente, los 12 meses del año 2026 constituyen el horizonte de previsión, que representa el resultado del ejercicio, la estimación de volumen de expediciones que el operador puede esperar durante el próximo año.

Esta estructura de validación fuera de la muestra es metodológicamente rigurosa porque garantiza que las métricas de error calculadas reflejan el rendimiento real

de cada modelo ate datos que no han visto durante el entrenamiento. De esta forma, las métricas obtenidas son comparables entre métodos y proporcionan una base fiable y objetiva para determinar cuál predice mejor en el contexto específico de este caso.

4.2 Propuesta metodológica

La propuesta de este trabajo se articula en torno a tres decisiones principales: la selección de los modelos predictivos, el procedimiento de aplicación y validación, y los criterios de evaluación y comparación de resultados.

Se han seleccionado tres enfoques de predicción de naturaleza y complejidad técnica distintas, con el objetivo de evaluar comparativamente su rendimiento sobre los mismos datos y determinar qué nivel de sofisticación está justificado en el contexto específico de un operador 3PL con datos parciales e imperfectos.

- Excel: Se utiliza como modelo de referencia, representando el enfoque, más extendido en la industria de la logística. Su elección responde a un criterio de representatividad, cualquier modelo sofisticado debe demostrar una mejora real sobre este método accesible para justificar el coste de su implementación.
- Sarima: Modelo estadístico de series temporales que captura explícitamente la tendencia, la estacionalidad y la estructura autorregresiva de la serie. Se aplica ckn la especificación (1,1,1) (1,0,1,12), que incorpora un cilio estacional anual de 12 meses. Esta configuración es adecuada para series mensuales con patrones estacionales recurrentes como los que presentan las expediciones de los clientes tender analizados.

- ANN (Red neuronal artificial): Modelo de aprendizaje automático que aprende patrones directamente a partir de los datos históricos, sin necesidad de asumir una forma concreta de la serie. Para predecir el volumen de un mes determinado, la red utiliza tres valores como entrada: el mes anterior, el mes de hace dos meses y el mismo mes el año pasado. Este último input es el que permite a la red capturar la estacionalidad, por ejemplo, si el julio pasado fue bajo la red aprende que el próximo julio probablemente también lo será.

El procedimiento de aplicación es idéntico para los tres modelos y se replica de forma independiente para cada uno de los ocho clientes. Consta de tres fases secuenciales, como se describe en el apartado anterior.

La comparación entre modelos se realiza mediante tres métricas estándar de error de predicción, calculadas sobre el período de validación 2025 para cada cliente y modelo.

- MAE (Error Absoluto Medio): Media de las diferencias absolutas entre los valores reales y los predichos. Indica cuántas expediciones de media se equivoca el modelo por mes, en términos absolutos. Es la métrica más intuitiva e interpretable operativamente.
- RMSE (Raíz del Error Cuadrático Medio): Similar al MAE pero penaliza más los errores grandes. Si un mes concreto tiene un error muy elevado, el RMSE lo refleja de forma más pronunciada que una media. Significativamente es más potente que el MAE, ya que destaca la presencia de meses con errores puntuales grandes.
- MAPE (Error Porcentual Absoluto Medio): Error medio expresado en porcentaje sobre el valor real. Permite comparar el rendimiento entre clientes con volúmenes de expediciones muy distintos, ya que normaliza el error respecto a la escala de cada serie.

La evaluación final se realiza comparando las tres métricas de los tres modelos para cada cliente, lo que permite identificar qué método predice con mayor precisión en cada caso y extraer conclusiones sobre la robustez de cada enfoque.

4.3 Resultados obtenidos

En esta sección se presentan los resultados del ejercicio de predicción para los tres modelos aplicados.

Para determinar el modelo con mejor rendimiento en cada cliente, se toma el MAPE como métrica referencia. Esta elección responde a que los ocho clientes presentan volúmenes de expediciones muy distintos entre sí. En este contexto, MAE no permite comparaciones directas entre clientes, ya que un error de 10 expediciones tiene un impacto relativo muy diferente según el volumen de cada

serie. El MAPE, al expresar el error en términos porcentuales sobre el valor real, normaliza esta diferencia de escala y permite una evaluación homogénea del rendimiento de cada modelo independientemente del volumen.

En primer lugar, la siguiente tabla recoge los resultados según las métricas de error obtenidas durante la validación sobre el período 2025.

Cliente	Excel (FORECAST.ETS)			SARIMA			ANN		
	MAE	RMSE	MAPE%	MAE	RMSE	MAPE%	MAE	RMSE	MAPE%
Cliente 1	9.52	13.45	15.24%	5.07	6.29	5.59%	5.79	7.23	7.82%
Cliente 2	36.21	43.69	14.93%	20.34	25.79	8.47%	25.40	30.32	10.08%
Cliente 3	23.54	32.90	23.23%	8.52	10.20	9.55%	10.03	12.19	12.46%
Cliente 4	3.29	4.12	10.02%	9.56	11.43	24.78%	5.98	7.11	18.52%
Cliente 5	5.20	6.21	31.36%	4.18	4.99	30.46%	7.36	8.21	59.95%
Cliente 6	18.74	21.42	49.61%	11.85	12.67	29.18%	10.51	12.41	21.63%
Cliente 7	51.14	60.46	27.29%	39.12	48.75	19.07%	58.13	73.65	25.13%
Cliente 8	5.28	6.37	6.24%	5.94	7.98	6.22%	8.03	12.18	8.22%

Tabla 5: Tabla comparativa de métrica de error: MAE, RMSE y MAPE).

En segundo lugar, se presentan, para cada cliente, las gráficas de validación de 2025 y las previsiones para 2026.

La gráfica de la izquierda es la validación, se pueden ver los valores reales y las predicciones de los tres modelos, y la de la derecha la previsión, donde se muestra el histórico y las predicciones de los tres modelos para el año siguiente.

Cliente 1:

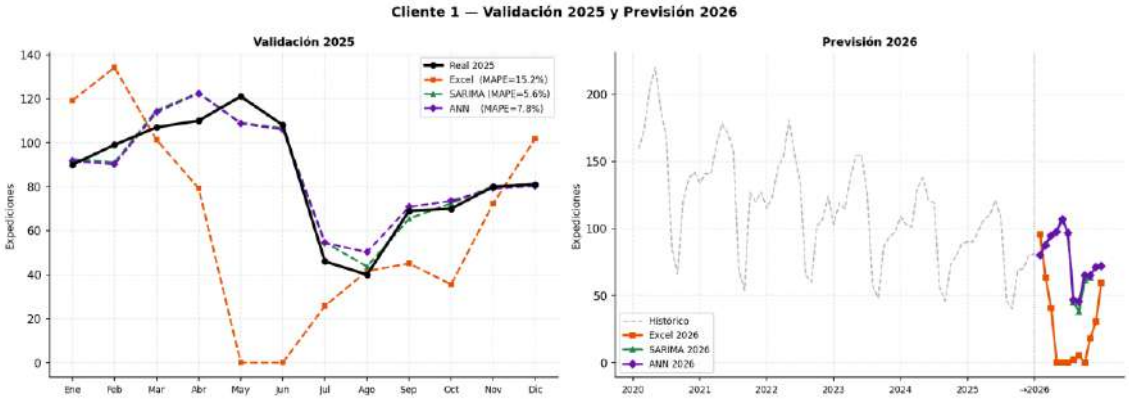

Figura 4: Gráficos cliente 1. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo.

Cliente 2:

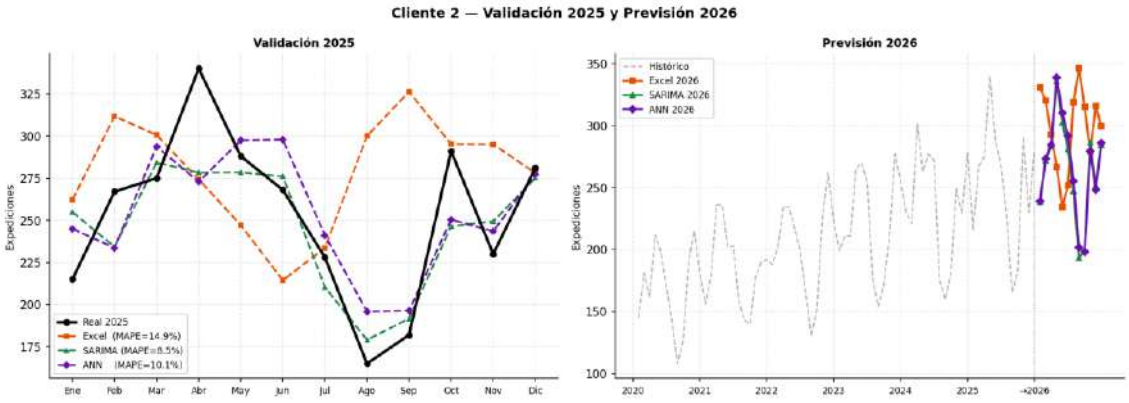

Figura 5: Gráficos cliente 2. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo.

Cliente 3:

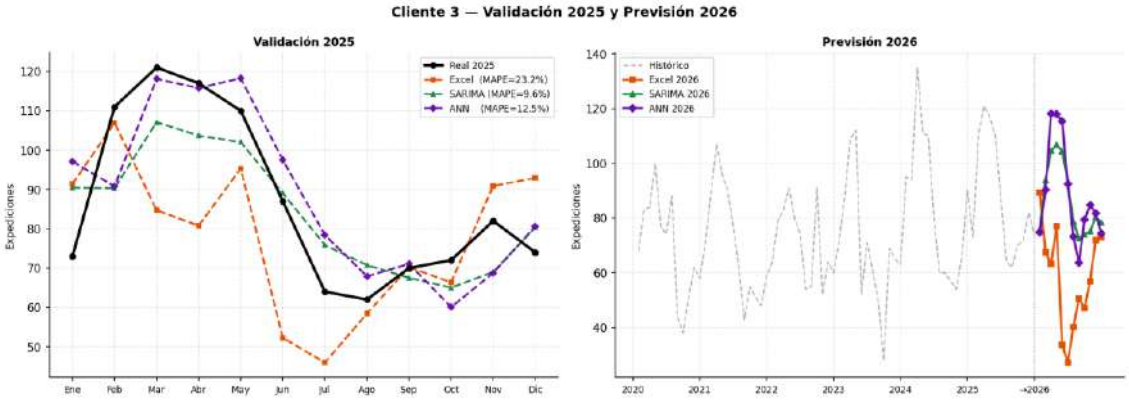

Figura 6: Gráficos cliente 3. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo.

Cliente 4:

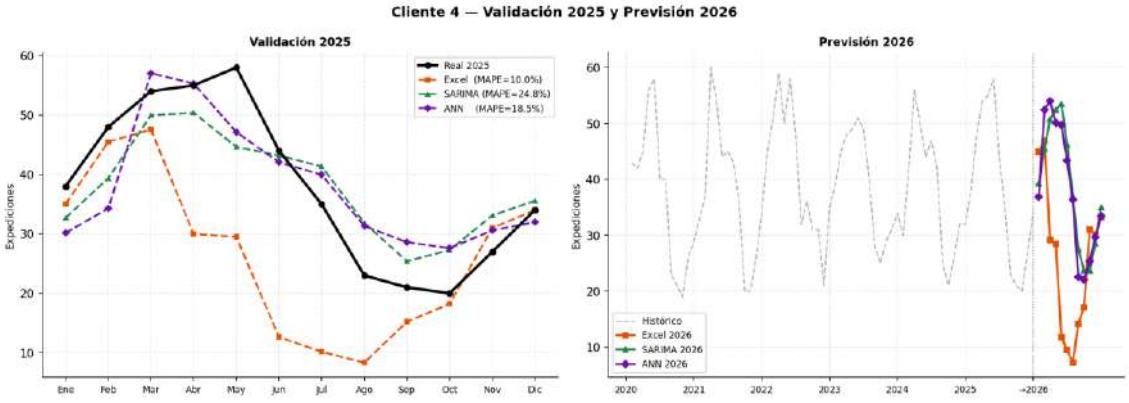

Figura 7: Gráficos cliente 4. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo.

Cliente 5:

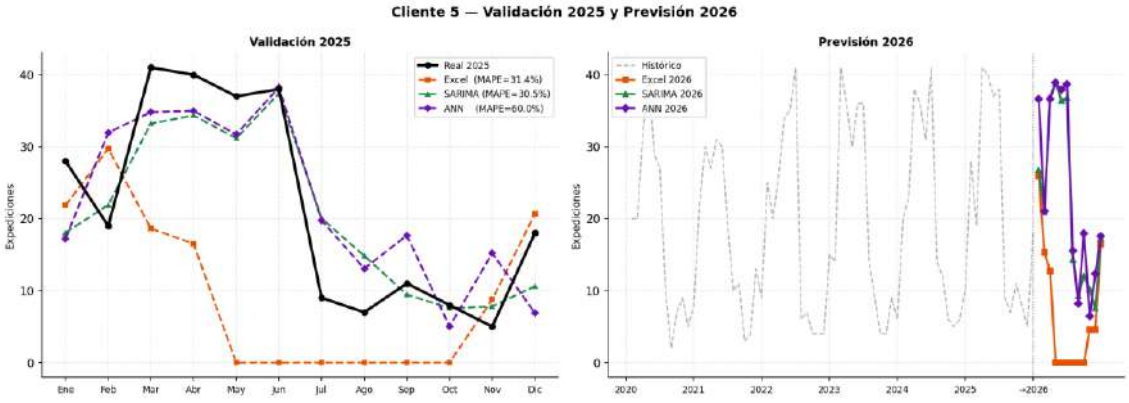

Figura 8: Gráficos cliente 5. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo.

Cliente 6:

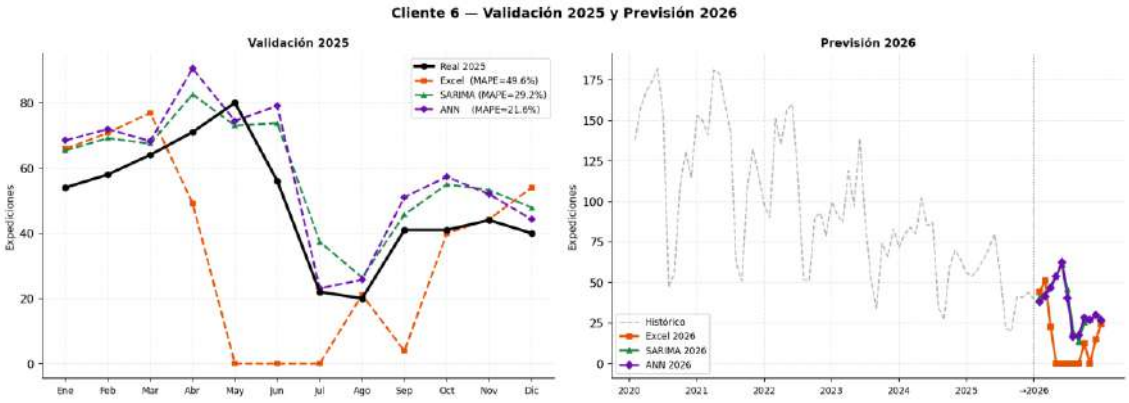

Figura 9: Gráficos cliente 6. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo.

Cliente 7:

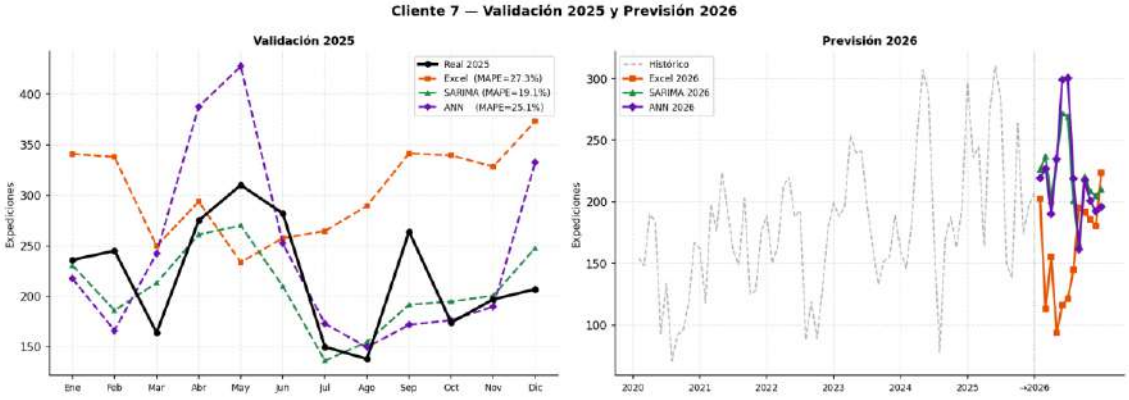

Figura 10: Gráficos cliente 7. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo.

Cliente 8:

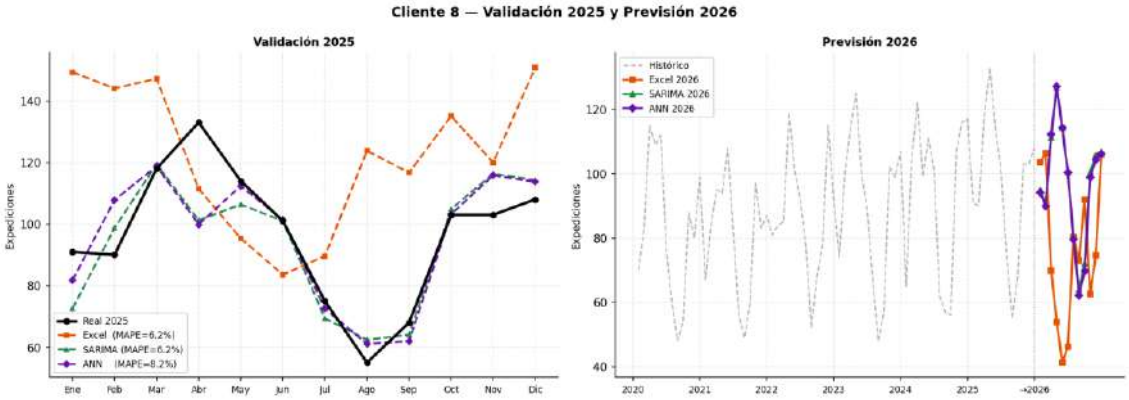

Figura 11: Gráficos cliente 8. A la izquierda, validación del 2025 comparando los valores reales de expediciones con las predicciones según modelo. A la derecha la previsión del 2026 según modelo.

4.4 Comparación de métodos y evaluación de métodos de predicción

A partir de los resultados del apartado anterior, es posible extraer una visión global del rendimiento de los tres modelos de predicción a lo largo de los ocho clientes. Tomando como referencia el MAPE de la validación de 2025, SARIMA obtiene el mejor resultado en cinco de los ocho clientes, ANN en uno y Excel en dos.

Estos resultados sugieren que SARIMA es, en términos generales, el método más consistente para la mayoría de los clientes analizados. Lo que resulta coherente con la naturaleza estacional de las series de expediciones, la mayoría de los clientes presentan patrones recurrentes a lo largo del año que SARIMA modela de forma explícita.

Sin embargo, los dos casos en los que Excel obtiene el mejor resultado son especialmente reveladores. El Cliente 4 es el cliente más fiable y estable de todos, con un cumplimiento cercano al 97% y baja variabilidad mensual; en este caso, un método simple como el suavizado exponencial de Excel es suficiente para capturar el comportamiento de la serie, y métodos más sofisticados no aportan una mejora real. El Cliente 7, por el contrario, es el más volátil de todos, con saltos bruscos mes a mes que ningún método predice con precisión y en este escenario de alta incertidumbre, el modelo más simple resulta, paradójicamente, el menos perjudicado por la volatilidad.

Esta observación tiene una implicación práctica relevante para un operador 3PL, la elección del método de predicción no debería ser uniforme para toda la cartera de clientes, sino que podría adaptarse al perfil de comportamiento de cada uno.

Clientes estables y predecibles pueden gestionarse adecuadamente con herramientas sencillas como Excel, mientras que clientes con estacionalidad marcada se benefician de métodos como SARIMA. Los clientes de alta volatilidad, en cambio, representan un reto para cualquier enfoque y podrían requerir estrategias adicionales de gestión de la incertidumbre, más allá de la mejora del método predictivo.

4.5 Limitaciones y líneas futuras

El ejercicio práctico desarrollado en este trabajo presenta una serie de limitaciones que conviene señalar, tanto por rigor académico como porque permiten identificar líneas de trabajo futuras que podrían enriquecer y dar continuidad a este estudio.

1. Limitaciones relativas a los datos:

Los datos utilizados son sintéticos, construidos a partir de patrones operativos reales, pero sin proceder de un único conjunto de datos históricos de una empresa concreta. Si bien esta aproximación, ha permitido rajar con un caso representativo y diverso sin comprometer información confidencial, los resultados obtenidos, en cuanto a magnitudes absolutas de error, deben interpretarse como ilustrativos del comportamiento relativo de los modelos, más que como una medida exacta del rendimiento que cabría esperar al aplicar estos métodos sobre datos reales de un operador concreto.

2. Limitaciones metodológicas:

Este trabajo se ha centrado en tres metodologías concretas, con un peso importante hacia el enfoque estadístico clásico frente a alternativas de aprendizaje automático más complejas. Esta decisión es tomada por accesibilidad, ya que las tres herramientas empleadas son de uso libre o están disponibles en cualquier escenario estándar, lo que permite que cualquier operador, independientemente de su tamaño, pueda replicar este análisis sin incurrir en costes.

Existen, sin embargo, herramientas de software comercial que integran capacidades de previsión avanzada, combinando varios algoritmos predictivos, paneles de visualización y actualizaciones automáticas de los modelos a medida que llegan nuevos datos.

Plataformas de Transportation Management System (TMS) con módulos predictivos, soluciones de Business Intelligence con capacidades de forecasting integrado, o plataformas SaaS especializadas en supply chain analytics, son ejemplos de este tipo de herramientas, ya mencionadas en apartados anteriores.

Estas soluciones suelen ofrecer una experiencia considerablemente más sencilla que la combinación de Excel y Python empleada en este trabajo, automatizando

gran parte del proceso de selección y ajuste de modelos. Y permitiendo centrarse en los datos de entrada y en el análisis de resultados obtenidos, sin necesidad de comprender el funcionamiento interno de cada algoritmo.

3. El reto de los clientes sin histórico:

Una limitación adicional, no abordada directamente en el caso práctico pero relevante para su aplicación real, son esos clientes que se incorporan a la cartera del operador sin un histórico de actividad propio. Los ocho clientes simulados en este trabajo cuentan con 72 meses de experiencia con el operador, lo que ha permitido entrenar y validar los modelos. En la práctica, se puede dar la situación de que entre un nuevo contrato tender y que no existan datos operativos previos, lo que se conoce como un problema de cold start.

Una posible solución sería aplicar la técnica del cliente espejo. Consiste en identificar, dentro de la cartera existente de clientes, características similares del nuevo cliente y utilizar el histórico de dichos clientes para ayudar a hacer una asunción de cómo podría funcionar la actividad del nuevo cliente. Si hay una similitud en los productos que comercializan los clientes probablemente tiendan a generar patrones logísticos.

La línea futura que este trabajo consistiría en realizar un estudio exhaustivo que vaya más allá de las variables consideradas en este trabajo. Dicho estudio debería analizar, por cada cliente tender de la cartera, su tendencia de actividad a lo largo del tiempo, su nivel de cumplimiento contractual, y un conjunto amplio de variables operativas adicionales como el volumen de kilogramos, los metros lineales, los metros cúbicos, el tipo de producto comercializado y el tipo de equipo requerido.

A partir de esta caracterización profunda, sería posible extraer conclusiones sobre qué tipo de herramientas de software y de inteligencia artificial resultarían más adecuadas para el operador en función del perfil agregado en la cartera. Un operador cuya cartera esté dominada por clientes estables y predecibles podría obtener un retorno limitado de la inversión en plataformas avanzadas, mientras que un operador con una cartera muy volátil podría justificar mejor el coste de herramientas más sofisticadas. En este sentido, el propio estudio descriptivo de

la cartera se convertiría en la base para una decisión de inversión tecnológica informada.

5. Conclusiones

5.1 Conclusiones principales

A lo largo de este trabajo se ha profundizado en el funcionamiento operativo de los operadores logísticos 3PL, prestando especial atención a los contratos tipo tender y a la incertidumbre que estos introducen en la planificación diaria.

La revisión del marco teórico ha permitido entender el contexto operativo de los operadores 3PL y, sobre esta base, se ha identificado un problema concreto y recurrente en este modelo de negocio. Básicamente, se trata de que el dato declarado por el cliente en el RFQ no garantiza el comportamiento real durante la vigencia del contrato. Esta brecha obliga al operador a planificar de forma reactiva, con desgaste y con la existencia de una pérdida de eficiencia grande.

Para abordar este problema de forma práctica, se ha construido un caso de estudio con ocho clientes simulados, cada uno simulando un perfil de comportamiento concreto. Sobre el histórico de expediciones de cada cliente se han aplicado tres modelos de predicción distinta. Los tres se han validado prediciendo el año 2025, del que ya se conocían valores reales, y posteriormente se han utilizado para generar previsiones de expediciones de cara al 2026.

Los resultados obtenidos muestran que SARIMA es, en términos generales, el modelo más consistente, obteniendo el mejor resultado en cinco de los ocho clientes. Sin embargo, ningún modelo resultó uniformemente superior.

Esta heterogeneidad demuestra que un modelo más complejo no es necesariamente mejor, sino que lo importante es elegir el modelo más adecuado para cada operador.

El hallazgo central de este trabajo es que aplicar cualquier de estos modelos aporta al operador información que el dato RFQ por si solo no puede ofrecer. Para un operador 3PL, disponer de una estimación mensual del volumen de

actividad esperado representa una mejora sustancial. El paso de no predecir nada a predecir con un modelo simple ya constituye, por sí mismo, una mejora relevante. Los modelos más sofisticados pueden aportar un valor adicional, pero la decisión de incorporar un enfoque de predicción es, en sí misma, más determinante que la elección del modelo concreto con el que se empiece.

De cara al futuro, la incorporación de capacidades predictivas en la operativa no debería entenderse como una sustitución al criterio de los planificadores, sino como una herramienta de apoyo que reduce la incertidumbre sobre la que se toman las decisiones. Las limitaciones observadas en este trabajo, señalan que el camino hacia una predicción de la demanda plenamente fiable en este sector requiere de mayor disponibilidad de datos reales y de enfoques que combinen distintos modelos según el perfil de cada cliente.

No obstante, este trabajo sugiere que, incluso con las herramientas más accesibles y sin necesidad de grandes inversiones tecnológicas, adoptar un enfoque de predicción de la demanda puede representar una primera aproximación útil y contribuir a mejoras operativas relevantes y que ese primer paso es el que marca la diferencia.

5.2 Respuesta a los objetivos

A continuación, se revisa el grado de cada uno de los objetivos específicos planteados. Al inicio de este trabajo.

- Estudiar y desglosar el funcionamiento operativo de un operador logístico.

Este objetivo se ha abordado en el marco teórico, donde se ha descrito la estructura de tareas de un operador 3PL y se ha contextualizado el papel de la planificación operativa. Esta base conceptual resulta imprescindible para interpretar correctamente los datos del caso práctico y para justificar por qué la predicción de la demanda operativa es relevante en este contexto.

- Entender el impacto real de la incertidumbre en la planificación.

Se ha cumplido tanto a nivel teórico como empírico. El marco teórico ha descrito cómo la falta de visibilidad sobre la actividad futura conduce a una planificación reactiva, con desgaste de los equipos y el deterioro de la calidad de las decisiones. El caso práctico ha cuantificado esta incertidumbre, mostrando que

las desviaciones entre lo contratado y lo entregado pueden alcanzar magnitudes muy significativas en algunos clientes.

- Comprender cómo trabajan los clientes tipo tender y sus limitaciones.

Este objetivo se ha desarrollado en profundidad, analizando las características de los contratos tender, el proceso de RFQ/RFI, y la brecha entre la información disponible y la información ideal que necesitaría un operador para planificar con certeza. El caso práctico ha ilustrado esta brecha con datos concretos para ocho perfiles de cliente distintos.

- Identificar el papel de la predicción de la demanda en la toma de decisiones.

Se ha cumplido mediante la aplicación práctica de los tres modelos predictivos y la generación de previsiones mensuales para 2026. Estas previsiones constituyen información que el operador no tendría disponible si se limitara a utilizar el dato contratado en el RFQ, y que puede emplearse para anticipar necesidades de capacidad, personal y recursos de transporte.

- Simular un entorno logístico real mediante datos.

Se ha cumplido mediante la construcción de un conjunto de datos sintéticos de ocho clientes tender, con seis años de histórico mensual, tres tipos de servicio (grupaje, LTL y FTL) y ocho perfiles de comportamiento diferenciados diseñados específicamente para representar la diversidad que cabría esperar en la cartera real de un operador 3PL.

- Aplicar técnicas de análisis y predicción sobre los datos obtenidos.

Se ha cumplido mediante la aplicación de los tres modelos predictivos sobre cada uno de los ocho clientes, con validación fuera de muestra sobre 2025 y generación de previsiones mensuales para los doce meses de 2026, tal como se planteaba en el objetivo.

5.3 Implicaciones para el sector

Más allá de los resultados específicos obtenidos para los ocho clientes del caso práctico, este trabajo permite extraer algunas implicaciones de interés para operadores logísticos 3PL que gestionan carteras de clientes tender.

En primer lugar, los resultados refuerzan la idea de que el dato contratado en el RFQ no debería utilizarse de forma aislada como base de planificación. La magnitud de las desviaciones observadas —en ambas direcciones, tanto de sobre-entrega como de incumplimiento— sugiere que cualquier operador que base su planificación exclusivamente en el dato del tender está trabajando con información sistemáticamente sesgada.

En segundo lugar, la heterogeneidad de resultados entre clientes apunta a que la inversión en capacidades predictivas debería ser proporcional a la complejidad real de cada cliente, y no necesariamente uniforme para toda la cartera. Un cliente estable puede gestionarse adecuadamente con herramientas accesibles como Excel, mientras que clientes con estacionalidad marcada se benefician de modelos como SARIMA. Esta conclusión tiene una implicación práctica directa: antes de invertir en plataformas predictivas avanzadas para toda la cartera, puede resultar más eficiente realizar un diagnóstico previo que identifique qué segmentos de clientes justifican realmente esa inversión.

Por último, el hecho de que el modelo más simple (Excel) haya obtenido el mejor resultado en dos de los ocho clientes —incluyendo el más volátil de todos— es un recordatorio de que la sofisticación técnica no es un fin en sí mismo. Para un operador 3PL, especialmente uno de tamaño medio sin equipos de datos propios, comenzar con herramientas accesibles y evolucionar de forma progresiva hacia modelos más complejos solo cuando estos demuestren una mejora real puede ser una estrategia más sostenible que la adopción directa de la solución más avanzada disponible en el mercado.

Referencias

[1] Al_Admin. (2025, 31 marzo). Operador Logístico. Qué es y por qué lo necesitas. *Blog Across Logistics*. https://acrosslogistics.com/blog/operador-logistico

[2] *¿Qué es la supply chain y cuál es la importancia de gestionar la cadena de suministro?* (2025, 8 agosto). Santander Open Academy. https://www.santanderopenacademy.com/es/blog/Que-es-supply-chain.html.

[3] Partidaweb. (2026, 7 abril). *Types of Logistics Operators in Global Supply Chains - Partida Logistic*. Partida Logistic. https://www.partidalogistics.com/en/types-of-logistics-operators-in-global-supply-chains/

[4] *Tipos operadores logísticos diferencias | DSV*. (s. f.). https://www.dsv.com/es-es/ayuda/faq/que-es-1pl-2pl-3pl-4pl-5pl

[5] Paula. (2026, 13 enero). *What is 1PL, 2PL, 3PL, 4PL and 5PL? Differences between logistics operators*. Spain. https://www.fmlogistic.es/en/blog/types-logistical-operators/

[6] Brunet. (2026, 11 marzo). *Grupaje terrestre: qué es, cómo funciona y cuándo compensa*. Transportes de Sabadell. https://transportesabadell.com/grupaje-terrestre-que-es-como-funciona-y-cuando-compensa/

[7] *Capacity Management in Logistics and Supply Chain: What Is Capacity Management in Logistics? Examples of Capacity Management, Measuring Capacity in Logistics*. (s. f.). https://www.reloadlogistics.com/news/capacity-management-in-logistics-and-supply-chain

[8] *Logistics capacity planning challenges*. (s. f.). CapaPlanner. https://capaplanner.com/blog/LogisticsCapacityPlanning

[9] Triskell Software. (2025, 5 noviembre). *Planificación de la capacidad: la guía definitiva para tu negocio*. https://triskellsoftware.com/es/blog/planificacion-capacidad/

[10] *From Bottleneck to Breakthrough: Solving Capacity Constraints in Logistics*. (s. f.). https://racklify.com/encyclopedia/from-bottleneck-to-breakthrough-solving-capacity-constraints-in-logistics/

[11] Finn, T., & Smalley, I. (2026, 7 enero). Previsión de la demanda. *¿Qué es la previsión de la demanda?* https://www.ibm.com/es-es/think/topics/demand-forecasting

[12] *Qué es la previsión de demanda o demand forecasting*. (s. f.). https://amphoralogistics.com/es/blog/qu%C3%A9-es-la-previsi%C3%B3n-de-demanda-o-demand-forecasting

[13] decide4AI, & decide4AI. (2026, 7 abril). *Casos de uso reales de forecasting*. Decide. https://decidesoluciones.es/casos-de-uso-reales-de-forecasting/

[14] Meribia. (s. f.). *Meribia Blog: Integración TMS y ERP/CMR: Clave en Logística*. https://www.meribia.net/es/blog/integracion-tms-y-erp-cmr-clave-en-logistica

[15] Juan. (2021, 20 julio). *Protección de datos en el transporte y logística. Guía 2021*. Ayuda Ley Protección Datos. https://ayudaleyprotecciondatos.es/transporte-logistica/#Normativa_de_Proteccion_de_Datos_que_deben_cumplir_las_empresas_de_transporte_y_logistica

[16] De Imagina, E. (2024, 10 octubre). Todo sobre los Pronósticos y Tendencias en Excel. *Imagina Formación*. https://imaginaformacion.com/tutoriales/pronosticos-tendencias-excel

[17] Canessa, R. (2024, 2 julio). ¿Qué es el modelo SARIMA? | Técnicas de Trading. *Técnicas de Trading*. https://www.tecnicasdetrading.com/2024/07/modelo-sarima.html

[18] *ANN*. (2026, 4 marzo). https://www.indicio.com/es/forecasting-models/ann

[19] *Sistema de gestión y logística de transporte | TMS | SAP*. (s. f.). SAP. https://www.sap.com/spain/products/scm/transportation-logistics.html

[20] Solistica. (s. f.). *Business Intelligence: La clave para optimizar tu logística*. https://blog.solistica.com/business-intelligence-la-clave-para-optimizar-tu-log%C3%ADstica

[21] Lindquist, M. (2025, 18 diciembre). *AI in Demand Forecasting: Overview, Use Cases, and Benefits*. https://www.oracle.com/es/scm/ai-demand-forecasting/

[22] *Freight Tendering (RFP/RFQ) | Logistics Glossary Easy4Pro*. (s. f.). Easy4pro. https://www.easy4pro.com/glossary/freight-tendering-(rfp%2Frfq)

[23] Logistics, B., & Logistics, B. (2023, 27 septiembre). *RFP and RFQ: What They Mean And Why They're Important*. Brimich Logistics. https://www.thebrimichgroup.com/rfp-and-rfq-meaning-and-importance/

Anexos

Los modelos predictivos descritos en este capítulo se han ejecutado en Google Colab, un entorno de programación en la nube que no requiere instalación local y proporciona acceso gratuito a las librerías de Python necesarias (statsmodels, scikit-learn), lo que permite su réplica por cualquier persona sin necesidad de configurar un entorno de desarrollo propio.

El propósito principal de este programa es realizar los cálculos de los modelos SARIMA y ANN, obtener sus resultados y compararlos con las predicciones generadas mediante Excel, permitiendo así una evaluación objetiva del rendimiento de cada método. Para el desarrollo y la comprensión del código empleado se ha contado con el apoyo de herramientas de inteligencia artificial.



```python
from google.colab import files
import pandas as pd
import numpy as np

archivo = files.upload()

CLIENTES = [f"Cliente {i+1}" for i in range(8)]

series = {}
for cliente in CLIENTES:
    df = pd.read_excel("Caso Práctico Inputs.xlsx",
                       sheet_name=cliente,
                       header=4,
                       usecols=[2])
    df.columns = ["Entregado"]
    df["Entregado"] = pd.to_numeric(df["Entregado"], errors="coerce")
    df = df.dropna()
    series[cliente] = df["Entregado"].values[:72].astype(float)
    print(f"{cliente}: {len(series[cliente])} meses cargados")

from statsmodels.tsa.statespace.sarimax import SARIMAX

MESES_TRAIN = 60
PERIODOS_2025 = ['Jan-25','Feb-25','Mar-25','Apr-25','May-25','Jun-25',
                 'Jul-25','Aug-25','Sep-25','Oct-25','Nov-25','Dec-25']
PERIODOS_2026 = ['Jan-26','Feb-26','Mar-26','Apr-26','May-26','Jun-26',
                 'Jul-26','Aug-26','Sep-26','Oct-26','Nov-26','Dec-26']

print("\n" + "=" * 55)
print("RESULTADOS SARIMA — VALIDACIÓN 2025")
print("=" * 55)
print(f"{'Cliente':<12} {'MAE':>8} {'RMSE':>8} {'MAPE %':>8}")
print("-" * 40)

resultados_sarima = {}
```

```
    print(f"{cliente:<12} {mae:>8.2f} {rmse:>8.2f} {mape:>8.2f}")

print("-" * 40)

print("\n" + "=" * 55)
print("PREVISIÓN 2026 — SARIMA")
print("=" * 55)
for cliente in CLIENTES:
    print(f"\n{cliente}:")
    for mes, val in zip(PERIODOS_2026, resultados_sarima[cliente]["pred_2026"]):
        print(f"  {mes}: {val:.1f}")

PERIODOS_HIST = ['Jan-20','Feb-20','Mar-20','Apr-20','May-20','Jun-20',
                 'Jul-20','Aug-20','Sep-20','Oct-20','Nov-20','Dec-20',
                 'Jan-21','Feb-21','Mar-21','Apr-21','May-21','Jun-21',
                 'Jul-21','Aug-21','Sep-21','Oct-21','Nov-21','Dec-21',
                 'Jan-22','Feb-22','Mar-22','Apr-22','May-22','Jun-22',
                 'Jul-22','Aug-22','Sep-22','Oct-22','Nov-22','Dec-22',
                 'Jan-23','Feb-23','Mar-23','Apr-23','May-23','Jun-23',
                 'Jul-23','Aug-23','Sep-23','Oct-23','Nov-23','Dec-23',
                 'Jan-24','Feb-24','Mar-24','Apr-24','May-24','Jun-24',
                 'Jul-24','Aug-24','Sep-24','Oct-24','Nov-24','Dec-24',
                 'Jan-25','Feb-25','Mar-25','Apr-25','May-25','Jun-25',
                 'Jul-25','Aug-25','Sep-25','Oct-25','Nov-25','Dec-25']

with pd.ExcelWriter("SARIMA_resultados.xlsx", engine="openpyxl") as writer:
    for cliente in CLIENTES:
        r     = resultados_sarima[cliente]
        y_val = series[cliente][60:]

        df_val = pd.DataFrame({
            "Período":          PERIODOS_HIST[60:],
            "Mes":              list(range(61, 73)),
            "Entregado Real":   y_val.astype(int),
            "Previsión SARIMA": [round(v, 1) for v in r["pred_val"]],
            "Error Absoluto":   [round(abs(a-b), 1) for a, b in zip(y_val, r["pred_val"])]
        })
```

```
for cliente in CLIENTES:
    y       = series[cliente]
    y_train = y[:MESES_TRAIN]
    y_val   = y[MESES_TRAIN:]

    modelo = SARIMAX(
        y_train,
        order=(1, 1, 1),
        seasonal_order=(1, 0, 1, 12),
        enforce_stationarity=False,
        enforce_invertibility=False
    )
    resultado = modelo.fit(disp=False)

    pred_val = np.array(resultado.get_forecast(steps=12).predicted_mean)
    pred_val = np.maximum(pred_val, 0)

    mae  = np.mean(np.abs(y_val - pred_val))
    rmse = np.sqrt(np.mean((y_val - pred_val)**2))
    mape = np.mean(np.abs((y_val - pred_val) / np.where(y_val==0, 1, y_val))) * 100

    modelo2 = SARIMAX(
        y,
        order=(1, 1, 1),
        seasonal_order=(1, 0, 1, 12),
        enforce_stationarity=False,
        enforce_invertibility=False
    )
    resultado2 = modelo2.fit(disp=False)
    pred_2026 = np.array(resultado2.get_forecast(steps=12).predicted_mean)
    pred_2026 = np.maximum(pred_2026, 0)

    resultados_sarima[cliente] = {
        "pred_val":  pred_val,
        "pred_2026": pred_2026,
        "MAE":  mae,
        "RMSE": rmse,
        "MAPE": mape,
    }
```

```
        df_val.loc[len(df_val)] = ["MAE",      "", "", "", round(r["MAE"],  2)]
        df_val.loc[len(df_val)] = ["RMSE",     "", "", "", round(r["RMSE"], 2)]
        df_val.loc[len(df_val)] = ["MAPE (%)", "", "", "", round(r["MAPE"], 2)]

        df_2026 = pd.DataFrame({
            "Período":          PERIODOS_2026,
            "Mes":              list(range(73, 85)),
            "Previsión SARIMA": [round(v, 1) for v in r["pred_2026"]]
        })

        df_val.to_excel(writer,  sheet_name=f"{cliente}_Val",  index=False)
        df_2026.to_excel(writer, sheet_name=f"{cliente}_2026", index=False)

files.download("SARIMA_resultados.xlsx")
print("Excel descargado.")

import matplotlib.pyplot as plt

meses_hist = np.arange(1, 73)
meses_val  = np.arange(61, 73)
meses_2026 = np.arange(73, 85)

fig, axes = plt.subplots(2, 4, figsize=(18, 8))
fig.suptitle("SARIMA – Validación 2025 y Previsión 2026",
             fontsize=13, fontweight="bold")

for i, cliente in enumerate(CLIENTES):
    ax = axes[i // 4][i % 4]
    r  = resultados_sarima[cliente]

    ax.plot(meses_hist, series[cliente],
            linestyle="--", color="gray", linewidth=1.5, label="Real")
    ax.plot(meses_val, r["pred_val"],
            linestyle="-", color="orange", linewidth=2, label="Pred. 2025")
    ax.plot(meses_2026, r["pred_2026"],
            linestyle="-", color="green", linewidth=2, label="Prev. 2026")

    ax.axvline(x=60, color="blue", linestyle=":", linewidth=1)
    ax.axvline(x=72, color="red",  linestyle=":", linewidth=1)

    ax.set_title(
        f"{cliente}\nMAE={r['MAE']:.1f} | MAPE={r['MAPE']:.1f}%",
        fontsize=8
    )
    ax.set_xlabel("Mes", fontsize=7)
    ax.set_ylabel("Expediciones", fontsize=7)
    ax.legend(fontsize=6)
    ax.grid(True, alpha=0.3)

plt.tight_layout()
plt.show()
```

```python
from google.colab import files
import pandas as pd
import numpy as np

archivo = files.upload()

CLIENTES = [f"Cliente {i+1}" for i in range(8)]

series = {}
for cliente in CLIENTES:
    df = pd.read_excel("Caso Práctico Inputs.xlsx",
                       sheet_name=cliente,
                       header=4,
                       usecols=[2])
    df.columns = ["Entregado"]
    df["Entregado"] = pd.to_numeric(df["Entregado"], errors="coerce")
    df = df.dropna()
    series[cliente] = df["Entregado"].values[:72].astype(float)
    print(f"{cliente}: {len(series[cliente])} meses cargados")

PERIODOS_2026 = ['Jan-26','Feb-26','Mar-26','Apr-26','May-26','Jun-26',
                 'Jul-26','Aug-26','Sep-26','Oct-26','Nov-26','Dec-26']

PERIODOS_HIST = ['Jan-20','Feb-20','Mar-20','Apr-20','May-20','Jun-20',
                 'Jul-20','Aug-20','Sep-20','Oct-20','Nov-20','Dec-20',
                 'Jan-21','Feb-21','Mar-21','Apr-21','May-21','Jun-21',
                 'Jul-21','Aug-21','Sep-21','Oct-21','Nov-21','Dec-21',
                 'Jan-22','Feb-22','Mar-22','Apr-22','May-22','Jun-22',
                 'Jul-22','Aug-22','Sep-22','Oct-22','Nov-22','Dec-22',
                 'Jan-23','Feb-23','Mar-23','Apr-23','May-23','Jun-23',
                 'Jul-23','Aug-23','Sep-23','Oct-23','Nov-23','Dec-23',
                 'Jan-24','Feb-24','Mar-24','Apr-24','May-24','Jun-24',
                 'Jul-24','Aug-24','Sep-24','Oct-24','Nov-24','Dec-24',
                 'Jan-25','Feb-25','Mar-25','Apr-25','May-25','Jun-25',
                 'Jul-25','Aug-25','Sep-25','Oct-25','Nov-25','Dec-25']

```

```python
from sklearn.neural_network import MLPRegressor
from sklearn.preprocessing import StandardScaler
from sklearn.pipeline import Pipeline

print("=" * 55)
print("RESULTADOS ANN — VALIDACIÓN 2025")
print("=" * 55)
print(f"{'Cliente':<12} {'MAE':>8} {'RMSE':>8} {'MAPE %':>8}")
print("-" * 40)

resultados_ann = {}

for cliente in CLIENTES:
    y       = series[cliente]
    y_train = y[:60]
    y_val   = y[60:]

    def crear_inputs(serie, inicio, fin):
        X, target = [], []
        for t in range(12, len(serie)):
            if t >= inicio and t < fin:
                X.append([serie[t-1], serie[t-2], serie[t-12]])
                target.append(serie[t])
        return np.array(X), np.array(target)

    X_train, y_target = crear_inputs(y_train, 12, len(y_train))

    ann = Pipeline([
        ("scaler", StandardScaler()),
        ("ann", MLPRegressor(
            hidden_layer_sizes=(10, 5),
            activation="relu",
            solver="adam",
            max_iter=5000,
            random_state=42
        ))
    ])
    ann.fit(X_train, y_target)
```

```
    serie_ext = list(y_train.copy())
    pred_val  = []
    for _ in range(12):
        t = len(serie_ext)
        x = np.array([[serie_ext[t-1], serie_ext[t-2], serie_ext[t-12]]])
        pred = ann.predict(x)[0]
        pred_val.append(max(pred, 0))
        serie_ext.append(pred)
    pred_val = np.array(pred_val)

    mae  = np.mean(np.abs(y_val - pred_val))
    rmse = np.sqrt(np.mean((y_val - pred_val)**2))
    mape = np.mean(np.abs((y_val - pred_val) / np.where(y_val==0, 1, y_val))) * 100

    X_full, y_full = crear_inputs(y, 12, len(y))
    ann2 = Pipeline([
        ("scaler", StandardScaler()),
        ("ann", MLPRegressor(
            hidden_layer_sizes=(10, 5),
            activation="relu",
            solver="adam",
            max_iter=5000,
            random_state=42
        ))
    ])
    ann2.fit(X_full, y_full)

    serie_ext2 = list(y.copy())
    pred_2026  = []
    for _ in range(12):
        t = len(serie_ext2)
        x = np.array([[serie_ext2[t-1], serie_ext2[t-2], serie_ext2[t-12]]])
        pred = ann2.predict(x)[0]
        pred_2026.append(max(pred, 0))
        serie_ext2.append(pred)
    pred_2026 = np.array(pred_2026)
```

```

    resultados_ann[cliente] = {
        "pred_val":  pred_val,
        "pred_2026": pred_2026,
        "MAE":  mae,
        "RMSE": rmse,
        "MAPE": mape,
    }

    print(f"{cliente:<12} {mae:>8.2f} {rmse:>8.2f} {mape:>8.2f}")

print("-" * 40)
print("Completado.")

from google.colab import files
import pandas as pd

with pd.ExcelWriter("ANN_resultados.xlsx", engine="openpyxl") as writer:
    for cliente in CLIENTES:
        r     = resultados_ann[cliente]
        y_val = series[cliente][60:]

        df_val = pd.DataFrame({
            "Período":       PERIODOS_HIST[60:],
            "Mes":           list(range(61, 73)),
            "Entregado Real":   y_val.astype(int),
            "Previsión ANN": [round(v, 1) for v in r["pred_val"]],
            "Error Absoluto":   [round(abs(a-b), 1) for a, b in zip(y_val, r["pred_val"])]
        })
        df_val.loc[len(df_val)] = ["MAE",       "", "", "", round(r["MAE"],  2)]
        df_val.loc[len(df_val)] = ["RMSE",      "", "", "", round(r["RMSE"], 2)]
        df_val.loc[len(df_val)] = ["MAPE (%)", "", "", "", round(r["MAPE"], 2)]

        df_2026 = pd.DataFrame({
            "Período":       PERIODOS_2026,
            "Mes":           list(range(73, 85)),
            "Previsión ANN": [round(v, 1) for v in r["pred_2026"]]
        })
```

```
151
152         df_val.to_excel(writer,  sheet_name=f"{cliente}_Val",  index=False)
153         df_2026.to_excel(writer, sheet_name=f"{cliente}_2026", index=False)
154
155 files.download("ANN_resultados.xlsx")
156 print("Excel descargado.")
157
```